

**Universidade Estadual Paulista  
Faculdade de Engenharia de Ilha Solteira  
Programa de Pós-Graduação em Engenharia Elétrica**

**ANALISE DINÂMICA DE CONTINGÊNCIAS DE  
SISTEMAS DE ENERGIA ELÉTRICA POR REDES  
NEURAIS BASEADAS NA TEORIA DA RESSONÂNCIA  
ADAPTATIVA**

**Wagner Peron Ferreira**

Orientador: Prof. Dr. Carlos Roberto Minussi

Tese de Doutorado submetida ao Programa de Pós-Graduação em Engenharia Elétrica da Faculdade de Engenharia de Ilha Solteira – UNESP, como parte dos requisitos para a obtenção do título de Doutor em Engenharia Elétrica.

Ilha Solteira - SP, novembro de 2003.

A Deus.

Aos meus pais Anna e Maercy.

À minha mulher Eliane.

## **AGRADECIMENTOS**

Agradeço ao Professor Doutor Carlos Roberto Minussi pela orientação, dedicação, incentivo, amizade, paciência e principalmente por acreditar em meu potencial.

Ao apoio financeiro da CAPES, Coordenação de Aperfeiçoamento de Pessoal de Nível Superior.

Ao meu irmão, Maercy, pelo apoio recebido.

Aos meus colegas do Departamento de Engenharia Elétrica (DEE) do curso de pós-graduação.

Às funcionárias da seção de pós-graduação pela atenção e dedicação.

Aos professores do DEE que, direta ou indiretamente, ajudaram no desenvolvimento desta pesquisa.

Aos funcionários do DEE, com atenção especial para o setor de informática e para a secretaria.

## RESUMO

Este trabalho de pesquisa tem por objetivo o desenvolvimento de uma metodologia para a análise dinâmica de contingências de sistemas de energia elétrica por redes neurais, cuja motivação deve-se ao fato de que as redes neurais, ainda que demandem um considerável tempo de processamento para a execução do treinamento, podem realizar diagnósticos em tempo real. Para tanto, será desenvolvido um modelo que estabelece a relação entre entradas e saídas da rede com um menor número possível de variáveis. A rede neural corresponde a uma nova configuração chamada ART&ARTMAP nebulosa baseada na arquitetura ART (*Adaptive Resonance Theory*). As redes neurais ART possuem como características mais importantes a plasticidade e a estabilidade, as quais são qualidades primordiais para a execução do treinamento e para a análise de modo eficiente. A rede neural ART&ARTMAP nebulosa está sendo proposta visando proporcionar um desempenho superior, em termos de precisão e rapidez, se comparada à formulação ARTMAP convencional e maior ainda quando comparada a outras redes neurais disponíveis na literatura especializada. A principal característica da rede neural ART&ARTMAP nebulosa refere-se ao gerenciamento de dados analógicos e binários estabelecidos no modelo do sistema de tal modo que estes dados são tratados separadamente, ou seja, os dados analógicos são processados e transformados em um conjunto equivalente binário. Deste modo, tem-se uma concepção que manipula somente dados na forma binária, tendo como resultado uma redução da dimensão do problema e melhor qualidade das soluções. A metodologia proposta é um procedimento que incorpora inovações em relação à literatura existente, em destaque: proposta de uma nova arquitetura de rede neural baseada na teoria da ressonância adaptativa chamada rede neural ART&ARTMAP nebulosa. A rede neural proposta apresenta-se como promissora, também, para aplicações em várias áreas do conhecimento. São enfocadas as aplicações no problema da análise dinâmica de contingências, em destaque o problema da análise de estabilidade transitória, considerando-se, primeiramente, um sistema de 3 máquinas síncronas e, posteriormente, um sistema de energia elétrica composto por 10 máquinas síncronas, 42 linhas de transmissão e 45 barras. São discutidas, também, outras abordagens em várias áreas do conhecimento humano.

## ABSTRACT

This work aims to develop a methodology to contingency dynamic analyzing of electric energy systems by neural networks, considering that the neural networks, although usually spend a considerable time during the training phase can produce diagnosis in real time. Therefore, it is developed a model that establishes a relation between input and output of the network with the least quantity of possible variables, being an optimized structural system. The neural network corresponds to a new configuration called fuzzy ART&ARTMAP based on the ART (*Adaptive Resonance Theory*). The most important characteristics of ART neural networks are plasticity and stability, primordial features for training and for an efficient analysis. The fuzzy ART&ARTMAP neural network is proposed to proportionate a superior performance in terms of precision and velocity, when compared to the conventional ARTMAP formulation and even more superior when compared to other neural networks available in the literature. The principal characteristic of the fuzzy ART&ARTMAP is the binary and analog management, established on the model of the system, such that these data are treated isolated, i.e., the analog data are processed and transformed in an equivalent binary set. This way, it is found a conception that manipulate only binary data, and the results show a reduction on the dimension of the problem and better quality on the solutions. The proposed methodology is a proceeding that incorporates innovations in relation to the existent literature, such as: proposal of a new architecture of neural network based on the adaptive resonance theory called fuzzy ART&ARTMAP. The proposed neural network is promising for applications in several areas of the knowledge. It is focused the application in security analysis, specially the transient stability analysis, considering, firstly, a system of 3 synchronous machines and then a system composed of 10 synchronous machines, 42 transmission lines, and 45 buses. Approaches in other areas of the human knowledge are also discussed.

## SUMÁRIO

1 – Introdução .....	1
2 - Análise de Segurança de Sistemas de Energia Elétrica .....	5
2.1. Introdução .....	5
2.2. Análise Estática X Análise Dinâmica.....	5
2.3. Estados de Operação dos Sistemas de Energia Elétrica .....	8
2.4. Conclusão .....	13
3 – Redes Neurais Artificiais .....	14
3.1. Introdução .....	14
3.2. Histórico .....	14
3.3. Características Gerais .....	15
3.4. Modelo Biológico de um Neurônio .....	16
3.5. Modelo do Neurônio Artificial .....	17
3.6. Treinamento .....	20
3.7. Principais Redes Neurais .....	23
3.8. Conclusão.....	24
4 - Rede Neural ART .....	25
4.1. Introdução .....	25
4.2. Características Básicas do Sistema ART .....	25
4.3. Algoritmo ART Nebuloso .....	27
4.3.1. Valores Iniciais dos Pesos .....	27
4.3.2. Iniciação dos Parâmetros da Rede .....	28
4.3.3. Normalização do Vetor de Entrada .....	28
4.3.4. Codificação do Complemento .....	28
4.3.5. Escolha da Categoria .....	29
4.3.6. Teste de Vigilância .....	30
4.3.7. Treinamento .....	30
4.4. Representação Geométrica do Algoritmo ART Nebuloso .....	31
4.5. Conclusão .....	36
5 - Rede Neural ARTMAP .....	37
5.1. Introdução .....	37



5.2 Características da Rede Neural ARTMAP Nebulosa .....	37
5.3. Algoritmo do Sistema ARTMAP Nebuloso .....	39
5.4. Exemplo Ilustrativo .....	43
5.4.1. Critério de Igualdade de Áreas .....	43
5.4.2. Exemplo Numérico .....	45
5.5. Conclusão .....	51
6 - Formulação do Problema da Análise de Segurança de Sistemas Elétricos de Potência por Redes Neurais .....	52
6.1. Introdução .....	52
6.2. Formulação .....	52
6.3. Definição dos Estímulos de Entrada .....	59
6.4. Definição dos Estímulos de Saída .....	62
6.5. Definição do Perfil de Geração e de Carga .....	64
6.6. Conclusão .....	67
7 - Rede Neural Proposta .....	68
7.1. Introdução .....	68
7.2. Rede Neural ART&ARTMAP Nebulosa .....	69
7.3. Conclusão .....	71
8 - Aplicações .....	72
8.1. Introdução .....	72
8.2. Análise de Estabilidade Transitória.....	73
8.3. Análise de Segurança de um Sistema de 3 barras .....	78
8.4. Análise de Segurança do Sistema Sul-Brasileiro .....	84
8.5. Outras Aplicações .....	91
8.6. Conclusão .....	94
9 – Conclusões e Sugestões para Trabalhos Futuros .....	95
9.1. Conclusões.....	95
9.2. Sugestões para Trabalhos Futuros .....	97
Referências Bibliográficas .....	99
Apêndice A – Dados do Sistema de Energia Elétrica .....	109
Apêndice B – Artigos Publicados .....	114

# CAPÍTULO 1

## INTRODUÇÃO

Esta pesquisa tem por objetivo o desenvolvimento de uma metodologia para análise dinâmica de contingências de sistemas de energia elétrica por redes neurais artificiais baseadas na Teoria da Ressonância Adaptativa (ART) (*Adaptive Resonance Theory*) [11]–[16]. A análise de segurança consiste de um conjunto de procedimentos praticados na operação e planejamento de sistemas elétricos de potência com o propósito de inferir sobre os efeitos provocados por defeitos, manobras operativas, etc., enfim por toda e qualquer perturbação que modifique o ponto de equilíbrio (estado) do sistema. Estas inferências são realizadas, na maioria das vezes, por observação de algum índice, o qual é usado para avaliar o grau de severidade da contingência (defeito) sobre o sistema. Logo, qualquer que seja a perturbação aplicada ao sistema – de pequena escala ou de grande escala – o seu impacto pode ser deduzido, através do uso de um índice apropriado que deva refletir, o mais precisamente possível, o comportamento do sistema, do ponto de vista quantitativo e, principalmente qualitativo. É, portanto, um desafio propor um índice com tais características sobre os problemas associados à análise de segurança. Cada enfoque dado ao problema de análise de segurança (estático ou dinâmico, critérios de estabilidade de tensão ou de ângulo, etc.) requer um índice específico. Não há, por conseguinte, disponibilidade de um índice geral para todos dos casos a serem analisados.

Assim sendo, o objetivo desta pesquisa é, portanto, o desenvolvimento de uma metodologia de análise dinâmica de contingências por redes neurais, no contexto da família ART. Será proposto, também, um modelo do sistema baseado nos resultados apresentados na referência [64], em que são adotados como dados de entrada da rede neural os vetores de potências ativa e reativa nodais e um vetor constituído pelas informações das contingências, assim como referentes à configuração da rede elétrica, considerando-se qualquer que seja o problema a ser abordado, ou pelo menos para a grande maioria dos problemas de análise de segurança. O que muda em cada problema é a escolha

de um índice de segurança, em particular, que compõe a saída da rede neural, ou seja, os estímulos de saída do sistema neural na fase de treinamento. A idealização final deste sistema neural para análise de segurança é completada através do uso de um esquema para a elaboração do perfil de geração e de carga do sistema por um procedimento aleatório [64] que, a princípio, cobre todo o espectro de variação da demanda em um certo período de tempo considerado (por exemplo, o consumo diário). Evita-se, deste modo, a geração exaustiva de rotinas de previsão de carga e, por consequência, a determinação de despachos de geração que, via de regra, é realizada via despachos econômicos.

As redes neurais ART são arquiteturas cujos fundamentos estão baseados na teoria da ressonância adaptativa [16]. Então, a partir de uma configuração básica, várias outras concepções podem ser derivadas, por inclusão de mecanismos com vistas a melhorar o desempenho da rede, tanto em precisão quanto em rapidez. Estas várias concepções com treinamentos não-supervisionado e/ou supervisionado constituem, coletivamente, a chamada família ART.

Deve-se observar que o funcionamento das redes neurais é constituído por duas fases fundamentais: treinamento e testes. A fase de treinamento requer uma grande quantidade de processamento para a sua realização, enquanto que a fase de testes é efetivada, praticamente, sem esforço computacional. Esta é, portanto, a principal justificativa para o uso de redes neurais para a resolução de problemas complexos que exigem soluções rápidas, como é caso de aplicações em tempo real. As redes neurais, portanto, são dotadas de capacidade para realizar complexos mapeamentos não-lineares.

A nova arquitetura proposta é constituída por três módulos ART (um módulo ART e um módulo ARTMAP), sendo designada rede neural ART&ARTMAP nebulosa. A rede neural ARTMAP [13] é uma arquitetura neural baseada no treinamento para mapeamentos multidimensionais (multientradas/multisaídas) sendo composta por dois módulos ART e um módulo Inter-ART. As redes neurais da família ART possuem as características de estabilidade (capacidade de aprender por ajuste de pesos por um processo dinâmico convergente) e de plasticidade (capacidade de aprender continuamente, incluindo o “armazenamento” de novos padrões sem destruir o conhecimento adquirido no passado). As redes neurais ARTMAP, assim como as redes ART, são capazes de incluir inovações que podem produzir melhores resultados. O módulo ART é usado para classificar os vetores de entrada (dados analógicos), correspondentes as potências ativa e reativa nodais, em diferentes categorias e convertê-las em informações binárias  $\{P^{bin}, Q^{bin}\}$ , através de um

módulo de processamento código ativo/código binário. A entrada do módulo ARTMAP nebuloso é constituída pelo conjunto  $\{P^{bin}, Q^{bin}\}$  acrescido de informações binárias referentes às condições de falta e da topologia da rede elétrica. Assim, a rede neural ARTMAP recebe somente dados binários, o que representa uma situação favorável para aplicações em sistemas de grande porte, reduzindo assim o esforço computacional necessário para se realizar o treinamento, obtendo melhoria na qualidade das análises, em comparação às demais redes neurais.

Este conjunto de medidas tem proporcionado o desenvolvimento de um sistema neural para a análise de contingências de sistemas de energia elétrica de modo eficiente em termos de rapidez e precisão, que o habilita para aplicações em tempo real.

Assim sendo, as principais contribuições deste trabalho podem ser destacadas da seguinte forma:

- 1) desenvolvimento de uma metodologia de análise dinâmica de contingências por redes neurais. Trata-se de um modelo único que pode ser usado para a resolução de um grande número de problemas no contexto da análise de segurança: estabilidade de tensão, estabilidade de ângulo, etc. Este modelo está sendo proposto baseado no trabalho desenvolvido na referência [64], ou seja, são considerados dados de entrada da rede neural os vetores de potências ativas e reativas (dados analógicos) e o vetor contendo os dados referentes à falta, topologia, etc. (dados binários) e a saída sendo estabelecida como sendo um índice (margem de segurança, índice de confiabilidade, etc.);
- 2) proposta de uma nova arquitetura de rede neural baseada na teoria da ressonância adaptativa chamada rede neural ART&ARTMAP nebulosa. Esta rede neural está sendo proposta com o objetivo de tornar a resolução mais rápida e mais precisa, se comparada às demais arquiteturas da família ART e mais ainda se comparada a outras redes neurais mais importantes disponíveis na literatura especializada. Por exemplo, enquanto o treinamento (via retropropagação) de rede neural *feedforward* para a execução de determinada tarefa demanda algumas horas, a mesma tarefa é realizada usando uma rede neural ARTMAP em poucos segundos ([15]);
- 3) a rede neural proposta neste trabalho (rede neural ART&ARTMAP nebulosa) se apresenta como promissora, também, em outras aplicações, em destaque, na previsão de cargas elétricas multinodais (para aplicação principalmente em sistemas de

distribuição) [45], assunto este que está sendo abordado em outras pesquisas do grupo de trabalho.

Este texto está organizado em capítulos e apêndices, cujos conteúdos são assim descritos:

*Capítulo 2* : É apresentada a formulação do problema de análise de segurança de sistemas de energia elétrica.

*Capítulo 3* : São apresentados os principais conceitos sobre redes neurais artificiais.

*Capítulo 4* : É apresentada a rede neural ART.

*Capítulo 5* : É apresentada a rede neural ARTMAP.

*Capítulo 6* : É apresentada a formulação do problema da análise de segurança de sistemas de energia elétrica por redes neurais.

*Capítulo 7* : Apresenta-se a rede neural proposta. Trata-se da rede neural ART&ARTMAP que é derivada da família ART.

*Capítulo 8* : São apresentados os resultados da análise dinâmica de contingências de sistemas de energia elétrica obtidos com o emprego da rede neural ART&ARTMAP nebulosa. Trata-se da análise de estabilidade transitória, primeiramente considerando-se um sistema de 3 barras, depois considerando-se uma versão do sistema da região sul do Brasil, composta por 45 barras, 73 linhas de transmissão e 10 máquinas síncronas.

*Capítulo 9* : São apresentadas as principais conclusões e sugestões para trabalhos futuros.

*Referências* : Encontram-se relacionadas, em ordem alfabética, as referências bibliográficas.

*Apêndice A* : Contém os dados do sistema teste (versão do sistema elétrico de potência da região sul do Brasil).

*Apêndice B* : Contém os artigos publicados.

## CAPÍTULO 2

### ANÁLISE DE SEGURANÇA DE SISTEMAS DE ENERGIA ELÉTRICA

#### 2.1. INTRODUÇÃO

Neste capítulo apresentam-se os principais conceitos sobre a análise de segurança de sistemas de energia elétrica. Serão abordados os principais estados operativos do sistema e transições de estados promovidas mediante a atuação de ações de controle. Serão abordados os fenômenos associados à operação e os estudos que devem ser realizados (análise de estabilidade transitória, estabilidade de tensão, etc.). Este capítulo está sendo proposto com vista a situar e ilustrar os eventos mais importantes sobre a segurança do sistema e, especialmente, preparar uma série de resultados para serem usados (servir de referência) no desenvolvimento de um sistema neural para análise de segurança que será tratado nos capítulos subseqüentes.

#### 2.2. ANÁLISE ESTÁTICA X ANÁLISE DINÂMICA

A análise de segurança consiste de um conjunto de procedimentos usados na operação e planejamento de sistemas elétricos de potência com o objetivo de inferir os efeitos provocados por faltas (defeitos), manobras, etc., enfim toda e qualquer perturbação que modifique o ponto de equilíbrio do sistema. Neste sentido, apresentam-se as seguintes definições:

*Definição 1.* **Perturbação (ou distúrbio).** Define-se perturbação como sendo qualquer ação que venha provocar a alteração do estado de equilíbrio do sistema de energia elétrica:

- variação da carga;
- saída ou entrada em operação de equipamentos elétricos (linhas de transmissão, geradores, etc.);
- descargas atmosféricas;
- defeitos por ação da natureza (neve, vento, etc.);
- ação do homem (voluntária ou involuntária);
- etc.

*Definição 2.* **Contingências.** Definem-se contingências como ocorrências que levam às perturbações:

- saída forçada de operação de equipamentos elétricos;
- curto-circuito causado por descargas atmosféricas, ação mecânica, etc.;
- etc.

Os defeitos encontram-se sempre presentes na rotina dos sistemas elétricos. Por mais que se desenvolva formas de evitá-los, dificilmente serão eliminados. Cabe, então, desenvolver técnicas para análise dos impactos de tais defeitos (análise de segurança) e, na medida do possível, propor formas eficientes para reduzir, ou pelo menos, atenuar ou seus efeitos (controle de segurança). Há vários pontos importantes sobre a operação dos sistemas que devem ser considerados na análise, tais como: os limites dos equipamentos elétricos (aquecimento, etc.), confiabilidade, entre outros. Contudo, a maior preocupação deve ser dada às unidades geradoras, tendo em vista a necessidade das máquinas síncronas em manter o sincronismo. Neste contexto, grande parte dos riscos do não atendimento da demanda está associada às máquinas síncronas frente à ocorrência de contingências. Tais eventos provocam oscilações, principalmente nos ângulos das máquinas que, dependendo de suas magnitudes podem ocasionar a perda de estabilidade do sistema (uma ou mais máquinas síncronas perdem o sincronismo) que, quase sempre evolui para um *blackout*.

Segurança em sistema de potência, em geral, pode ser definida, então, como sendo a medida de robustez do sistema a operar em um estado de equilíbrio sobre

condições normais e sob perturbação. Estabilidade de sistema de potência pode ser definida, de forma genérica, como sendo a propriedade de um sistema de potência que o capacita a manter um estado de equilíbrio estável sobre condição de operação normal e se manter neste estado estável, ou em outro estado estável (atingir um novo estado de equilíbrio aceitável, sem perda de integridade física do sistema) após sofrer uma perturbação [42]. Estabilidade de sistema de potência é um problema muito complexo, ou seja, depende de uma variedade de parâmetros como o tempo de duração do distúrbio e da eliminação da falta, o tamanho do distúrbio considerado e a natureza física da instabilidade resultante. Em relação à magnitude da perturbação, pode-se considerar a estabilidade de pequenas oscilações e de grande oscilações, envolvendo tensões, ângulos e frequência [53], [54]. A Figura 1 ilustra os principais estudos que envolvem o conceito de estabilidade [78].

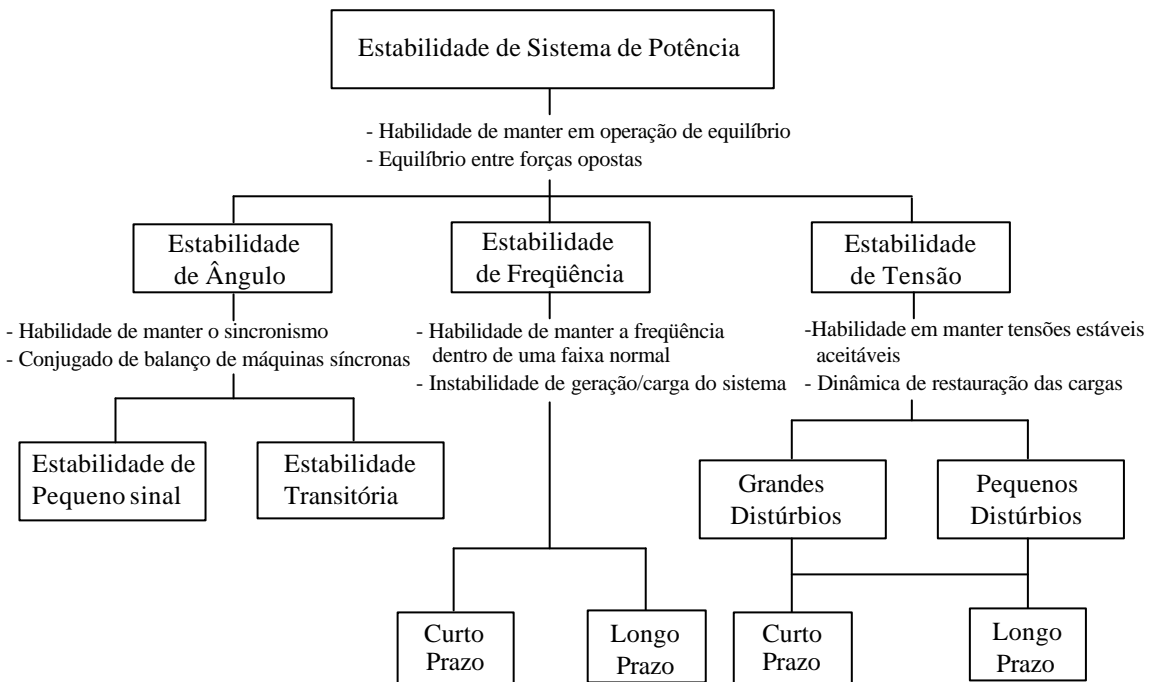


Figura 1. Tipos de fenômenos de estabilidade em sistemas elétricos de potência.

Vários problemas de segurança distinguem-se de acordo com a característica do “sintoma” (baixa tensão, grande desvio angular), e os principais controles (potência reativa, chaveamento) para aliviar (moderar) o problema, a escala de tempo da dinâmica, além da amplitude do distúrbio. Por exemplo, em estabilidade transitória, o desempenho dinâmico está em termos de segundos e, principalmente, é afetado por operações de chaveamento e controles rápidos de potência (por exemplo, controle rápido, conversores de



corrente diretos de alta tensão, FACTS) e suporte de tensão pelos reguladores automáticos de tensão de geradores síncronos e compensadores var estáticos (SVCs). Em estabilidade de tensão, os fenômenos mais rápidos são caracterizados por súbitos colapsos de tensão desenvolvidos em velocidades ainda maiores que a perda de sincronismo. Mais clássica é a instabilidade de tensão de médio prazo, a qual corresponde a um tempo típico de ajuste de um a cinco minutos. Neste caso, o colapso de tensão é principalmente direcionado para o transformador com mudança automática de *taps* para restaurar as tensões próximas à carga. Existe uma terceira estrutura de tempo ainda lenta, correspondente a chamada estabilidade de tensão de longo prazo, a qual envolve o crescimento gradual na demanda da carga. Esta interage com segurança estática clássica e está bem dentro do alvo da intervenção do operador.

Geralmente, a perda do sincronismo se desenvolve em poucos segundos após o início do distúrbio; atualmente, entre os fenômenos considerados na Figura 1, estabilidade transitória é o mais rápido a se desenvolver.

A característica não-linear da estabilidade transitória, sua rápida evolução e suas implicações práticas desastrosas a tornam uma das mais importantes e ao mesmo tempo mais problemática no assunto de avaliação e mais ainda para controle.

### **2.3. ESTADOS DE OPERAÇÃO DOS SISTEMAS DE ENERGIA ELÉTRICA**

A análise de segurança, portanto, é a responsável pela realização dos estudos destacados na Figura 1. Estes estudos abrangem a maioria dos problemas associados ao funcionamento dos sistemas de energia elétrica. A grande parte das metodologias destinadas à análise de segurança disponíveis na literatura especializada fazem suas inferências baseadas em índices que medem a severidade dos efeitos impostos ao sistema em consequência da ocorrência de defeitos. Visando estabelecer formas para interpretar tais efeitos, Dy Lyacco [78] propôs a divisão do funcionamento de sistemas elétricos de potência descritos por cinco estados operativos:

- 1) normal;
- 2) de alerta;
- 3) de emergência;
- 4) *in extremis*;

## 5) restaurativo.

Todos estes estados são caracterizados pelo atendimento ou não das equações das restrições de igualdades (equações algébricas e diferenciais) e das restrições de desigualdades que descrevem o funcionamento do sistema. As restrições de igualdades representam as leis físicas que regem a operação (por exemplo: balanço de potência), enquanto que as restrições de desigualdades estão associadas às violações operativas e de segurança. O balanço de potência corresponde em observar que a geração total deve suprir a carga total mais as perdas elétricas associadas aos vários equipamentos da rede elétrica. As inequações (ou restrições de desigualdades) representam os limites físicos dos equipamentos elétricos, por exemplo, os limites de correntes, de potências elétricas que trafegam nos sistemas de transmissão e de distribuição, das tensões nodais, entre outros. Em resumo, estes estados são evidenciados através da observação do cumprimento ou não das equações e inequações que governam os sistemas elétricos. As transições de estados são estabelecidas em função da aplicação de ações corretivas que são o redespacho de geração, corte de carga, chaveamento de equipamentos elétricos, reajuste do perfil de tensão nodal, uso de mecanismos compensadores (FACTS, etc.) entre outros. Como ilustração, tomando-se o caso em que uma determinada linha esteja com seu limite violado (excesso de corrente e/ou diferença angular expressiva), pode-se resolver este problema, a princípio, através de um redespacho de geração. É evidente que este processo deve ser realizado com critério e com o uso de técnicas apropriadas (via otimização, por exemplo).

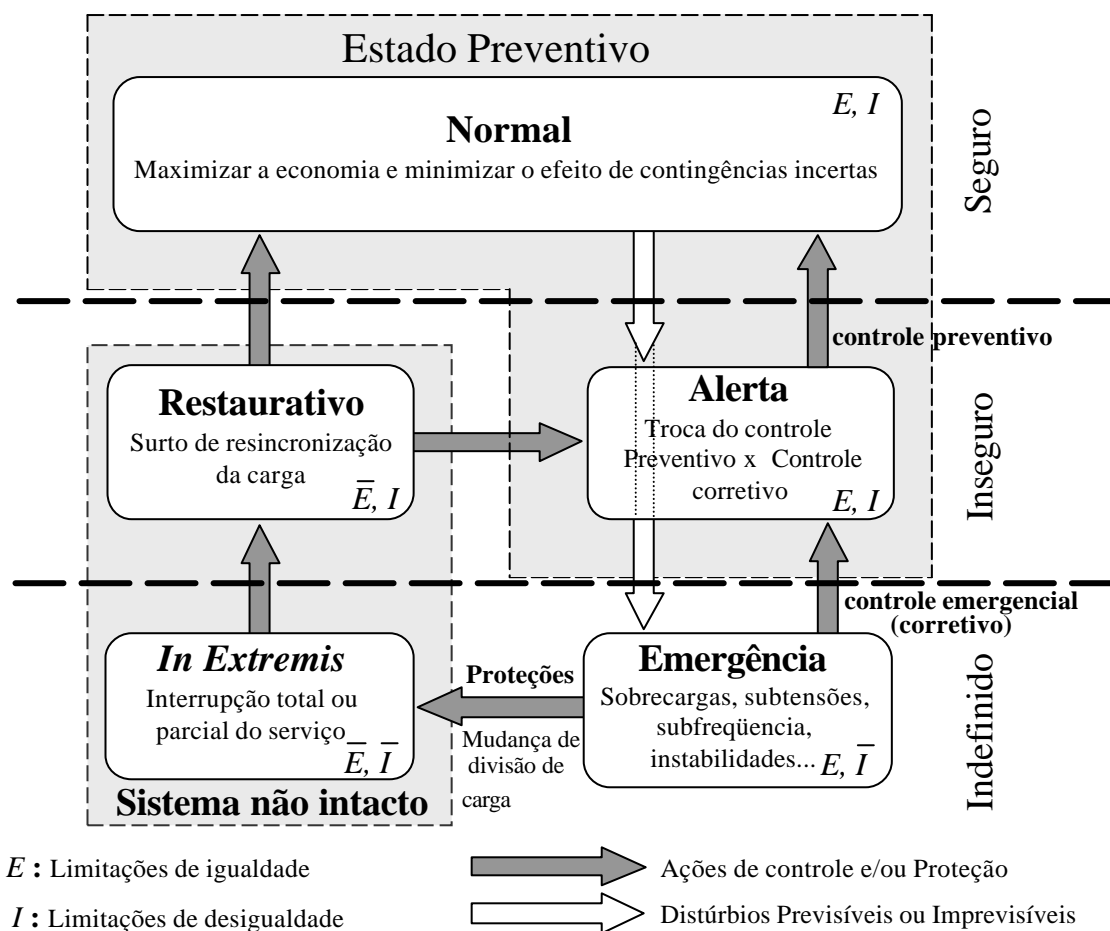


Figura 2. Estados de operação dos sistemas de energia elétrica e suas transições.

Na Figura 2, apresenta-se um esquema mostrando os vários estados operativos e suas transições [78]. Estes estados são caracterizados pelas seguintes condições operativas, de acordo com as seguintes convenções [78]:

$E$  = atendimento das restrições de igualdade;

$I$  = atendimento das restrições de desigualdade;

$\bar{E}$  = não atendimento das restrições de igualdade;

$\bar{I}$  = não atendimento das restrições de desigualdade.

Baseadas nesta convenção, apresenta-se, a seguir, uma breve descrição destes estados e, na seqüência, são mostradas as suas transições [78].

**Estado Normal** : Caracteriza-se como uma condição operativa em que todas as variáveis do sistema estão dentro de uma faixa normal de operação e nenhum equipamento encontra-se sobrecarregado, ou seja, o sistema está intacto, com suprimento total de demanda e nenhuma violação dos limites de operação. Neste estado, há margem de reserva de capacidade associada à transmissão, geração, etc. suficiente para proporcionar um nível adequado de segurança, mesmo havendo ocorrência das contingências ou perturbações (aumento de carga, curto-circuito, perda de equipamento, entrada/saída de carga, etc.) que frequentemente são impostas ao sistema.

**Estado de Alerta** : Neste estado, todas as restrições operativas encontram-se satisfeitas, porém, há riscos de não ser atendidas, caso venham ocorrer contingências no sistema. Este estado é considerado inseguro, portanto, ações preventivas devem ser tomadas visando a retomada do estado normal.

**Estado de Emergência** : O sistema entra no estado de emergência se um distúrbio severo ocorre quando o sistema está no estado de alerta. Este estado é caracterizado pela violação das restrições de operação, as tensões nas barras estão baixas e/ou as cargas nos equipamentos excederam o limite de emergência de curto prazo. O sistema ainda está intacto e pode ser restaurado para o estado de alerta pelo início de ações do controle de emergência como: eliminação da falta, controle de excitação, etc. Se estas medidas não são aplicadas ou não são efetivas, o sistema entra no modo *in extremis*.

O objetivo da detecção do estado emergencial é avaliar se o sistema está em processo de perda de integridade, seguindo o princípio do distúrbio atual. Esta é uma evolução mais determinística, onde a resposta no tempo é crítica enquanto considerações econômicas tornam-se temporariamente secundárias. Controle de emergência consiste em tomar ações rápidas como último recurso, para evitar interrupção parcial ou completa no serviço. Quando ambos controles preventivo (tentativa de mudança do estado de alerta para o estado normal) e emergencial (tentativa de mudança do estado de emergência para o

estado de alerta) não são aplicados ou não são efetivos, dispositivos de proteção local automáticos atuarão de forma a preservar de danos irreversíveis os componentes do sistema de potência por operação em condições inaceitáveis. Este procedimento acarreta distúrbios futuros e o resultado é a interrupção em cascata e a possibilidade de paralisações como divisão do sistema e *blackout* parcial ou completo.

**Estado *In Extremis*** : Neste estado, as equações e as inequações são violadas. O sistema não pode permanecer por muito tempo nesta condição, pois, assim, uma parte do sistema quase sempre será perdida. A ação de controle de emergência deve ser diretamente introduzida para salvar o sistema que se encontra em operação e evitar o colapso total da rede elétrica.

**Estado Restaurativo** : Depois que o colapso tenha sido contido, o sistema pode evoluir para o estado restaurativo. Neste estado, o sistema pode transitar entre os estados de alerta e normal, dependendo das circunstâncias envolvidas. Constitui-se na ação em que são conectados novamente os componentes que se encontram fora de serviço (linhas de transmissão, geradores, transformadores, etc.) e o restabelecimento das cargas desligadas.

O estado restaurativo representa a condição na qual ações de controle são efetuadas para reconectar as instalações e restaurar a carga do sistema. Ele é atingido quando uma emergência é eliminada por desligamento manual ou automático de partes do sistema, efetuado pelo centro de controle ou por dispositivos locais. As restrições operacionais são obedecidas, mas o sistema não está intacto (cargas não atendidas, ilhamentos, etc). Na opção de se passar do estado de emergência para o estado restaurativo, sacrifica-se a integridade do sistema (inclusive com o desligamento de cargas) em benefício da observância das restrições de operação. Neste estado, a tarefa é minimizar a quantidade de energia não entregue pela perda de geração tão logo que possível e escolher as cargas a serem desconectadas em ordem de prioridade. O sistema transita deste estado para o estado de alerta ou para o estado normal, dependendo das condições do sistema.

O conceito de segurança utilizado neste capítulo, refere-se à operação, tanto do ponto de vista estática como dinâmica. No caso estático, ou de pequenas oscilações, os modelos são lineares e podem ser resolvidos usando uma série de técnicas disponíveis na literatura, *e.g.*, álgebra matricial, método de perturbação, análise de sensibilidade, análise modal, entre outras. Quando se trata da análise do sistema frente às grandes perturbações (saída de equipamentos de operação, curto-circuito, etc.), os modelos são não-lineares compostos por equações algébricas, diferenciais e, em alguns casos, também, envolvendo equações diferenciais parciais (caso de transitórios eletromagnéticos).

O fenômeno de estabilidade dos sistemas elétricos de potência abrange, basicamente, três módulos [78]: estabilidade dos ângulos das máquinas síncronas, estabilidade de frequência e estabilidade de tensão. Estas três divisões são significativamente importantes por se tratar da análise comportamental do sistema quando sujeitos às grandes perturbações que, potencialmente, podem conduzir o sistema à instabilidade. Esta instabilidade, principalmente quando envolvem os ângulos das máquinas, pode provocar o colapso parcial ou total do sistema, como discutido anteriormente.

As abordagens introduzidas neste capítulo têm como finalidade dar uma visão geral do funcionamento de um sistema elétrico de potência, e com isso direcionar o estado do sistema no qual a pesquisa proposta estará contribuindo.

## **2.4. CONCLUSÃO**

Neste capítulo foram apresentados os principais conceitos sobre a análise de segurança de sistemas de energia elétrica. Foram abordados, também, os principais estados de operação do sistema e suas transições, promovidas pela atuação de ações de controle. Foram mostrados também os fenômenos associados à operação e os estudos que devem ser realizados, como por exemplo, análise de estabilidade transitória, estabilidade de tensão, etc.

## **CAPÍTULO 3**

### **REDES NEURAIIS ARTIFICIAIS**

#### **3.1. INTRODUÇÃO**

Neste capítulo são apresentados os principais conceitos sobre Redes Neurais Artificiais (RNA). São apresentados, também, um breve histórico, as principais características e arquiteturas e, ainda, as formas de treinamento de redes neurais. Trata-se de uma exposição de concepções visando fornecer subsídio à compreensão da metodologia proposta, a ser apresentada nos próximos capítulos, a qual refere-se à análise de segurança de sistemas elétricos de potência por redes neurais baseadas na teoria da ressonância adaptativa [11]–[16].

#### **3.2. HISTÓRICO**

Redes Neurais Artificiais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência [31], [33], [36], [67], [71], [78]. São definidas como sendo um sistema de processamento de informações constituído por um grande número de elementos processadores únicos (neurônios) amplamente interconectados em uma arquitetura inspirada na estrutura da porção córtex cerebral [72]. Com o passar do tempo, a evolução tem dado ao cérebro humano características desejáveis como paralelismo massivo, representação e cálculos distribuídos, habilidade em aprender e generalizar, adaptabilidade, tolerância a falhas e baixo consumo de energia [26]. A utilização da computação neural é recente. Ela atua em problemas nos quais aproximações computacionais convencionais são comprovadamente ineficazes [30], por exemplo,

reconhecimento de padrões contendo dados incompletos ou ruído, etc. A rede neural foi inspirada inicialmente pelo reconhecimento de que o cérebro humano efetua cálculos diferentemente de um computador digital convencional [8], [10]. Quem introduziu a idéia de neurônios como constituintes estruturais do cérebro foi Ramón e Cajál em 1911 [36], [76]. O cérebro é altamente complexo, não-linear e efetua cálculos de modo paralelo. Ele possui a capacidade de organizar os neurônios de forma que realizem certos cálculos muitas vezes mais rápidos do que o mais rápido computador digital existente hoje [31]. Um histórico resumido sobre Redes Neurais Artificiais deve começar por três das mais importantes publicações iniciais, desenvolvidas por McCulloch e Pitts (1943) [36], [76], Hebb (1949) [36], [76], e Roseblatt (1958) [36], [76]. Estas publicações introduziram o primeiro modelo de redes neurais simulando “máquinas”, o modelo básico de rede de auto-organização, e o modelo Perceptron de aprendizado supervisionado, respectivamente [71]. Aproximações convencionais têm sido propostas para resolver uma variedade de problemas tais como reconhecimento de padrões, diagnóstico, otimização, memória associativa, controle entre outros. As redes neurais proporcionam alternativas instigantes, e muitas aplicações podem beneficiar-se do uso delas [33].

### **3.3. CARACTERÍSTICAS GERAIS**

A rede neural pode ser definida como sendo um sistema de comunicação adaptivo que utiliza uma “função custo” para representar a saída desejada. Pode ser caracterizada, matematicamente, como um sistema dinâmico que pode ser modulado como um grupo de equações diferenciais interconectadas. As redes neurais são caracterizadas pelo cálculo coletivo e cooperativo e pela sua robustez, ou seja, sua operação é insensível a entradas parciais, imperfeitas ou incompletas.

A maneira na qual os neurônios de uma rede neural são estruturados está intimamente ligada ao algoritmo de aprendizado para treiná-la. A rede neural é dividida em camadas como pode ser visto pela Figura 3. Essas camadas são classificadas em três tipos: (1) camada de entrada, (2) camada(s) intermediária(s) e (3) camada de saída, sendo que cada camada possui uma função. A camada de entrada faz a apresentação dos padrões para a rede. A(s) camada(s) intermediária(s) ou camada(s) escondida(s) faz(em) a interação entre a camada de entrada e a camada de saída. Ela é responsável pelo processamento das



informações. E por último, a camada de saída realiza a apresentação do resultado final do processamento da rede.




Figura 3. Representação da rede neural em camadas.

### 3.4. MODELO BIOLÓGICO DE UM NEURÔNIO

O neurônio é a unidade celular fundamental do sistema nervoso, particularmente o cérebro [36]. É uma unidade de processamento simples (soma ou corpo celular) que recebe e combina sinais de outros neurônios através dos caminhos de entrada chamados de dendritos. A conexão entre um axônio de um neurônio e um dendrito (ou axônio) de um outro neurônio é chamado de sinapse (Figura 4). Se o sinal combinado de todos os dendritos pelo neurônio é grande o bastante, ou seja, ultrapassa um certo limiar, o neurônio dispara um sinal de saída ao longo de um caminho chamado axônio (linha de transmissão) transmitindo, deste modo, a informação para outro neurônio, e assim sucessivamente.

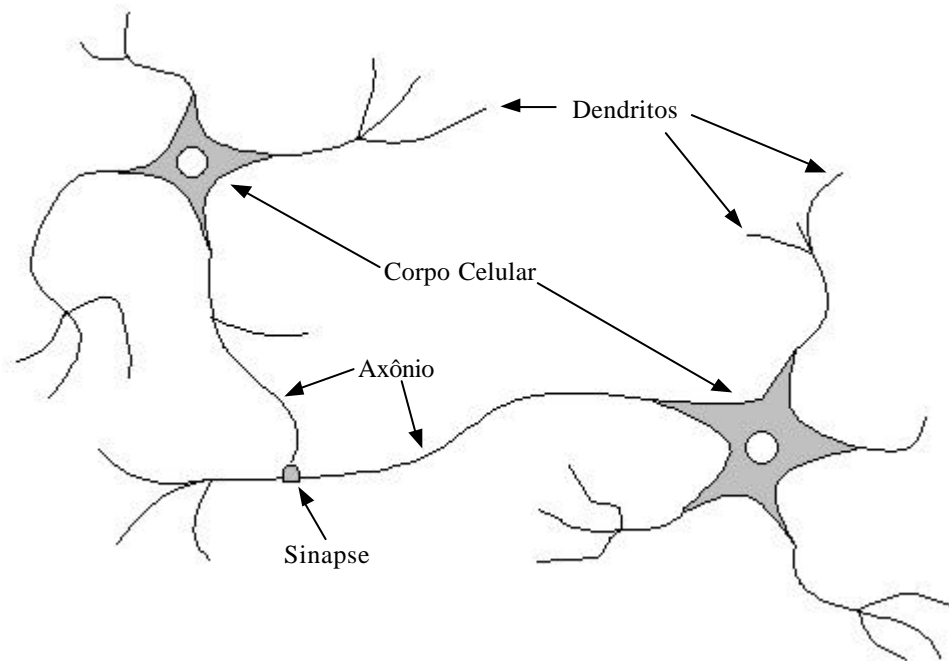


Figura 4. Representação de um modelo biológico de um neurônio.

### 3.5. MODELO DO NEURÔNIO ARTIFICIAL

McCulloch e Pitts [36] propuseram uma unidade binária contendo *threshold* (disparo) como um modelo computacional para um neurônio, como mostrado na Figura 5.

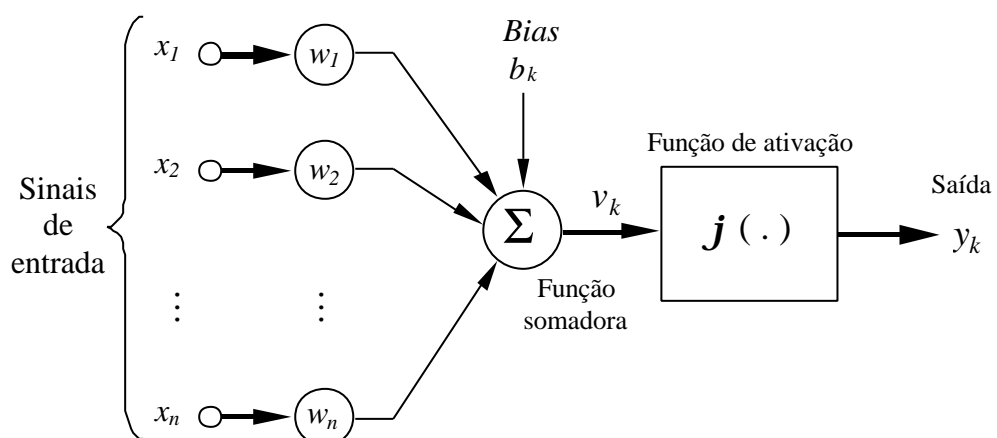


Figura 5. Representação do neurônio de McCulloch-Pitts.

Seus elementos são constituídos basicamente por uma série de pesos sinápticos, um adicionador ou função somadora que junta os sinais de entrada e uma função de ativação que dá a formatação e limita a amplitude do sinal de saída de um neurônio. Nele, também está presente uma entrada *bias* aplicada externamente denotada por  $b_k$ . O *bias* tem o efeito de aumentar, se positivo, ou diminuir, se negativo, a entrada da rede da função de ativação. Os tipos básicos de funções de ativação são: (a) função de ativação *threshold*, (b) função de ativação linear por partes e (c) função de ativação sigmoidal. Estas funções de ativação, que são as principais funções disponíveis na literatura especializada, são mostradas nas Figuras 6, 7 e 8.

a) Função de ativação *threshold* 
$$j(v) = \begin{cases} 1, & \text{para } v \geq 0 \\ 0, & \text{para } v < 0 \end{cases}$$




Figura 6. A função de ativação *Threshold*.

b) Função de ativação linear por partes 
$$j(v) = \begin{cases} 1, & \text{para } v \geq 1/2 \\ v, & \text{para } 1/2 > v > -1/2 \\ 0, & \text{para } v \leq -1/2 \end{cases}$$




Figura 7. A Função de ativação linear por partes.

c) Função de ativação sigmoidal:  $\mathbf{j}(v) = \frac{1}{1 + e^{-\lambda v}}$




Figura 8. A Função de ativação Sigmoidal.

sendo:

$\mathbf{l}$  = inclinação da curva sigmoidal.

Este neurônio artificial (modelo matemático) calcula a soma ponderada de seus  $n$  sinais de entrada,  $x_j, j = 1, 2, 3, \dots, n$  e gera uma saída assim definida [80]:

$$y_k = \mathbf{j} \left[ \sum_{j=1}^n x_j w_j + b_k \right] \quad (3.5.1)$$

sendo:

$\mathbf{j}(\cdot)$  = função de ativação escolhida;

$b_k$  = bias.

A Tabela 1 mostra a analogia entre Neurônio Biológico e Neurônio Artificial:

Tabela 1. Analogia entre Neurônio Biológico e Neurônio Artificial.

<b>Neurônio Biológico</b>	<b>Neurônio Artificial</b>
Sinapse	Conexão de pesos
Axônio	Canal de saída
Dendritos	Canal de entrada
Soma (derivada da palavra <i>sôma</i> do grego que significa corpo celular)	Função de ativação

Uma rede neural é, portanto, um arranjo complexo de vários neurônios interligados e dispostos em camadas.

### 3.6. TREINAMENTO

O treinamento de uma rede neural pode ser definido como sendo um processo no qual a rede se adapta a um estímulo para a realização da saída desejada [36]. Treinamento também pode ser definido como um processo contínuo de classificação/organização de um estímulo de entrada. Quando um estímulo é introduzido na rede, através da camada de entrada, ela se reorganiza ou se desenvolve para uma nova classificação. Durante o processo de treinamento, a rede ajusta seus parâmetros sinápticos em resposta a um estímulo de entrada tal que ela converge, ou seja, a resposta de saída aproxima-se da resposta de saída desejada. Quando a resposta de saída atual é a mesma da desejada, diz-se que a rede completou sua fase de treinamento, ou pode-se dizer que ela adquiriu conhecimento. De outra forma, pode-se dizer que treinamento é o processo no qual os parâmetros livres de uma rede neural são adaptados através de estimulações do ambiente no qual a rede está inserida [8]. O processo de treinamento pode ser entendido como um problema de atualização da arquitetura da rede e conexão de pesos tal que ela

possa realizar eficientemente uma tarefa específica [33]. O tipo de treinamento é determinado pela maneira que ocorrem mudanças em seus parâmetros. A rede neural aprende através de seu ambiente por um processo iterativo de ajustamento aplicado a seus pesos sinápticos e nível *bias*.

O treinamento pode ser dividido em três modelos principais: (1) treinamento supervisionado, (2) treinamento não-supervisionado e (3) treinamento híbrido [33], cujas definições são estabelecidas na seqüência.

*Definição 3. Treinamento Supervisionado*, ou treinamento com um “professor”, a rede é provida (munida) de uma resposta (saída) correta para cada padrão de entrada. Os pesos são ajustados para permitir a reprodução das respostas tão próximas possíveis às respostas corretas conhecidas.

*Definição 4. Treinamento Não-supervisionado*, ou treinamento sem um professor, não requer uma resposta correta associada a cada padrão de entrada na série dos dados de treinamento. Ele emprega a estrutura suporte (fundamental) no dado, ou correlação entre padrões nos dados e organiza padrões dentro de categorias dessas correlações.

*Definição 5. Treinamento Híbrido*. Combina treinamento supervisionado e treinamento não supervisionado. Parte dos pesos são ajustados através do treinamento supervisionado, enquanto outros são obtidos através de treinamento não-supervisionado.

Dentro do contexto das definições anteriormente apresentadas, há outras formas de treinamento mais específicas (uso de técnicas ou procedimentos particulares), entre as quais destacam-se os treinamentos: por reforço; competitivo; regra delta; gradiente descendente e Hebbiano.

No **Treinamento por Reforço** (supervisionado), um estímulo de entrada é aplicado e uma resposta de saída é obtida. O “professor” não apresenta a saída desejada à rede, apresenta sim uma representação binária, se a resposta desejada foi alcançada ou não. Se a indicação é negativa, a rede reajusta seus parâmetros e é feita a tentativa novamente. Esse processo continua até alcançar a resposta de saída desejada. Durante esse processo

não há indicação se a resposta está divergindo ou convergindo da meta desejada. No uso desta técnica de treinamento, certos limites devem ser estabelecidos para que o processo não se mantenha indefinidamente.

O **Treinamento Competitivo** é uma outra forma de treinamento não-supervisionado, distinguindo-se pela sua operação característica e arquitetura. Nesta estrutura vários neurônios estão na camada de saída. Quando um estímulo de entrada é aplicado, cada neurônio de saída compete com os outros para produzir o sinal de saída próximo do alvo. A saída vencedora, então, torna-se dominante sobre as demais e as outras saídas param de produzir um sinal de saída para aquele estímulo. Para outros estímulos outro neurônio torna-se dominante e assim por diante.

A **Regra Delta** é baseada na idéia de ajustamento contínuo dos valores dos pesos tal que a diferença do erro (delta) entre o valor de saída desejada e o valor de saída atual de um elemento de processamento é reduzida. Ela também é conhecida como regra de treinamento *Widrow-Hoff* ou mínimos quadrados [80].

Na **Regra do Gradiente Descendente** os valores dos pesos são ajustados por uma quantidade proporcional à primeira derivada (o gradiente) do erro, entre o valor da saída desejada e o valor da saída atual de um elemento de processamento, com respeito ao valor do peso [79]. A meta é decrescer a função erro, evitando um mínimo local e alcançando o atual ou um mínimo global (Figura 9).

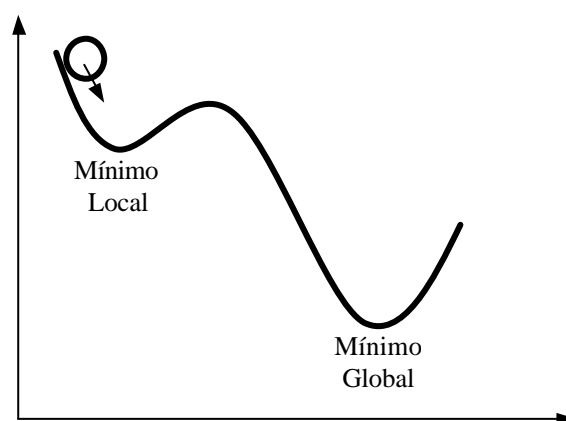


Figura 9. Descida para um ponto mínimo global.

No **Treinamento hebbiano** [36], quando um axônio de uma célula A está muito perto de excitar uma célula B, a resistência sináptica entre a célula A e a célula B é modificada de acordo com o grau de correlação entre entrada e saída.

### 3.7. PRINCIPAIS REDES NEURAIS

Existem basicamente dois tipos de redes neurais, a rede neural não-recorrente (Figura 10) e a rede neural recorrente (Figura 11). A rede neural recorrente distingue-se da rede neural não-recorrente por possuir pelo menos um laço de realimentação.




Figura 10. Rede neural não-recorrente.




Figura 11. Rede neural recorrente.



A presença de laços de realimentação tem um profundo impacto na capacidade de treinamento da rede neural e em seu desempenho. Além disso, os laços de realimentação envolvem o uso de ramos particulares compostos de elementos de unidade de atraso que resultam em um comportamento dinâmico não-linear. As principais redes neurais não-recorrentes são: *perceptron* [80], redes neurais da família ART (ART, ARTMAP, etc.) [16] e a rede de Kohonen [76], enquanto que as redes neurais recorrentes mais relevantes encontram-se as redes de Hopfield [67]. Na rede *perceptron*, em alguns casos, usa-se realimentar a entrada (com retardo) para realizar, por exemplo, previsão de séries temporais.

### **3.8. CONCLUSÃO**

Neste capítulo foram abordados os principais conceitos e um breve histórico sobre Redes Neurais Artificiais. Foram apresentadas, também, as principais características e principais arquiteturas, assim como as formas de treinamento de redes neurais.

## CAPÍTULO 4

### REDE NEURAL ART

#### 4.1. INTRODUÇÃO

Neste capítulo será apresentada a rede neural ART (*Adaptive Resonance Theory*) [13]. Esta rede neural foi proposta inicialmente por Stephen Grossberg, em 1976, e, em publicações posteriores, em parceria com Gail Carpenter (1986/87) [16]. Desde então a rede neural ART tem sido estabelecida como sendo uma das primeiras arquiteturas neurais para resolução de problemas de classificação de padrões [41]. A rede neural ART nebulosa constitui-se numa combinação do módulo ART (célula fundamental) e a lógica nebulosa [36], [48], [70]. É uma máquina de agrupamento (classificação) de padrões que é capaz de reunir coleções arbitrárias de padrões analógicos e/ou binários de entrada. Basicamente, a arquitetura é constituída por uma camada de reconhecimento de baixo para cima (*bottom-up*) e uma camada generativa de cima para baixo (*top-down*). Se o padrão de entrada e o padrão realimentado treinado se “casam” (existência de ressonância), um processo dinâmico chamado ressonância adaptiva é realizado. Um aspecto importante e muito atrativo das redes ART está relacionado ao dilema estabilidade e plasticidade que é apresentado a seguir.

#### 4.2. CARACTERÍSTICAS BÁSICAS DO SISTEMA ART

O sistema ART é um modelo não-supervisionado baseado no treinamento competitivo. Descobre categorias autonomamente e cria novas categorias quando necessário. Ele foi desenvolvido para resolver problemas de instabilidade de sistemas de realimentação, particularmente o dilema estabilidade/plasticidade. A estabilidade está relacionada com a garantia de agrupamento de todos os elementos nas classes criadas pelo

sistema, tendo em vista que os pesos da rede possuem a característica somente de decrescimento, ou seja, à medida que as adaptações dos pesos são realizadas, os novos valores tendem sempre a diminuir até a estabilização. A plasticidade é a característica que a rede possui de aprender um novo padrão, em qualquer tempo de sua operação, sem perder o aprendizado adquirido anteriormente. Na atividade de reconhecimento de padrões, quando uma certa entrada não se assemelha a nenhum dos grupos já existentes, um novo grupo é criado para a referida entrada. Essa característica pode, em alguns sistemas neurais, comprometer a estabilidade da rede, ou seja, quando uma nova aprendizagem ocorre, os padrões já treinados anteriormente são prejudicados podendo a rede perder a capacidade de reconhecer os padrões antigos. Nas redes ART esse problema é resolvido pelo mecanismo de vigilância que administra a inclusão de novas entradas em cada grupo. A arquitetura ART possui duas camadas principais: (1) a primeira é a camada de entrada (comparação) com  $N$  nós (neurônios) e; (2) a segunda é a camada de saída (reconhecimento) com  $M$  nós (Figura 12). Estas duas camadas se interagem. Além delas, existe uma camada intermediária que funciona como uma rede de filtragem adaptativa entre as camadas de entrada e de saída. Para cada camada existem sinais de controle visando manipular o fluxo de dados.

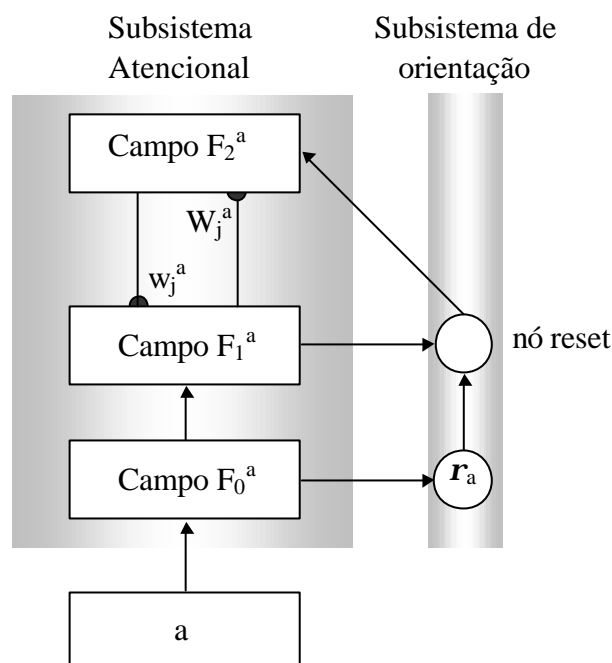


Figura 12. Representação do sistema ART.

No treinamento, um padrão é inserido na rede através da camada de entrada, codificado e passado para a camada de saída com as conexões de pesos da rede de filtragem adaptativa. Nela inicia-se a dinâmica do sistema com o treinamento competitivo.

### 4.3. ALGORITMO ART NEBULOSO

Cada sistema ART possui um campo,  $F_0$ , de nós (neurônios) que representa um vetor de entrada atual; um campo  $F_1$ , que recebe entradas de baixo para cima de  $F_0$  e entradas de cima para baixo do campo,  $F_2$ , representando o código ativo ou categoria ativa (Figura 12). Visando ilustrar estas atividades, apresenta-se a Figura 13 onde é destacado o neurônio vencedor (índice  $J$ ) e suas conexões com os componentes do vetor de entrada.

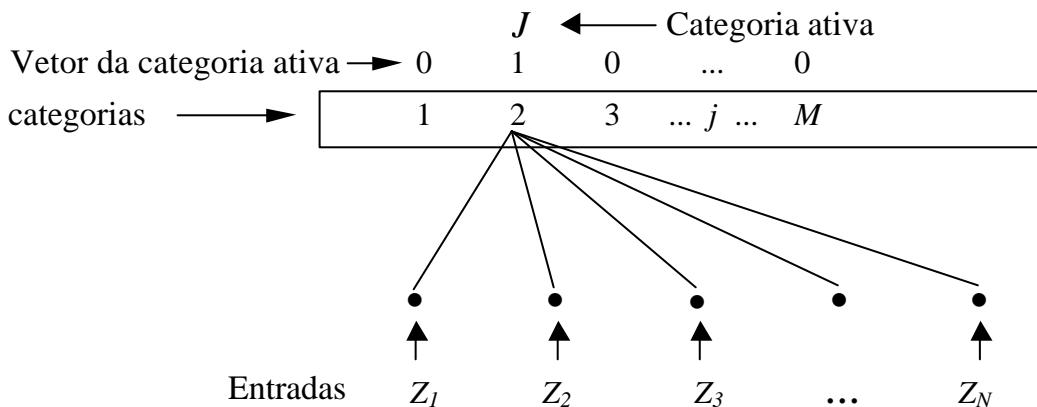


Figura 13. Conexão entre entrada e o vetor vencedor (designado com o índice  $J$ ).

O resumo do algoritmo ART nebuloso é dado a seguir [15]:

#### 4.3.1. Valores Iniciais dos Pesos

Os pesos no início do processo são adotados como sendo iguais a 1, ou seja:

$$w_{j1}(0) = \dots = w_{jm}(0) = 1. \quad (4.3.1.1)$$

Neste instante, diz-se que os nós estão descomprometidos (não se encontram ativados).

### 4.3.2. Iniciação dos Parâmetros da Rede

Os parâmetros da rede devem ser arbitrados como segue:

- parâmetro de escolha  $\mathbf{a}$  :  $\mathbf{a} > 0$ ;
- taxa de treinamento  $\mathbf{b}$  :  $\mathbf{b} \in [0,1]$ ;
- parâmetro de vigilância  $\mathbf{r}$  :  $\mathbf{r} \in [0,1]$ .

### 4.3.3. Normalização do Vetor de Entrada

Nesta etapa, é feita a normalização do vetor de entrada. Ela tem como função fazer com que a proliferação de categorias seja evitada. Esse processo é realizado como segue:

$$\mathbf{I} = \frac{\mathbf{a}}{|\mathbf{a}|}. \quad (4.3.3.1)$$

A norma é definida por:

$$|\mathbf{a}| = \sum_{i=1}^M |a_i| \quad (4.3.3.2)$$

sendo:

$M$  = dimensão do padrão de entrada.

### 4.3.4. Codificação do Complemento

É a regra que preserva a amplitude da informação dos vetores de entrada. O complemento do vetor de entrada é dado por:

$$a_i^c \equiv 1 - a_i ; \quad (4.3.4.1)$$

e o vetor de entrada se torna:

$$\mathbf{I} = [\mathbf{a} \ \mathbf{a}^c] \equiv [a_1 \dots a_M \ a_1^c \dots a_M^c]. \quad (4.3.4.2)$$

Note que:

$$\begin{aligned} |\mathbf{I}| &= |[\mathbf{a} \ \mathbf{a}^c]|; \\ &= \sum_{i=1}^M a_i + (M - \sum_{i=1}^M a_i); \\ &= M. \end{aligned} \quad (4.3.4.3)$$

#### 4.3.5. Escolha da Categoria

A função de escolha é calculada para cada entrada da seguinte forma:

$$T_j(\mathbf{I}) = \frac{|\mathbf{I} \wedge \mathbf{w}_j|}{\mathbf{a} + |\mathbf{w}_j|}. \quad (4.3.5.1)$$

sendo:

$\wedge$  = operador nebuloso *AND* definido por:

$$(\mathbf{p} \wedge \mathbf{q})_i \equiv \min(p_i, q_i); \quad (4.3.5.2)$$

Como a entrada  $\mathbf{I}$  é fixa, representada-se aqui, por simplicidade de notação,  $T_j(\mathbf{I})$  por  $T_j$ . A categoria escolhida é indexada pelo índice  $J$ , sendo:

$$T_J = \max \{ T_j : j = 1, \dots, N \}. \quad (4.3.5.3)$$

Se mais de uma categoria  $T_j$  apresenta valor máximo, então, escolhe-se a de menor índice. Quando a  $J$ -ésima categoria é escolhida como sendo o maior valor de menor índice,  $y_J = 1$  e  $y_j = 0$  para  $j \neq J$ , sendo  $\mathbf{y}$  o vetor atividade em  $F_2$ . No sistema de escolha, a atividade em  $F_1$ , vetor  $\mathbf{x}$ , segue a equação:

$$x = \begin{cases} \mathbf{I} & , \text{ se } F_2 \text{ está inativo;} \\ \mathbf{I} \wedge \mathbf{w}_J & , \text{ se o } J\text{-ésimo nó de } F_2 \text{ é escolhido.} \end{cases} \quad (4.3.5.4)$$

#### 4.3.6. Teste de Vigilância

A ressonância ocorre se a função *match*:

$$|\mathbf{I} \wedge \mathbf{w}_J| / |\mathbf{I}|; \quad (4.3.6.1)$$

da categoria escolhida satisfaz o critério de vigilância:

$$\frac{|\mathbf{I} \wedge \mathbf{w}_J|}{|\mathbf{I}|} \geq r; \quad (4.3.6.2)$$

ou seja, a partir da Equação (4.3.5.3), quando a  $J$ -ésima categoria é escolhida, a ressonância ocorre caso:

$$|x| = |\mathbf{I} \wedge \mathbf{w}_J| \geq r |\mathbf{I}|. \quad (4.3.6.3)$$

O *reset* (descarte da categoria escolhida corrente) ocorre caso a inequação:

$$\frac{|\mathbf{I} \wedge \mathbf{w}_J|}{|\mathbf{I}|} < r; \quad (6.3.6.4)$$

seja observada. Neste caso, a categoria escolhida e indexada por  $J$  é igualada a zero e o processamento é repetido (retorna-se ao item (4.3.5), para que seja então escolhida uma nova categoria).

Esse processo continua até que o teste de vigilância seja aceito.

#### 4.3.7. Treinamento

Após a finalização da pesquisa de índices, o vetor peso  $\mathbf{w}_J$  é atualizado de acordo com a Equação:

$$\mathbf{w}_J^{(novo)} = \mathbf{b} (\mathbf{I} \wedge \mathbf{w}_J^{(velho)}) + (1 - \mathbf{b}) \mathbf{w}_J^{(velho)}. \quad (4.3.7.1)$$

O treinamento rápido corresponde à adoção de  $\mathbf{b} = 1$ .

A Tabela 2 faz comparações entre as arquiteturas ART1 (dados binários) e o ART nebulosa (dados analógicos e binários).

Tabela 2. Comparações entre os processos ART1 e ART Nebuloso.

Processo	ART1	ART Nebuloso
Escolha da Categoria	$T_j(\mathbf{I}) = \frac{ \mathbf{I} \cap \mathbf{w}_j }{\alpha +  \mathbf{w}_j }$	$T_j(\mathbf{I}) = \frac{ \mathbf{I} \wedge \mathbf{w}_j }{\alpha +  \mathbf{w}_j }$
Critério <i>Match</i>	$\frac{ \mathbf{I} \cap \mathbf{w}_j }{ \mathbf{I} } \geq \rho$	$\frac{ \mathbf{I} \wedge \mathbf{w}_j }{ \mathbf{I} } \geq \rho$
Treinamento Lento	$\mathbf{w}_J^{(novo)} = \mathbf{b} (\mathbf{I} \cap \mathbf{w}_J^{(velho)}) + (1 - \mathbf{b}) \mathbf{w}_J^{(velho)}$	$\mathbf{w}_J^{(novo)} = \mathbf{b} (\mathbf{I} \wedge \mathbf{w}_J^{(velho)}) + (1 - \mathbf{b}) \mathbf{w}_J^{(velho)}$
Treinamento Rápido	$\mathbf{w}_J^{(novo)} = \mathbf{I} \cap \mathbf{w}_J^{(velho)}$	$\mathbf{w}_J^{(novo)} = \mathbf{I} \wedge \mathbf{w}_J^{(velho)}$

sendo:

$\cap$  = operador interseção.

#### 4.4. Representação Geométrica do Algoritmo ART Nebuloso

Nesta seção é detalhada a representação geométrica do algoritmo ART Nebuloso. Por facilidade, trabalha-se com uma série de entradas  $\mathbf{I}$  de dimensão dois. Utilizando a forma de codificação do complemento, a série de entrada torna-se:

$$\begin{aligned} \mathbf{I} &= [\mathbf{a} \ \mathbf{a}^c]; \\ &= [a_1 \ a_2 \ 1-a_1 \ 1-a_2]. \end{aligned} \quad (4.4.1)$$



Da mesma forma, o vetor peso  $w$  é definido da seguinte maneira:

$$w_j = [u_j \ u_j^c]; \quad (4.4.2)$$

sendo  $u_j$  e  $u_j^c$  vetores bi-dimensionais.

Define-se  $u_j$  como sendo um vértice do retângulo  $R_j$  e  $u_j^c$  (ou  $v_j$ ) como o outro vértice oposto deste mesmo retângulo representados na Figura 14. O tamanho de  $R_j$  é definido como sendo igual a altura somada à largura de  $R_j$ , ou seja:

$$\begin{aligned} |R_j| &\equiv |v_j - u_j|. & (4.4.3) \\ &= |(v_{1j} - u_{1j}) (v_{2j} - u_{2j})| \\ &= |(v_{1j} - u_{1j})| + |(v_{2j} - u_{2j})| \\ &\quad \text{base do} \qquad \qquad \text{altura do} \\ &\quad \text{retângulo} \qquad \qquad \text{retângulo} \end{aligned}$$

sendo:

$$v_j = [v_{1j} \ v_{2j}]$$

$$u_j = [u_{1j} \ u_{2j}].$$




Figura 14. Interpretação geométrica do ART Nebuloso na forma de codificação do complemento.

Quando se utiliza o treinamento rápido no sistema ART nebuloso,  $b = 1$ , sendo  $J$  um nó descomprometido (sem ter agrupado nenhuma categoria/valores dos pesos todos ainda unitários), segundo a Equação (4.3.7.1), o novo vetor peso se torna:

$$w_J^{(novo)} = I;$$

$$= [ \mathbf{a} \ \mathbf{a}^c ] . \quad (4.4.4)$$

Assim, os vértices do novo retângulo formado por  $\mathbf{w}_J^{(novo)}$  são  $\mathbf{a}$  e  $(\mathbf{a}^c)^c = \mathbf{a}$ . Portanto,  $R_J^{(novo)}$  é justamente o ponto  $\mathbf{a}$ .




Figura 15. Representação geométrica durante o treinamento rápido.

O treinamento aumenta o tamanho de cada retângulo  $R_j$ . Desta forma, o tamanho de  $R_j$  aumenta e o valor de  $\mathbf{w}_j$  reduz durante o treinamento. O tamanho máximo de  $R_j$  é condicionado ao parâmetro de vigilância  $\mathbf{r}$ . Durante cada processamento do treinamento rápido,  $R_j$  expande para  $R_j \oplus \mathbf{a}$ , sendo  $\oplus$  “operador” expansão, o qual é o retângulo mínimo contendo  $R_j$  e  $\mathbf{a}$  (vide Figura 15). Os vértices de  $R_j \oplus \mathbf{a}$  são dados por  $\mathbf{a} \wedge \mathbf{u}_j$  e  $\mathbf{a} \vee \mathbf{u}_j$ , sendo o operador nebuloso AND ( $\wedge$ ) definido por:

$$(\mathbf{p} \wedge \mathbf{q})_i \equiv \min(p_i, q_i); \quad (4.4.5)$$

e o operador nebuloso OR ( $\vee$ ) é definido por:

$$(\mathbf{p} \vee \mathbf{q})_i \equiv \max(p_i, q_i). \quad (4.4.6)$$

Então, o tamanho de  $R_j \oplus \mathbf{a}$  pode ser representado por:

$$|R_j \oplus \mathbf{a}| \equiv |(\mathbf{a} \vee \mathbf{v}_j) - (\mathbf{a} \wedge \mathbf{u}_j)|. \quad (4.4.7)$$

O processo de *reset* faz com que seja escolhida outra categoria se  $|R_j \oplus \mathbf{a}|$  for muito grande. Com o treinamento rápido, cada  $R_j$  iguala-se ao menor retângulo que engloba todos os vetores  $\mathbf{a}$  escolhidos para a categoria  $j$ , com a condição de que:

$$|R_j| \leq 2(1 - \mathbf{r}). \quad (4.4.8)$$

Em geral, se  $\mathbf{a}$  tem dimensão  $M$ , no hiper-retângulo  $R_j$  inclui os dois vértices  $\wedge_j \mathbf{a}$  e  $\vee_j \mathbf{a}$ , sendo que o  $i$ -ésimo componente de cada vetor é definido pela equação:

$$(\wedge_j \mathbf{a}) = \min \{ a_i : \mathbf{a} \text{ foi codificado pela categoria } j \}; \quad (4.4.9)$$

e

$$(\vee_j \mathbf{a}) = \max \{ a_i : \mathbf{a} \text{ foi codificado pela categoria } j \}. \quad (4.4.10)$$

O tamanho de  $R_j$  é dado por:

$$|R_j| \equiv | \vee_j \mathbf{a} - \wedge_j \mathbf{a} |; \quad (4.4.11)$$

e o peso  $w_j$  é dado por:

$$\mathbf{w}_j = (\wedge_j \mathbf{a}, (\vee_j \mathbf{a})^c); \quad (4.4.12)$$

que são formas semelhantes às apresentadas nas Equações (4.4.2) e (4.4.3). Então:

$$|\mathbf{w}_j| \equiv \sum_i (\wedge_j \mathbf{a})_i + \sum_i [1 - (\vee_j \mathbf{a})_i] = M - | \vee_j \mathbf{a} - \wedge_j \mathbf{a} |. \quad (4.4.13)$$




Figura 16. ART nebuloso com treinamento rápido e codificação do complemento, a  $j$ -ésima categoria do retângulo  $R_j$  que inclui todos aqueles vetores  $\mathbf{a}$  no quadrado unitário o qual tem categoria de ativação  $j$  sem *reset*. O vetor peso  $\mathbf{w}_j$  iguala-se a  $(\wedge_j \mathbf{a}, (\vee_j \mathbf{a})^c)$ .

Com o treinamento rápido e a codificação complementar do sistema ART nebuloso, a  $j$ -ésima categoria do retângulo  $R_j$  inclui todos aqueles vetores  $\mathbf{a}$  na unidade do quadrado o qual tem categoria ativada  $j$  sem *reset* (Figura 16). O vetor peso  $\mathbf{w}_j$  é igual a  $(\wedge_j \mathbf{a}, (\vee_j \mathbf{a})^c)$ . O tamanho (magnitude) do hiper-retângulo é, portanto:

$$|R_j| = M - |\mathbf{w}_j|. \quad (4.4.14)$$

A partir das Equações (4.3.6.3), (4.3.7.1) e (4.3.4.3), conclui-se que:

$$|\mathbf{w}_j| \geq \mathbf{r} M; \quad (4.4.15)$$

e a partir das Equações (4.4.1.3) e (4.4.1.4), obtém-se:

$$|R_j| \leq (1 - \mathbf{r}) M. \quad (4.4.16)$$

Assim, maior parâmetro de vigilância ( $\mathbf{r} \cong 1$ ) leva a menor  $R_j$ , enquanto menor vigilância ( $\mathbf{r} \cong 0$ ) permite maior  $R_j$ .

*Teorema* : Um sistema ART Nebuloso com codificação de complemento, treinamento rápido, e parâmetro de vigilância constante, forma categorias contidas em hiper-retângulos que convergem para limites em resposta a uma seqüência arbitrária de vetores de entrada analógicos ou binários.

Os hiper-retângulos aumentam monotonicamente em todas as dimensões. O tamanho  $|R_j|$  de um hiper-retângulo é igual  $M - |\mathbf{w}_j|$ , onde  $\mathbf{w}_j$  é o vetor peso correspondente. O tamanho  $|R_j|$  é limitado acima por  $M(1-\mathbf{r})$ . No limite conservativo, o treinamento referente a 1 iteração é tal que nenhum *reset* ou aprendizado adicional ocorre em apresentações subseqüentes de qualquer entrada. Portanto, se  $0 \leq \mathbf{r} < 1$ , o número de categorias é limitado, ainda que o número de exemplares na série de treinamento seja ilimitado.

## 4.5. CONCLUSÃO

Neste capítulo foi apresentada a rede neural ART (*Adaptive Resonance Theory*), suas características básicas e seu algoritmo. Foi também mostrada com detalhes uma interpretação geométrica do funcionamento da rede neural ART bem como sua capacidade de generalização.

## CAPÍTULO 5

### REDE NEURAL ARTMAP

#### 5.1. INTRODUÇÃO

Neste capítulo é apresentada a rede neural ARTMAP nebulosa. Trata-se de uma rede composta por dois módulos ART denominados  $ART_a$  e  $ART_b$ , os quais são treinados de modo não-supervisionado. Estes dois módulos são interligados por um módulo Inter-ART que é responsável pelo “casamento” entre as informações de entrada e de saída codificadas nas redes neurais  $ART_a$  e  $ART_b$ , ou seja, é realizado o mapeamento  $\mathbf{b} = \mathbf{f}(\mathbf{a})$ ,  $\mathbf{a}$  (entrada)  $\hat{\mathbf{I}} \hat{\mathbf{A}}^n$  e  $\mathbf{b}$  (saída)  $\hat{\mathbf{I}} \hat{\mathbf{A}}^m$ , sendo  $\mathbf{f}$  uma função desconhecida (linear ou não-linear) multi-dimensional. A rede neural ARTMAP também possui a característica de estabilidade e plasticidade, tal como a rede neural não-supervisionada ART. A inclusão dos conceitos da lógica nebulosa conferem a rede neural ARTMAP (ARTMAP nebulosa) uma maior flexibilidade de trabalho, pois pode ser empregada para manipular dados analógicos e/ou binários indistintamente, além de facilitar a implementação em *software*, bem como em *hardware*. Outra característica importante desta rede, igualmente estendida às demais redes neurais da linhagem ART, refere-se ao treinamento ser executado com grande rapidez, permitindo a implementação do treinamento de forma contínua sendo, portanto, uma estrutura bastante apropriada para o uso em tempo real.

Deve-se ressaltar que esta rede tem sido aplicada para a solução de problemas em várias áreas do conhecimento humano [1], [4], [7], [8], [10], [19], [27], [38], [44], [61], [65], [66], [69], [73].

#### 5.2. CARACTERÍSTICAS DA REDE NEURAL ARTMAP NEBULOSA

A arquitetura da rede neural ARTMAP possui a característica de realizar treinamento rápido de reconhecimento *on-line* e, ainda, manter a estabilidade do processo

de treinamento e de inferências. Ela também é capaz de executar testes de hipóteses e realizar classificação adaptativa em resposta a um fluxo arbitrário de padrões de entrada, podendo eles serem analógicos ou binários.

O sistema ARTMAP nebuloso inclui um par de módulos da teoria da ressonância adaptativa ( $ART_a$  e  $ART_b$ ) (Figura 12) que criam categorias de reconhecimento estáveis (Figura 16) [15]. Durante o treinamento supervisionado, os módulos  $ART_a$  e  $ART_b$  recebem, respectivamente, um fluxo de padrões de entrada  $a$  e um fluxo de padrões de entrada  $b$ , sendo que  $b$  é o diagnóstico correto associado à entrada  $a$ . Estes módulos são conectados por uma rede de treinamento associativa e um controlador interno (módulo inter-ART,  $F^{ab}$ , chamado de mapa de campo) que garante a operação do sistema em tempo real. O controlador é projetado para criar um número mínimo de categorias de reconhecimento necessárias para encontrar o critério de precisão. Este processo é realizado por uma regra de treinamento *minimax* que permite o sistema aprender rápido, eficiente e precisamente, minimizando o erro e maximizando a generalização do diagnóstico. O parâmetro  $r_a$  ajusta a semelhança mínima que  $ART_a$  deve ter no reconhecimento de uma categoria.

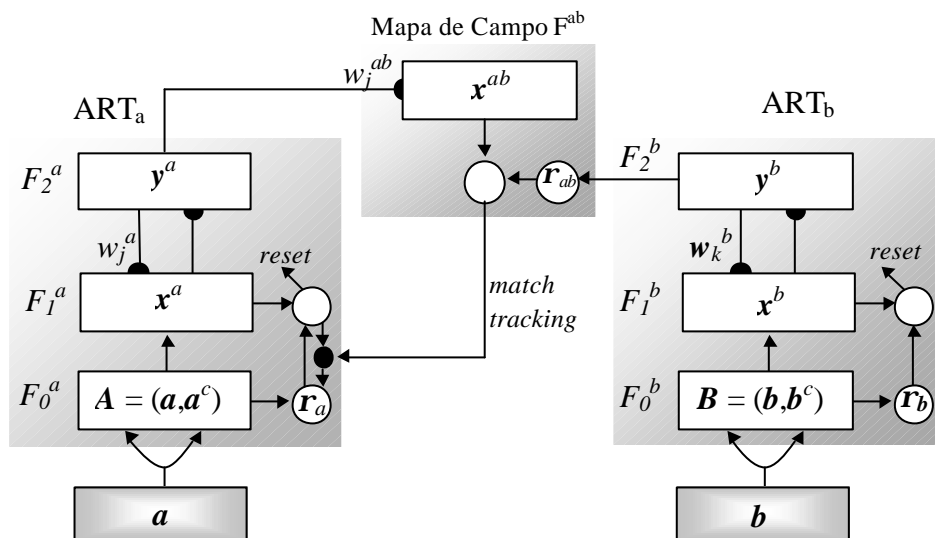


Figura 16. Arquitetura ARTMAP Nebulosa.

Valores baixos de  $r_a$  permitem a formação de categorias com maior número de padrões, generalização mais ampla e maior compressão do código. Num diagnóstico “mal

sucedido”, em  $ART_b$  deve-se aumentar  $r_a$  em uma quantia mínima necessária para acionar as hipóteses de teste em  $ART_a$  utilizando um mecanismo chamado *match-tracking*. Hipóteses de teste levam à seleção de uma nova categoria  $ART_a$ , a qual focaliza atenção em um novo agrupamento de características de entrada  $a$  que é mais capaz de diagnosticar  $b$ . O *match-tracking* reorganiza a estrutura da categoria, tal que o diagnóstico errôneo não é repetido em apresentações de entradas subsequentes. Esta combinação do mecanismo *match-tracking* e do treinamento rápido, pode levar a diferentes diagnósticos para um mesmo evento. A melhoria no diagnóstico é alcançada pelo treinamento do sistema realizado várias vezes, usando diferentes ordenações do grupo de entrada (ordenação pseudo-aleatória). O diagnóstico final, para um dado item de grupo de teste, é feito para o maior número de ocorrências na simulações (estratégia de votação) [15]. Esta estratégia pode também ser usada para aumentar a confiabilidade na avaliação de diagnósticos competitivos, dadas séries de treinamento pequenas, ruidosas ou incompletas [15].

### 5.3. ALGORITMO DO SISTEMA ARTMAP NEBULOSO

Como já foi mencionado anteriormente, a rede neural ARTMAP nebulosa incorpora dois módulos ART:  $ART_a$  e  $ART_b$ . Estes dois módulos são interligados através do módulo inter-ART, chamado mapa de campo  $F^{ab}$ . As interações mediadas pelo mapa de campo podem ser operacionalmente caracterizadas da seguinte maneira:

- 1) As entradas  $ART_a$  e  $ART_b$  são codificadas na forma do complemento:

$$\text{Para o } ART_a : \mathbf{I} = \mathbf{A} = [ \mathbf{a} \ \mathbf{a}^c ]$$

$$\text{Para o } ART_b : \mathbf{I} = \mathbf{B} = [ \mathbf{b} \ \mathbf{b}^c ]$$

- 2) Para o  $ART_a$  :

$$\text{O vetor de saída } F_1^a, \ \mathbf{x}^a \equiv [ x_1^a \ \dots \ x_{2Ma}^a ]$$

$$\text{O vetor de saída } F_2^a, \ \mathbf{y}^a \equiv [ y_1^a \ \dots \ y_{Na}^a ]$$

$$\text{O } j\text{-ésimo vetor peso, } \mathbf{w}_j^a \equiv [ w_{j1}^a \ w_{j2}^a \ \dots \ w_{j2Ma}^a ]$$

- 3) Para o  $ART_b$  :



O vetor de saída  $F_1^b$ ,  $\mathbf{x}^b \equiv [x_1^b \dots x_{2Mb}^b]$

O vetor de saída  $F_2^b$ ,  $\mathbf{y}^b \equiv [y_1^b \dots y_{Nb}^b]$

O  $k$ -ésimo vetor peso,  $\mathbf{w}_k^b \equiv [w_{k1}^b \ w_{k2}^b \ \dots \ w_{k2Mb}^b]$

4) Para o mapa de campo:

A saída do vetor  $F^{ab}$ ,  $\mathbf{x}^{ab} \equiv [x_1^{ab} \dots x_{Nb}^{ab}]$

O vetor peso do  $j$ -ésimo nó  $F_2^a$ ,  $\mathbf{w}_j^{ab} \equiv [w_{j1}^{ab} \dots w_{jNb}^{ab}]$ .

Os vetores  $\mathbf{x}^a$ ,  $\mathbf{y}^a$ ,  $\mathbf{x}^b$ ,  $\mathbf{y}^b$  e  $\mathbf{x}^{ab}$  são fixados em zero entre as apresentações da entrada.

A ativação do mapa de campo  $F^{ab}$  ocorre caso uma das categorias  $ART_a$  ou  $ART_b$  esteja ativa. Se o nó  $J$  de  $F_2^a$  é escolhido, então, seus pesos  $\mathbf{w}_J^{ab}$  ativam  $F^{ab}$ . Se o nó  $k$  em  $F_2^b$  está ativo, então, o nó  $K$  em  $F^{ab}$  é ativado um-a-um entre os caminhos de  $F_2^b$  e  $F^{ab}$ . Se ambos  $ART_a$  e  $ART_b$  estão ativos, então,  $F^{ab}$  torna-se ativo somente se  $ART_a$  diagnostica a mesma categoria de  $ART_b$ , por meio dos pesos  $\mathbf{w}_J^{ab}$ . Resumindo, o vetor de saída  $\mathbf{x}^{ab}$  de  $F^{ab}$  comporta-se da seguinte forma [15]:

$$\mathbf{x}^{ab} = \begin{cases} \mathbf{y}^b \wedge \mathbf{w}_J^{ab} & \rightarrow \text{se o } J\text{-ésimo nó de } F_2^a \text{ está ativo e } F_2^b \text{ está ativo;} \\ \mathbf{w}_J^{ab} & \rightarrow \text{se o } J\text{-ésimo nó de } F_2^a \text{ está ativo e } F_2^b \text{ está inativo;} \\ \mathbf{y}^b & \rightarrow \text{se } F_2^a \text{ está inativo e } F_2^b \text{ está ativo;} \\ 0 & \rightarrow \text{se } F_2^a \text{ está inativo e } F_2^b \text{ está inativo.} \end{cases} \quad (5.3.1)$$

Conforme equação (5.3.1),  $\mathbf{x}^{ab} = 0$  se o diagnóstico  $\mathbf{w}_J^{ab}$  não for confirmado por  $\mathbf{y}^b$ . Esta não confirmação aciona uma nova pesquisa de índice em  $ART_a$  para a obtenção de uma melhor categoria.

*Match-Tracking* (ajuste de adaptação). No início de cada apresentação de entrada o parâmetro de vigilância  $\mathbf{r}_a$  iguala-se a uma vigilância base,  $\bar{\mathbf{r}}_a$ . O parâmetro de vigilância do mapa de campo é  $\mathbf{r}_{ab}$ . Se a inequação:

$$|\mathbf{x}^{ab}| < \mathbf{r}_{ab} |\mathbf{y}^b| \quad (5.3.2)$$

é satisfeita, então,  $\mathbf{r}_a$  é aumentado até que ele seja ligeiramente maior do que:

$$|A \wedge w_J^a| < |A|^{-1} \quad (5.3.3)$$

na qual  $A$  é a entrada para  $F_1^a$ , na forma de código de complemento. Então:

$$|x^a| = |A \wedge w_J^a| < r_a |A| \quad (5.3.4)$$

em que  $J$  é o índice ativo para o nó  $F_2^a$  ativo. Quando isso ocorre,  $ART_a$  conduz a pesquisa também para ativação de outro nó  $J$  em  $F_2^a$  com:

$$|x^a| = |A \wedge w_J^a| \geq r_a |A| \quad (5.3.5)$$

e

$$|x^{ab}| = |y^b \wedge w_J^{ab}| \geq r_{ab} |y^b| \quad (5.3.6)$$

Caso nada semelhante exista, ocorre a paralisação de  $F_2^a$  para o restante da apresentação da entrada.

*Treinamento do Mapa de Campo.* Existem regras para o treinamento, as quais determinam como os pesos do mapa de campo  $w_{jk}^{ab}$  são atualizados. Os pesos  $w_{jk}^{ab}$  em  $F_2^a \rightarrow F^{ab}$  inicialmente são  $w_{jk}^{ab}(0) = 1$ . Durante a ressonância com a categoria ativa  $J$  de  $ART_a$ ,  $w_J^{ab}$  se aproxima do vetor de mapa de campo  $x^{ab}$ . Com o treinamento rápido, uma vez que  $J$  aprende a diagnosticar a categoria  $K$  em  $ART_b$ , aquela associação é permanente, ou seja,  $w_{JK}^{ab} = 1$  durante todo o processo.

Na Figura 17 e Tabela 3 apresentam-se uma síntese sobre o mecanismo de funcionamento da rede neural ARTMAP nebulosa nas atividades de F2 e módulo Inter-ART.

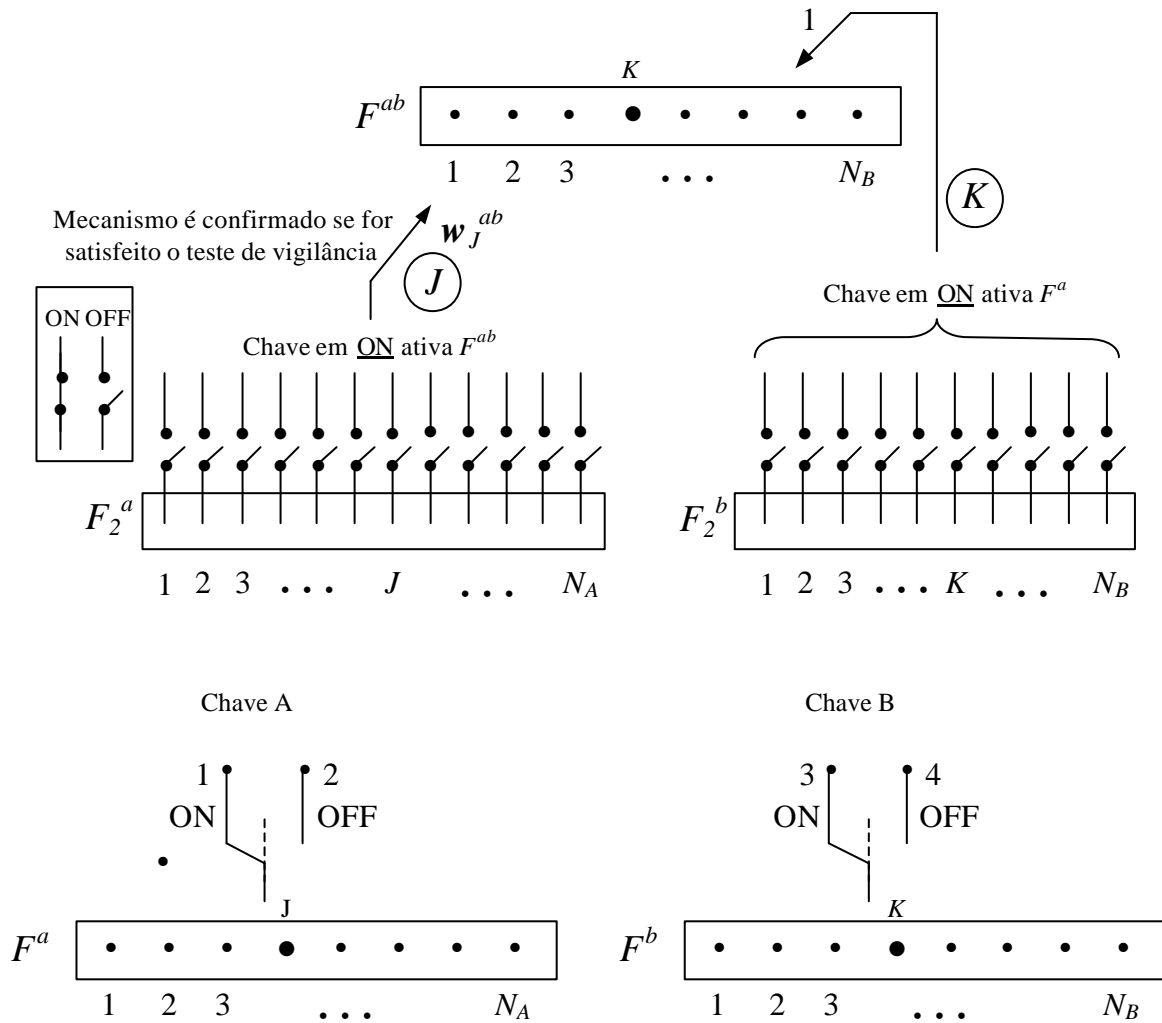


Figura 17. Funcionamento da rede neural ARTMAP nebulosa.

Tabela 3. Atividade no módulo Inter-ART.

$F^a$		Atividade	$F^b$		Atividade	$F^{ab}$
Chave			Chave			
ON	OFF	Atividade	ON	OFF	Atividade	Atividade
①	②		③	④		
$x$		$w_J^{ab}$	$x$		$y^b$	$y^b \wedge w_J^{ab}$
$x$		$w_J^{ab}$		$x$	0	$w_J^{ab}$
	$x$	0	$x$		$y^b$	$y^b$
	$x$	0		$x$	0	0

## 5.4. EXEMPLO ILUSTRATIVO

A seguir apresenta-se a análise de estabilidade transitória de sistemas de energia elétrica de um sistema composto por máquina síncrona contra barra infinita, por exemplo, considerando-se contingências referentes à saída de linha de operação. Para realizar a análise será necessário o uso de um número grande de pontos (constituindo os exemplos para o treinamento). Contudo, somente três pontos são empregados neste exemplo como forma de ilustrar a aplicação da rede neural ARTMAP nebulosa. São 3 perfis ( $P_m$ ,  $Q$ ) de geração, cujo indicativo de estabilidade do sistema extraído via emprego do CIA (Critério da Igualdade de Áreas) que é uma das técnicas mais indicadas para o caso de análise de sistema formado por máquina síncrona contra barra infinita. Para cada ponto a indicação será estável ou instável mediante o emprego do CIA como abordado a seguir.

Uma máquina síncrona é conectada a uma barra infinita através de um circuito duplo, conforme é mostrada na Figura 19. Consideram-se as seguintes hipóteses:

1. máquina síncrona representada por uma fonte de tensão atrás de uma reatância transitória;
2. fluxo de dispersão constante;
3. potência mecânica de entrada constante ( $P_m$ );
4. momento de inércia ( $M$ ) constante;
5. resistências nulas;
6. amortecimento nulo;
7. máquina síncrona de rotor liso.

### 5.4.1. CRITÉRIO DA IGUALDADE DE ÁREAS

Considera-se a equação de oscilação de uma máquina síncrona ligada a um barramento infinito e despreza-se o amortecimento:

$$M \frac{d^2\delta}{dt^2} = Pa \quad (5.4.1.1)$$

sendo:

$P_a \triangleq$  potência acelerante.

$$= P_m - P_e .$$

$P_e$  = Potência elétrica da máquina síncrona.

O CIA corresponde a interpretação da seguinte equação:

$$d\mathbf{d}/dt = \left\{ \int_{\mathbf{d}_0}^{\mathbf{d}_1} \frac{2P_a}{M} d\mathbf{d} \right\}^{1/2} \quad (5.4.1.2)$$

sendo:

$\mathbf{d}_0$  = posição angular da máquina síncrona funcionando de modo síncrono pré-falta, quando  $d\mathbf{d}/dt = 0$ .

O ângulo  $\mathbf{d}$  deixará de variar e a máquina novamente funcionará com velocidade síncrona, após a perturbação, quando  $d\mathbf{d}/dt = 0$ , ou quando:

$$\int_{\mathbf{d}_0}^{\mathbf{d}_1} \frac{2P_a}{M} d\mathbf{d} = 0 \quad (5.4.1.3)$$

A máquina não permanece em repouso com relação a barra infinita na primeira vez que  $d\mathbf{d}/dt = 0$ . Porém, o fato de que  $\mathbf{d}$  deixou momentaneamente de variar pode ser tomado como um indicativo de estabilidade do sistema. Se a potência acelerante ( $P_a$ ) é “plotada”, em função do ângulo  $\mathbf{d}$ , a expressão:

$$\int_{\mathbf{d}_0}^{\mathbf{d}_1} P_a d\mathbf{d}$$

pode ser interpretada como sendo a área sob a curva entre  $\mathbf{d}_0$  e  $\mathbf{d}_1$ , como mostra a Figura 18.




Figura 18. Ilustração do critério da igualdade de áreas.

$A1$  e  $A2$ , respectivamente, são áreas de aceleração e desaceleração. Deste modo, pode-se estabelecer o seguinte critério de análise de estabilidade transitória deste sistema:

1. se  $A1 \leq A2$ , o sistema é estável;
2. se  $A1 > A2$ , o sistema é instável;
3. limite de estabilidade: ocorre quando  $\delta_l$  é tal que  $Pa(\delta_l) = 0$  e as áreas  $A1$  e  $A2$  são iguais.

#### 5.4.2. EXEMPLO NUMÉRICO

O circuito equivalente deste sistema é mostrado na Figura 19.




Figura 19. Circuito equivalente.

dados:

$$E = 1,05 \text{ pu};$$

$$Xd = 0,2 \text{ pu (reatância transitória de eixo direto);}$$

$$X'd = 0,2 \text{ pu (reatância subtransitória de eixo direto);}$$

$$XT = 0,1 \text{ pu (reatância do transformador (reatância de dispersão));}$$

$$XL1 = 0,4 \text{ pu (reatância da linha 1);}$$

$$XL2 = 0,4 \text{ pu (reatância da linha 2);}$$

$$V = 1,00 \text{ pu};$$

$$Pm = 0,8 \text{ pu};$$

$$H = 4 \text{ MJ / MVA.}$$

A potência elétrica antes da retirada do defeito vale:

$$Pe^a = E V |YI2^a| \text{ sen } \mathbf{d}$$

sendo:

$$\begin{aligned} Xeq^a &= X'd + XT + (XL1 XL2) / (XL1 + XL2) \\ &= 0,5 \end{aligned}$$

$$\begin{aligned} |YI2^a| &= 1 / |Xeq^a| \\ &= 2 \end{aligned}$$

$$\begin{aligned} E V |YI2^a| &= 1,05 \cdot 1 \cdot 2 \\ &= 2,1 \end{aligned}$$

$$Pe^a = 2,1 \text{ sen } \mathbf{d}$$

O circuito equivalente, considerando-se a saída de operação da linha de transmissão 2, pode ser visualizado na Figura 20.




Figura 20. Circuito equivalente referente à saída da linha de transmissão 1.

A admitância equivalente do circuito entre as barras 1 e 2 vale:

$$Y_{12}^p = -j / \{ 0,2 + 0,1 + 0,4 \}$$

$$= -j 1,4286.$$

A potência elétrica correspondente é dada por:

$$P_e^p = E V | Y_{12}^p | \text{sen } d$$

ou seja:

$$P_e^p = 1,5 \text{ sen } d.$$

Ressalta-se que cada perfil de geração é definido pelo par de potências mecânica ( $P_m$ ) e reativa ( $Q$ ) da máquina síncrona. A potência reativa corresponde ao valor necessário para manter constante a tensão terminal da máquina síncrona.

Assim sendo, o CIA para este caso pode ser ilustrado na Figura 21.

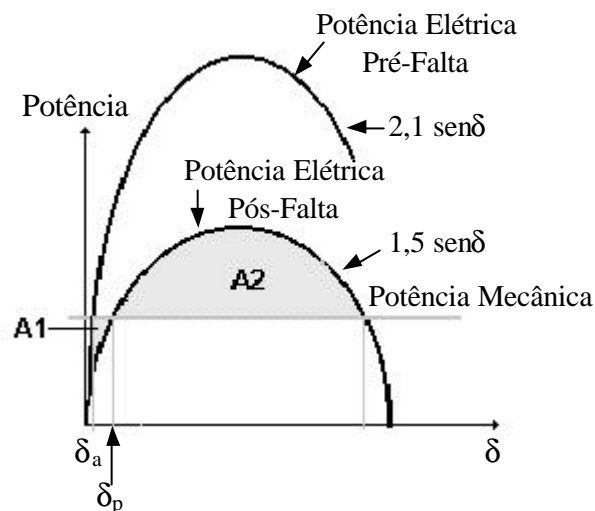


Figura 21. Análise de estabilidade transitória via critério da igualdade de áreas para contingência tipo saída de linha de transmissão.



Assim, obtém-se os seguintes valores para as áreas de aceleração e desaceleração:

$$A1 = \int_{d_a}^{d_p} (Pm - 1,5 \text{ sen } d) dd$$

$$A2 = \int_{d_p}^{p-d_p} (1,5 \text{ sen } d - Pm) dd .$$

Considerando-se 3 perfis de geração, os quais produzem os resultados relacionados na Tabela 4.

Tabela 4. Resultados da análise de estabilidade transitória pelo critério da igualdade de áreas.

Ponto	Pm	Q	Área de Aceleração A1	Área de Desaceleração A2	Indicação da Estabilidade
1	0,8	0,26	0,0195	0,9245	Estável
2	1,4	0,56	0,0839	0,0489	Instável
3	1,2	0,44	0,0519	0,2556	Estável

Considerando-se, portanto, a codificação para a saída da rede neural ARTMAP os valores 1 e 0 para representarem os casos estáveis e instáveis respectivamente. Assim, tem-se:

$$a_1 = [0,8 \ 0,26], \quad b_1 = [1];$$

$$a_2 = [1,4 \ 0,56], \quad b_2 = [0];$$

$$a_3 = [1,2 \ 0,44], \quad b_3 = [1].$$

sendo:

$$a = [Pm \ Q].$$

A curva mostrada no gráfico (Figura 22) representa uma linha imaginária que divide padrões de saída binários (0, 1) em casos instáveis e estáveis, respectivamente.

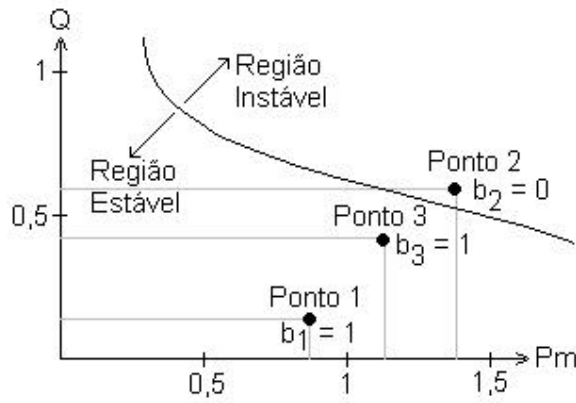


Figura 22. Ilustração dos pares de padrões de entrada e de saída.

Os vetores  $a_1$ ,  $a_2$  e  $a_3$ , por conveniência podem ser normalizados (para deixar os valores dos  $a_i$ 's e  $b_i$ 's dentro do intervalo  $[0,1]$ ), por exemplo, tomando-se como base o valor 2.

$$\underline{a}_1 = [0,4 \ 0,13], \quad b_1 = [1];$$

$$\underline{a}_2 = [0,7 \ 0,28], \quad b_2 = [0];$$

$$\underline{a}_3 = [0,6 \ 0,22], \quad b_3 = [1].$$

Na Tabela 5 são apresentados os vetores de entrada e de saída normalizados e aplicados a codificação complementar. Na Figura 23 apresentam-se os resultados do treinamento da rede neural ARTMAP nebulosa para a realização do referido exemplo. São mostradas as matrizes  $w^a$ ,  $w^b$  e  $w^{ab}$ . Em tais matrizes, as linhas nas quais todos os componentes são iguais a 1 referem-se às unidades não ativadas.

Deve-se ressaltar que, uma vez concluída a fase de treinamento, somente a matriz (memória)  $w^b$  é usada para a realização da análise (diagnóstico). O restante deste módulo não é usado. O diagnóstico é realizado via ART<sub>a</sub>, Inter-ART e  $w^b$ , na busca de  $y^b$  (classe diagnosticada) associada ao vetor padrão  $a$  (entrada) desconhecido, como conseqüência, determina-se o vetor  $b$  associado. Ou seja, estar-se-á realizando o mapeamento:  $b = f(a)$ ,  $a \hat{I} \hat{A}^2$  e  $b \hat{I} \hat{A}^1$ .

Tabela 5. Vetores normalizados e complementados.

Padrão	Entrada Normalizada e com Complemento	Saída Normalizada e com Complemento
1	[0,4 0,13 0,6 0,87]	[1 0]
2	[0,7 0,28 0,3 0,72]	[0 1]
3	[0,6 0,22 0,4 0,78]	[1 0]




Figura 23. Rede ARTMAP nebulosa para a realização do exemplo.

Na Figura 23, pode-se observar as matrizes treinadas para os módulos ART<sub>a</sub>, ART<sub>b</sub> e Inter ART. No módulo ART<sub>a</sub>, os três padrões são diferentes (apurados via aplicação do critério da rede neural ART), portanto, ocupam três memórias na matriz  $w^a$ . No módulo ART<sub>b</sub>, dos três padrões, dois são iguais, desta forma ocupam duas memórias na matriz  $w^b$ . A matriz Inter ART indica a linha correspondente ao ART<sub>a</sub> e a coluna correspondente ao ART<sub>b</sub>. A primeira linha da matriz, primeiro padrão ART<sub>a</sub>, é ajustada na primeira coluna em consequência da primeira memória de ART<sub>b</sub> ser utilizada. Na segunda linha, segundo padrão ART<sub>a</sub>, a segunda coluna é ajustada em 1, pois o padrão de ART<sub>b</sub> utiliza a segunda memória. Já na terceira linha, é utilizado a terceira memória para o ART<sub>a</sub>.

e no  $ART_b$  a primeira memória, então, em  $w^{ab}$ , ajusta-se o valor 1 para a terceira linha primeira coluna.

## 5.5. CONCLUSÃO

Neste capítulo é apresentada a rede neural ARTMAP nebulosa, seu algoritmo, seu princípio de funcionamento e suas características. É mostrado também um exemplo ilustrativo numérico, pelo critério da igualdade de áreas, no contexto de estabilidade transitória de sistemas de energia elétrica, através de um sistema composto por máquina síncrona contra barra infinita.

## **CAPÍTULO 6**

### **FORMULAÇÃO DO PROBLEMA DA ANÁLISE DE SEGURANÇA DE SISTEMAS ELÉTRICOS DE POTÊNCIA POR REDES NEURAIAS**

#### **6.1. INTRODUÇÃO**

Neste capítulo é formulado o problema da análise de segurança de sistemas de energia elétrica por redes neurais. A rede neural, proposta nesta pesquisa, refere-se à rede ART&ARTMAP nebulosa que será abordada no capítulo 7. A formulação da rede neural, para a realização da análise de segurança, envolve a definição de índices para a mensuração dos efeitos das contingências sobre o sistema. Para tanto, deve-se desenvolver e adequar modelos que estabeleçam a relação entre os estímulos de entrada e de saída e quais são as variáveis que constituem estes estímulos. Deve-se, também, desenvolver a estratégia para gerar o conjunto de estímulos, considerando o possível espectro de variação da demanda e o conseqüente atendimento pelas unidades geradoras. Trata-se, portanto, do estabelecimento do planejamento de dados para a fase de treinamento da rede neural. Estes temas são, então, abordados neste capítulo.

#### **6.2. FORMULAÇÃO**

Os efeitos de contingências sobre a operação de Sistemas de Energia Elétrica, por questões de conveniência, podem ser divididos em: (1) efeitos de pequena oscilação e (2) efeitos de grande oscilação. Os efeitos de pequena oscilação ocasionados, por exemplo,

por pequenas mudanças do perfil de geração do sistema (saída e/ou entrada em operação de equipamentos elétricos, mudança na carga do sistema, etc.) correspondem às perturbações que provocam pequenas oscilações em torno do ponto de equilíbrio. Estas oscilações, via de regra, podem ser modeladas como um problema linear, o que reduz a complexidade da análise. São chamadas de dinâmicas de pequenas oscilações. São modelos descritos por equações algébricas lineares e, em alguns casos, se necessários, são acrescentados sistemas de equações diferenciais lineares (procedentes de processo de linearização). Porém, nos casos dos efeitos de larga escala, por produzirem grandes oscilações, principalmente nos ângulos das máquinas síncronas, os modelos devem contemplar o comportamento não-linear do sistema. Neste caso, fazem parte desta classe as contingências de curto-circuito, saída de operação de equipamentos importantes do sistema, entre outras. Os modelos associados são descritos por equações algébricas e diferenciais não-lineares.

A seguir, são relacionadas as principais técnicas disponíveis na literatura para a análise de segurança:

(1) Pequenas Oscilações

- ◆ Análise de sensibilidade [42];
- ◆ Técnicas de autovalores e autovetores [42], [74];
- ◆ Perturbação singular [74], [81];
- ◆ Método direto de Liapunov [57];
- ◆ etc.

(2) Grandes Oscilações

- ◆ Resolução de sistemas de equações algébricas/diferenciais não-lineares altamente acopladas [3];
- ◆ Método direto de Liapunov [57];
- ◆ Técnicas de autovalores e autovetores [81];
- ◆ etc.

Tanto para dinâmica discreta como para dinâmica acentuada, pode-se empregar técnicas determinísticas, estocásticas, assim como técnicas inseridas no contexto de ALIFE (*artificial life* (vida artificial)) e computação quântica. No grupo de técnicas de inteligência artificial, destacam-se:

- ◆ redes neurais [31], [33], [36], [39], [43], [49], [67], [71], [72], [76];

- ◆ computação evolutiva [22];
- ◆ inteligência coletiva (*swarm intelligence*) [37];
- ◆ sistemas imunes artificiais [6], [17], [20], [21], [40], [77];
- ◆ computação quântica e neural-quântica [29], [32], [55];
- ◆ computação DNA [56];
- ◆ etc.

Estas técnicas de inteligência artificial constituem um conjunto de procedimentos que oferecem um grande potencial de aplicação, principalmente quando se exige maior qualidade das soluções: obtenção de soluções com a máxima rapidez, soluções “inteligentes” e precisas. As soluções inteligentes referem-se a uma série de dispositivos a serem empregados como, por exemplo: a incorporação de capacidade da tomada de decisão, resolução do problema frente à situações não previstas, etc.

Estas avaliações são realizadas, em sua grande maioria, através da observação de algum índice de inferência. Este índice “mede” o grau de severidade da contingência sobre o sistema. Por exemplo, a margem de segurança do sistema ( $M$ ) [50], para a análise de estabilidade transitória [24], [25], [34], [52] (assunto a ser abordado em seção posterior), fornece-nos a informação de quanto estável ou instável é o sistema na ocorrência da referida contingência. Quanto mais negativa for  $M$ , mais instável é o sistema, enquanto que quanto mais próximo de 1, mais robusto se apresenta o sistema frente à contingência. Ou seja, o espectro de variação da margem de segurança é, portanto:  $-\infty < M \leq 1$ . Assim, este índice  $M$ , ou um outro similar, pode ser usado para o treinamento da rede visando realizar a análise de estabilidade transitória de primeira oscilação.

Então, qualquer que seja a perturbação aplicada ao sistema – de pequena oscilação ou de grande oscilação – o seu impacto pode ser deduzido, através do uso de um índice apropriado. Este índice deve refletir de forma mais precisa possível, o comportamento do sistema, do ponto de vista quantitativo e, principalmente qualitativo. É, portanto, um desafio propor um índice com tais características sobre os problemas associados à análise de segurança. Cada enfoque dado ao problema de análise de segurança (estático ou dinâmico, critérios de estabilidade de tensão ou de ângulo, etc.) requer um

índice específico. Não há, por conseguinte, disponibilidade de um índice geral para todos os casos a serem analisados.

Assim sendo, nesta pesquisa, é proposto um esquema para o cálculo de índices de segurança através de redes neurais. Como argumentado anteriormente, a rede neural escolhida refere-se a arquitetura baseada na Teoria da Ressonância Adaptativa [11] – [16] pelas características já mencionadas. Trata-se de uma nova arquitetura chamada ART&ARTMAP nebulosa que será abordada no capítulo 7.

O funcionamento das redes neurais é constituído por duas fases fundamentais: treinamento e análise. As redes neurais são dispositivos que adquirem o conhecimento baseados na experiência que, neste caso, é realizado através do mecanismo de aplicação, convenientemente, de estímulos na entrada e na saída para redes supervisionadas, e apenas na entrada para redes não-supervisionadas. Na seqüência, é, por conseguinte, desenvolvido o sistema neural para a análise de segurança. Deve-se ressaltar que as redes neurais, em especial a proposta nesta pesquisa (que proporciona soluções rápidas e com boa precisão), são alternativas bastante interessantes para a resolução de uma série de problemas no contexto de sistemas de energia elétrica. Em destaque, na análise de segurança, por várias razões: (1) aprendem com a experiência, portanto, não havendo necessidade de conhecer o modelo do fenômeno que se está analisando, pelo menos, no mesmo grau de detalhamento como é abordado pelas demais técnicas; (2) uma vez concluído o treinamento, a análise é realizada em tempo real; e (3) permitem a realização do treinamento continuado fazendo com que se tenha à disposição uma técnica que, a princípio, pode proporcionar melhores soluções com o passar do tempo. Deve-se ressaltar que na rede proposta ART&ARTMAP nebulosa, o treinamento continuado pode ser implementado sem esforço computacional adicional.

Então, um índice geral de análise de segurança pode ser assim definido:

$$\begin{aligned} I(X) &\triangleq f(X) \\ &= Y \end{aligned} \tag{6.2.1}$$

sendo:

$I(X)$  = índice de segurança do sistema;

$f(X)$  = função não-linear desconhecida a ser identificada pela rede neural;



$X$  = conjunto de variáveis do sistemas aplicado na entrada da rede neural (estímulos de entrada);

$Y$  = conjunto de variáveis do sistemas aplicado na saída da rede neural (estímulos de saída).

Os vetores aqui usados seguem a notação por linha e não por coluna. Esta convenção facilita o tratamento da informação com redes neurais da família ART, se comparada à tradicional representação por coluna.

O treinamento e a análise são realizados, então, através das seguintes relações, respectivamente:

$$\begin{aligned}
 I(X^{\text{treinamento}}) &\triangleq f(X^{\text{treinamento}}) \\
 &= Y^{\text{treinamento}}
 \end{aligned}
 \tag{6.2.2}$$

$$\begin{aligned}
 I(X^{\text{análise}}) &\triangleq f(X^{\text{análise}}) \\
 &= Y^{\text{análise}}
 \end{aligned}
 \tag{6.2.3}$$

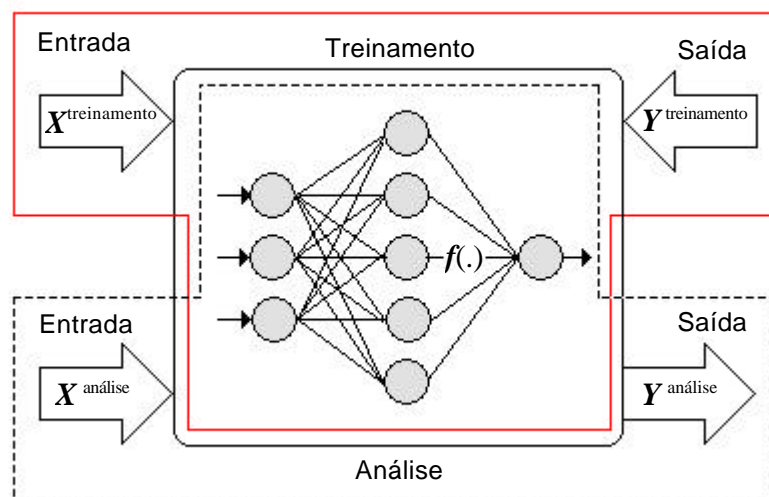


Figura 24. Treinamento e análise da rede neural para obtenção de índices de segurança.

A realização do sistema neural definido pelas Equações (6.2.2) e (6.2.3), ou seja, a identificação de uma função não-linear desconhecida correspondente ao mapeamento:  $X(\text{entrada}) \rightarrow Y(\text{saída}) = f(X)$ ,  $X \hat{I} \hat{A}^n$  e  $Y \hat{I} \hat{A}^m$ .

Nesta pesquisa é proposta uma rede neural (ART&ARTMAP nebulosa), descrita no capítulo 7, que visa proporcionar o máximo desempenho que as redes neurais da família ART podem proporcionar, que são: estabilidade e plasticidade, além de produzir soluções rápidas. Trata-se de uma concepção que utiliza os dados do problema – analógicos e binários – processados separadamente de tal forma que um módulo inicial ART nebuloso, associado a um conversor designado código ativo→código binário “aprende”, considerando-se os dados analógicos de entrada, via um treinamento não-supervisionado, para formar classes (códigos ativos) na saída deste módulo e converte tais classes em saídas binárias. Estas saídas binárias juntando-se aos dados binários de entrada da rede compõem a entrada (essencialmente binária) da rede neural ARTMAP nebulosa. A saída da rede neural (analógica que corresponde o índice  $I(X)$ ) é, também, usada na forma binária, gerada através de um módulo de processamento específico para cada aplicação. O funcionamento desta rede neural, envolvendo o treinamento e a análise, com entradas e saída binárias é muito eficiente, se comparado ao caso de entrada e de saída híbrida (analógica e binária).

O modelo do sistema com a estrutura anteriormente descrita pode ser desenvolvido da forma como é mostrada a seguir. Deve-se ressaltar que o estabelecimento deste modelo segue as orientações apresentadas na referência [64].

As informações necessárias para resolver um grande número de problemas em Sistemas de Energia Elétrica, em especial, para a análise da estabilidade transitória, podem ser agrupadas do seguinte modo [64]:

- (1) *Variáveis causais;*
- (2) *Variáveis Conseqüentes;*
- (3) *Parâmetros.*

Com esta divisão, é possível expressar o seguinte modelo para resolver tais problemas [64]:

$$Y = f(a, V, p) \quad (6.2.4)$$

sendo:

$Y$  = conjunto de variáveis de saída;

$f$  = função não-linear desconhecida;

$a$  = conjunto de variáveis causais;

$V$  = conjunto de variáveis conseqüentes;

$p$  = conjunto de parâmetros.

As variáveis causais  $a$ , consideradas nesta pesquisa, correspondem às potências ativa e reativa nodais do sistema. As variáveis conseqüentes  $V$ , dependendo do problema tratado, podem ser agrupadas de várias formas. Por exemplo, no caso da análise de estabilidade transitória de primeira oscilação, o conjunto  $V$  pode ser definido como sendo composto pelos ângulos e tensões nodais, os quais são a solução de um problema de fluxo de potência [53], [54], processado considerando-se as condições pré e pós-falta. Fazem parte de  $V$ , também, as potências elétricas das máquinas síncronas, velocidades, etc., obtidos a partir da resolução de um conjunto de equações ordinárias/diferenciais não-lineares. Enfim, são todas as grandezas que são envolvidas no processo de cálculo [64].

Contudo, as redes neurais produzem soluções baseadas num processo de treinamento, no qual é realizada a extração do conhecimento (pretende-se, por conseguinte, modelar a função  $f$  estritamente desconhecida), através da aplicação de estímulos na entrada e na saída do sistema neural. Deste modo, pode-se desenvolver um modelo alternativo à equação (6.2.4) em que as variáveis conseqüentes e os parâmetros passam a ser considerados como um conjunto implícito de informações, não necessitando ser fornecido à rede neural, bastando apenas dispor das variáveis causais e demais informações representadas por código (*e.g.*, código binário) [64]:

$$Y = f(a, L) \quad (6.2.5)$$

sendo:

$L$  = conjunto de informações codificadas (código binário).

Observa-se que o número de variáveis de entrada da rede neural, usando-se o modelo definido pela equação (6.2.5), é bastante reduzido, se comparado ao uso da forma convencional (equação (6.2.4)), que é a alternativa adotada pela maioria das referências [4], [35], [58], [68], entre outras.

Deste modo, as variáveis do sistema são divididas da seguinte forma:

- (1) variáveis de entrada analógicas  $a$  (vetor);
- (2) variáveis de entrada binárias  $L$  (vetor);
- (3) variável de saída  $Y$  (vetor).

As variáveis de entrada  $a$  são representadas pelos valores de potência ativa e reativa nodais, enquanto que  $L$  corresponde aos dados referentes às contingências, como mostrado no exemplo 1. A saída  $y$  será representada tomando-se como base as margens de segurança. Deve-se ressaltar que, através da aplicação de estímulos de entrada e saída da rede neural, o modelo (6.2.5) será estabelecido, ou seja, será determinada a função não-linear  $f$  desconhecida. Neste caso, está concluído o treinamento da rede neural. Se realizado com sucesso, a rede neural estará apta a generalizar (realização das análises).

Assim sendo, nesta Seção são estabelecidas as entradas e saídas da rede neural, de acordo com o modelo definido pela equação (6.2.5).

Exemplo Ilustrativo: Ocorrência de um curto-circuito na barra 12 com saída da linha de transmissão 2 (Figura 33 – página 84). A representação binária correspondente à esses acontecimentos pode ser feita da seguinte maneira:

Local : Barra 12 / Linha 2

Representação : 1100 / 0010

### 6.3. DEFINIÇÃO DOS ESTÍMULOS DE ENTRADA

A estrutura neural proposta visa a análise de segurança de sistemas de energia elétrica, considerando-se faltas de curto-circuito, saída ou entrada de operação de

equipamentos elétricos, etc., cujo enfoque de observação é dado sobre os ângulos e tensões (estabilidade de ângulos e de tensões). Os vetores padrões de entrada da rede neural são definidos como:

$$e = [ a \ L ] \quad (6.3.1)$$

sendo:

$e$  = vetor padrão de entrada da rede neural;

$L$  = vetor contendo as informações referentes às contingências (codificação binária);

$a$  = vetor padrão de entrada da rede neural referente às informações analógicas;

$$\underline{\Delta} [ P \ Q ]$$

$P$  = [  $P_1 \ P_2 \ \dots \ P_n$  ];

$Q$  = [  $Q_1 \ Q_2 \ \dots \ Q_n$  ];

$P_i$  = potência ativa da  $i$ -ésima barra do sistema;

$Q_i$  = potência reativa da  $i$ -ésima barra do sistema;

$n$  = número de barras do sistema.

O vetor  $L$  é formado por informações referentes às contingências (codificação binária). Para fins dos propósitos desta pesquisa, este vetor pode conter informações das contingências e da topologia da rede elétrica:

- (1) curto-circuito com saída de operação de linha de transmissão;
- (2) chaveamento de linhas de transmissão;
- (3) etc.

Usando-se a codificação binária pode-se trabalhar com várias alternativas combinando contingências e topologias da rede elétrica sob estudo. Por exemplo, pode-se considerar análise de uma contingência de curto-circuito com perda de linha de transmissão considerando-se várias topologias. Este evento pode ser contemplado, usando-se codificação binária representando 3 situações: barras sob curto-circuito; linha retirada e indicação de linha(s) adicionais em relação à configuração básica, como é ilustrado na Figura 25, ou seja, considera-se um trecho de um sistema onde se destacam a barra sob

curto-circuito (barra  $p$ ), a LT (Linha de Transmissão) retirada de operação (entre os nós  $p$  e  $q$ ) e a entrada de operação de um circuito (entre os nós  $r$  e  $s$ ).




Figura 25. Representação de um defeito referente a um curto-circuito com saída de linha de operação e mudança topológica correspondente à entrada em operação de uma linha de transmissão.

Tabela 6. Representação do vetor  $L$  por código binário da contingência e mudança topológica ilustrada na Figura 25.

Representação binária		
Curto-circuito na barra $p$  (Bloco 1)	Saída da LT entre os nós $p-q$  (Bloco 2)	Entrada em operação da LT entre os nós $r-s$ em relação à configuração básica  (Bloco 3)
$1 \ 2 \ \dots \ \dots \ nbits_1$ [0 0 0 1 0 ... 0 1 0 1]	$1 \ 2 \ \dots \ \dots \ nbits_2$ [0 1 1 1 0 ... 0 1 0 0]	$1 \ 2 \ \dots \ \dots \ nbits_3$ [1 1 1 1 1 ... 0 0 0 1]

O número de *bits* para os 3 blocos deve ser dimensionado de acordo com o número de contingências e da mudança topológica a ser considerado no problema a ser abordado, ou seja:

$$nbits_k \geq 1,44 \ln (N_k + 1) \quad (6.3.2)$$

sendo:

$nbits_k$  = número de *bits* para a representação do  $k$ -ésimo bloco;

$\ln$  = logaritmo neperiano;

$N_k$  = número de eventos do  $k$ -ésimo bloco;

$\dim(\mathbf{L}) = nbits_1 + nbits_2 + nbits_3$ .

Em resumo, a representação mostrada na Figura 25 destina-se, portanto, à análise de segurança considerando-se, a princípio, qualquer configuração, ao invés de uma topologia fixa. É, por conseguinte, uma situação mais plausível do ponto de vista da operação de sistemas elétricos de potência.

#### 6.4. DEFINIÇÃO DOS ESTÍMULOS DE SAÍDA

A formulação definida pelas equações (6.2.2) e (6.2.3) representam, portanto, a idealização da solução do problema da análise de segurança de forma genérica. Serve tanto para a análise onde se considera os critérios estáticos como dinâmicos. Para cada caso, o problema se restringe em estabelecer, convenientemente, os estímulos aplicados na saída, visto que as informações aplicadas na entrada da rede, no caso  $e \triangleq [P Q L]$ , são comuns para qualquer tipo de análise que se queira realizar, ou pelo menos, a grande maioria dos problemas que são abordados no contexto de sistemas elétricos de potência. Como já mencionado, o vetor  $e$  contém as variáveis causais do sistema e os dados referentes às contingências. Os parâmetros e demais variáveis (variáveis conseqüentes) são consideradas informações que são armazenadas na estrutura interna da rede neural, quando realizado o treinamento da rede, através da aplicação dos estímulos de entrada e de saída, como mostrado na Figura 26. As representações modulares servem apenas para enfatizar que uma mesma rede neural pode ser empregada para gerar vários índices de segurança, através da construção da estrutura interna nos pesos da rede. Para o cálculo dos índices, as variáveis de entrada são comuns a todos. O que muda são os estímulos de saída.

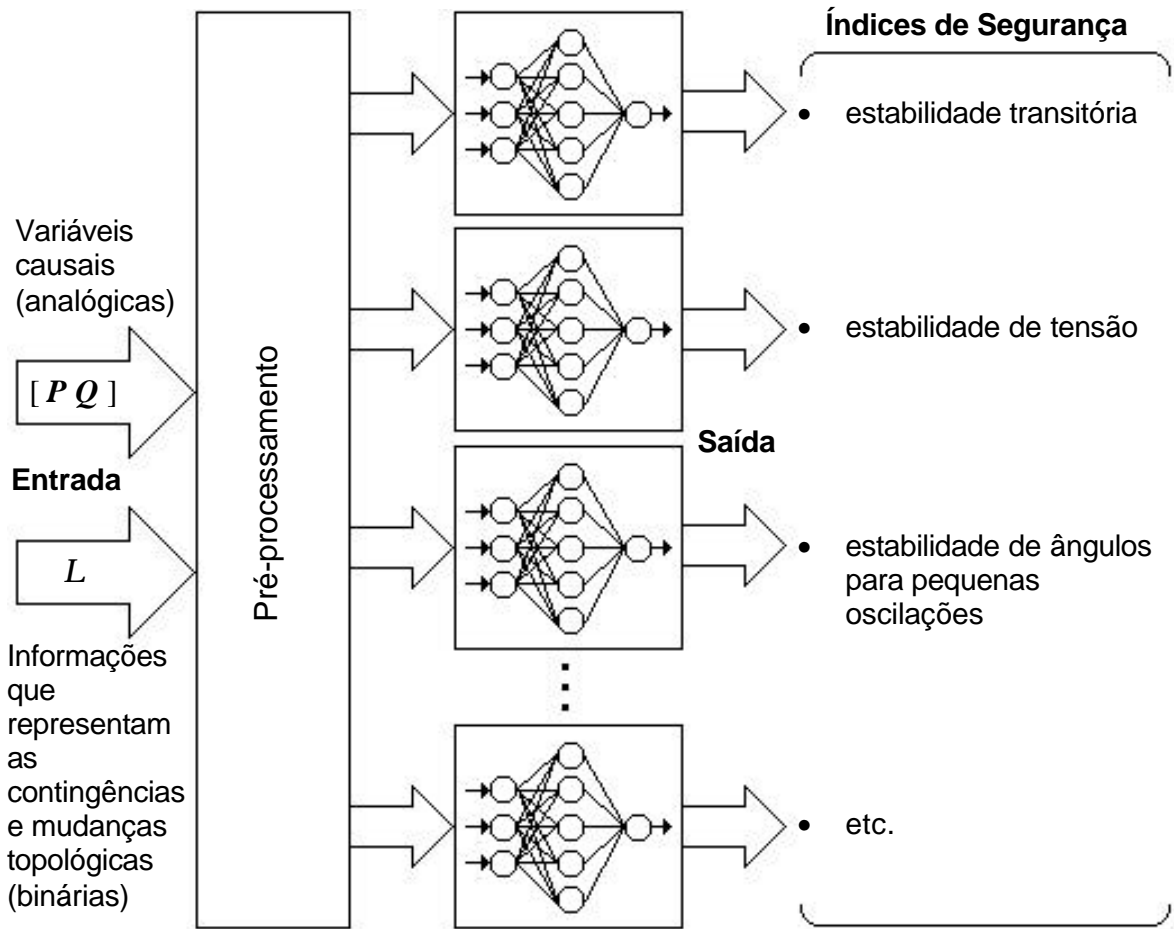


Figura 26. Rede neural para a análise de segurança de sistemas de energia elétrica baseada na geração de índices de segurança.

Esta concepção de rede neural pode ser idealizada como mostra a Figura 27, cujos dados (analógicos e binários) são tratados separadamente, sendo que os dados analógicos são “processados” por uma rede neural não-supervisionada e por um módulo conversor.



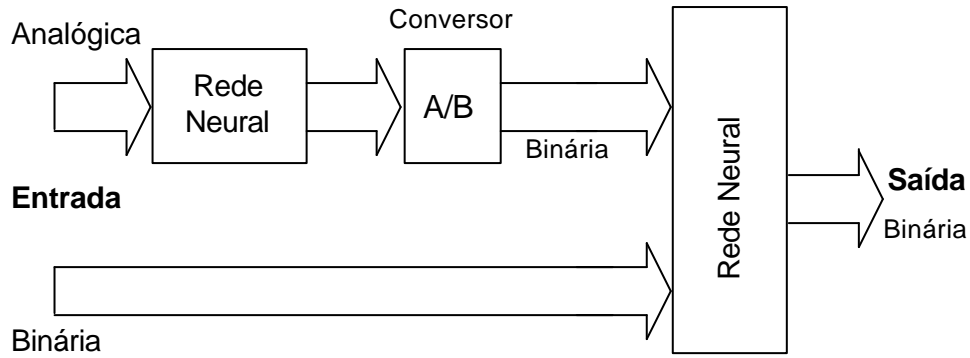


Figura 27. Rede neural para a análise de segurança de sistemas de energia elétrica baseada na geração de índices de segurança.

## 6.5. DEFINIÇÃO DO PERFIL DE GERAÇÃO E DE CARGA

Para a realização do treinamento – extração do conhecimento baseado em estímulos de entrada e de saída – deve-se proceder a apresentação de um conjunto de dados, no nosso caso,  $e = [a \ L]$  (entrada) e  $I$  (saída), constituindo um conjunto de pares de treinamento. Assim, nesta pesquisa é adotado o procedimento proposto na referência [64]. Trata-se da geração dos vetores  $P$  e  $Q$ , para a geração e para a carga do sistema por um procedimento de distribuição aleatória (ou pseudo-aleatória) da geração (despacho pseudo-aleatório para atender a demanda) e, também, de distribuição pseudo-aleatória da carga (demanda pseudo-aleatória), como mostrado a seguir.

Considere que um sistema com uma determinada topologia contendo um número de barras  $NB$ , sendo que  $NG$  são barras de geração e as demais são barras de carga ( $NL = NB - NG$ ). Considere, ainda, que se deseja realizar o despacho de geração para atender uma demanda variável tomando-se como referência o caso base:  $PG^0$ ,  $QG^0$ ,  $PL^0$  e  $QL^0$ , sendo:

$PG^0$  = vetor de potência ativa dos geradores do caso base;

$QG^0$  = vetor de potência reativa dos geradores do caso base;

$PL^0$  = vetor de potência ativa das cargas do caso base;

$QL^0$  = vetor de potência reativa das cargas do caso base.

Para se gerar um grande espectro de variação de demanda, o critério a ser usado refere-se distribuí-la pseudo-aleatoriamente, tomando-se variações percentuais da carga e da geração em torno do caso base (100%). Por exemplo, arbitrando-se um aumento percentual de 10%, pode-se realizar vários perfis de geração e de carga, realizando-se despachos de geração e definição da carga do sistema, distribuindo-se a geração e a carga de forma pseudo-aleatória nas barras do sistema, respeitando-se o percentual arbitrado. Com este procedimento, pode-se gerar perfis de geração e de carga entre, por exemplo, 80% e 120% do caso base.

Os vetores referentes às potências ativas e reativas das barra de geração podem ser definidos por [64]:

$$PG_i = PG_i^0 + PG_{total}^0 PERAG_i / HG \quad (6.5.1)$$

$$i \in \hat{W}(G)$$

$$QG_i = QG_i^0 + QG_{total}^0 PERAG_i / HG \quad (6.5.2)$$

$$i \in \hat{W}(G)$$

sendo:

$PG_i^0$  = potência ativa do gerador no caso 100%;

$QG_i^0$  = potência reativa do gerador no caso 100%;

$PG_i$  = potência ativa no  $i$ -ésimo gerador fixada pseudo-aleatoriamente;

$QG_i$  = potência reativa no  $i$ -ésimo gerador fixada pseudo-aleatoriamente;

$$PG_{total}^0 = \sum_{i \in \hat{W}(G)} PG_i^0;$$

$$QG_{total}^0 = \sum_{i \in \hat{W}(G)} QG_i^0;$$

$\hat{W}(G)$  = conjunto de barras de geração;

$PER$  = percentual de variação da demanda (valores positivos e negativos: por exemplo,  $PER = \pm 10\%$  correspondem a 90 e 110% do caso base, respectivamente);

$AG_i$  = número aleatório de uma seqüência de  $NG$  números gerados a partir de uma semente dada. Variando-se a semente, ter-se-á uma seqüência diferente de valores, cujo espectro de variação está compreendido entre 0 e 1:  $AG_i \in [0,1]$  ;

$$AG_{total} = \sum_{i \in \mathbf{W}(G)} AG_i ;$$

$$HG = 100 AG_{total} .$$

Com relação às cargas, os perfis de variação (curva variável de demanda) podem ser, então, obtidos por:

$$PL_i = PL_i^0 + PL_{total}^0 PER AL_i / HL \quad (6.5.3)$$

$$QL_i = QL_i^0 + QL_{total}^0 PER AL_i / HL \quad (6.5.4)$$

sendo:

$PL_i$  = potência ativa na  $i$ -ésima carga fixada pseudo-aleatoriamente;

$QL_i$  = potência reativa na  $i$ -ésima carga fixada pseudo-aleatoriamente;

$$PL_{total}^0 = \sum_{i \in \mathbf{W}(L)} PL_i^0 ;$$

$$QL_{total}^0 = \sum_{i \in \mathbf{W}(L)} QL_i^0 ;$$

$AL_i$  = número aleatório de uma seqüência de  $NL$  números gerados a partir de uma semente dada,  $AL_i \in [0,1]$  ;

$$HL = 100 AL_{total} ;$$

$$AL_{total} = \sum_{i \in \mathbf{W}(L)} AL_i ;$$

$\mathbf{W}(L)$  = conjunto de barras de carga.

## 6.6. CONCLUSÃO

Neste capítulo foi formulado o problema da análise de segurança de sistemas de energia elétrica por redes neurais. Foi desenvolvido um modelo para estabelecer a relação entre os estímulos de entrada e de saída e as variáveis constituintes dos mesmos. Pela definição do perfil de geração e de carga foi desenvolvida uma estratégia que gerou um conjunto de estímulos através da variação da demanda e conseqüentemente atendimento pelas unidades geradoras. Esta estratégia é usada para o planejamento de dados para a fase de treinamento da rede neural.

## CAPÍTULO 7

### REDE NEURAL PROPOSTA

#### 7.1. INTRODUÇÃO

A rede neural ARTMAP é uma arquitetura em que o treinamento é realizado de modo supervisionado. Destina-se à aproximação de funções não-lineares multidimensionais. Este esquema é adequado para a resolução de uma série de problemas complexos, por exemplo, em sistemas elétricos de potência: análise de segurança, análise de estabilidade transitória, previsão de carga, etc. A importância do emprego deste sistema deve-se às características de estabilidade e plasticidade, além de oferecer respostas bastante rápidas (em consequência do treinamento ser executado de forma rápida). Porém, as redes neurais da família ART apresentam algumas dificuldades operacionais: razoável sensibilidade aos parâmetros da rede (parâmetro de vigilância, etc.) e a ocorrência de possíveis predições falsas. Os efeitos da sensibilidade paramétrica têm sido resolvidos, ou atenuados, através do emprego de novas concepções de treinamento e de arquitetura das redes neurais ART [11]–[16]. Igualmente, várias propostas têm sido apresentadas na literatura especializada visando sanar o problema de imprecisão. Grande parte da imprecisão decorre, principalmente, do mecanismo de escolha de categorias e do teste de vigilância que necessita de aperfeiçoamento.

Assim sendo, nesta pesquisa é proposto um sistema neural, cujo objetivo é resolver, ou pelo menos, reduzir a imprecisão dos resultados da análise, através de um mecanismo que busque usar, separadamente, os dados analógicos e os dados binários. Este esquema é baseado no uso de um módulo ART nebuloso, que recebe os dados analógicos, produzindo na saída as informações características das redes ART que são os códigos ativos (discriminação das categorias). Estas categorias são processadas e transformadas em informações binárias que são agregadas às demais informações associadas ao problema, compondo o vetor de entrada do módulo ARTMAP. A saída da rede neural ARTMAP,

também, é binária. A formulação baseada na entrada e saída binárias confere à rede neural ARTMAP maior precisão e o uso de uma arquitetura modular (ART e ARTMAP) proporciona uma maior rapidez, se comparada somente ao emprego da rede neural ARTMAP (neste caso, os dados de entrada são binários e analógicos). Ressalta-se que esta concepção preserva a característica de plasticidade que, sem dúvida, é uma das principais qualidades das redes ART. Isto permite a implementação do treinamento continuado, constituindo um importante recurso no contexto da operação de sistemas elétricos de potência. Ressalta-se, ainda, que estes dois módulos (ART e ARTMAP) correspondem à formulação alternativa nebulosa [15]. Completando a oferta de possíveis recursos da rede neural ART&ARTMAP nebulosa, é acrescido um módulo ART nebuloso em operação paralela à rede neural ARTMAP nebulosa com vista à realização de treinamento não-supervisionado. Trata-se de mais uma alternativa, visto que em muitas aplicações estão disponíveis apenas as informações de entrada, ou seja, são as redes neurais que se auto-organizam a partir de estímulos aplicados na entrada.

## 7.2. REDE NEURAL ART&ARTMAP NEBULOSA

Na Figura 28 é mostrada a rede neural ART&ARTMAP nebulosa. Observa-se que a entrada do módulo ART corresponde ao vetor  $\mathbf{a}^{an}$  (analógico). Esta rede é não-supervisionada, ou seja, o treinamento é realizado usando somente os dados de entrada. A saída é fornecida contendo as classes (códigos ativos) associados aos padrões de entrada. Por meio de um módulo de processamento, estas classes são convertidas em um conjunto de dados binários  $\mathbf{Z}^{bin}$ . Os demais dados analógicos ( $\mathbf{L}^{an}$ ) são convertidos em dados binários ( $\mathbf{L}^{bin}$ ). Este vetor é agregado ao vetor  $\mathbf{Z}^{bin}$ , compondo a entrada do módulo ARTMAP. A saída, para fins do treinamento e de testes, é processada e transformada em dados binários. Os índices  $p, j$  e  $k$  (acrescido o índice  $q$  para o caso de treinamento não-supervisionado) e seus respectivos vetores indicam as atividades de cada módulo ART. Os blocos processadores são assim designados porque, além da conversão analógica/binária, realizam o processamento das informações. Por exemplo, na análise de estabilidade transitória de sistemas de energia elétrica, os dados de saída da rede, o vetor  $\mathbf{b}^{an}$  pode corresponder à margem de segurança [46], [47], [51], a qual é transformada em intervalo

convenientemente definido e, posteriormente, é efetuada a binarização para formar o vetor  $b^{bin}$  [46].

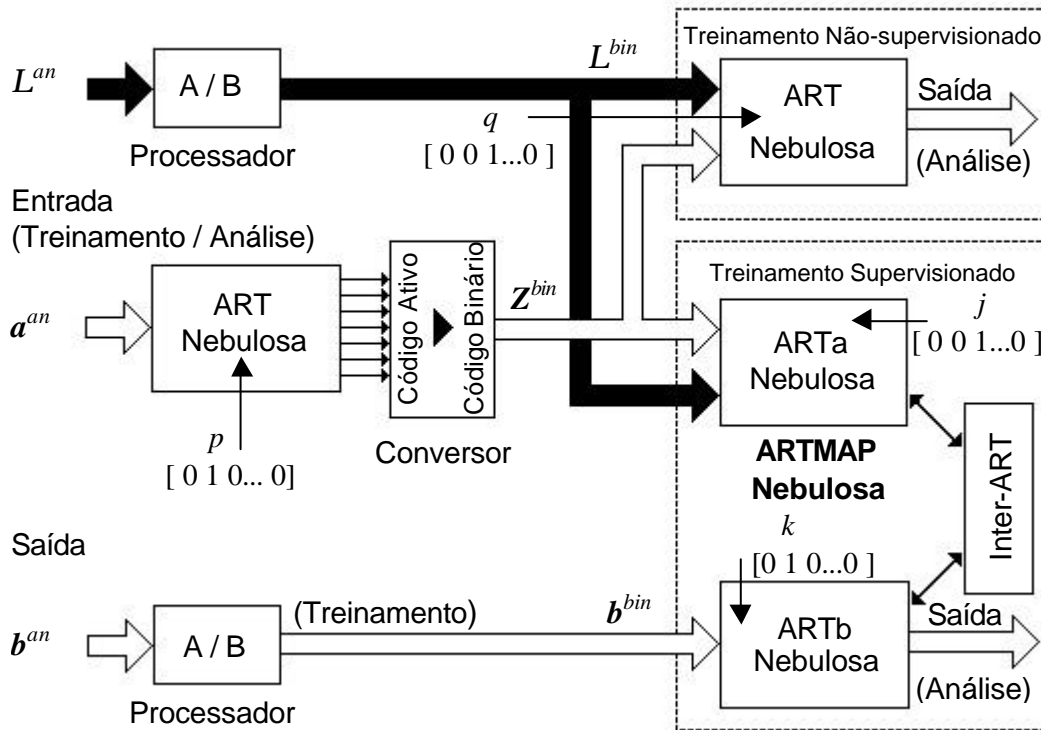


Figura 28. Rede neural ART&ARTMAP nebulosa supervisionada e não-supervisionada.

O conversor código ativo  $\rightarrow$  código binário poderá desempenhar uma função ainda mais complexa e especializada, através de uma formulação incluindo-se, por exemplo, conceitos eugênicos [22] com o propósito de tornar o sistema neural proposto ainda mais eficiente, principalmente com relação à precisão dos resultados, reduzindo o máximo a ocorrência de previsões falsas. Neste caso, deve-se formular os modelos englobando, a princípio, o módulo ART e o conversor (código ativo  $\rightarrow$  código binário). Este assunto deverá ser abordado em outras oportunidades uma vez que é uma das sugestões para trabalhos futuros.

Acrescenta-se ao sistema neural a possibilidade da realização do treinamento não-supervisionado, que é executado pelo módulo ART nebuloso alocado em paralelo com a rede ARTMAP nebulosa. Esta opção visa ampliar a capacidade de realização da rede neural. Deve-se destacar que a alternativa do treinamento não-supervisionado, conseqüentemente da análise (auto-organizável), não pode ser realizada tomando-se a saída

do módulo  $ART_a$  da rede neural ARTMAP, visto que a auto-organização, em  $ART_a$ , é comandada pelo mecanismo *match tracking* que confirma ou rejeita o “casamento” entre a entrada e a saída. Esta operação é responsável pela construção do mapeamento entre entrada e saída:  $X(\text{entrada}) \rightarrow Y(\text{saída}) = f(X)$ ,  $X \hat{I} \hat{A}^n$  e  $Y \hat{I} \hat{A}^m$ , sendo  $f(\cdot)$  a função não-linear desconhecida a ser identificada. Daí decorre o fato de se utilizar a rede neural ART nebulosa alocada paralelamente à rede ARTMAP para a realização do treinamento/análise de modo não-supervisionado, caso o usuário assim desejar.

### 7.3. CONCLUSÃO

Neste capítulo foi apresentada a rede neural ART&ARTMAP nebulosa, a qual é a proposta do trabalho, oriunda da família ART e, portanto, apresentando também as mesmas características de estabilidade e plasticidade. Foi ilustrado seu esquema básico para treinamento não-supervisionado (utilização somente de estímulos de entrada) e supervisionado (utilização de estímulos de entrada e de saída).



## CAPÍTULO 8

### APLICAÇÕES

#### 8.1. INTRODUÇÃO

Neste capítulo são apresentados e discutidos os resultados da aplicação da metodologia proposta (rede neural ART&ARTMAP nebulosa) para a análise de segurança de sistemas elétricos de potência. É abordada a análise de estabilidade transitória de sistemas de energia elétrica [23]. Ainda que o objetivo principal desta pesquisa seja a resolução de problemas no contexto de sistemas de energia elétrica, outros problemas, considerando-se outras áreas do conhecimento humano, são tratados e discutidos, como possíveis de serem resolvidos usando-se a rede neural proposta. Busca-se, neste caso, evidenciar as possíveis aplicações e encaminhamento de soluções da rede neural ART&ARTMAP nebulosa, visto que esta arquitetura está sendo direcionada para o trabalho com conjuntos de dados analógicos e binários – que é o caso de um grande número de problemas – sendo, internamente, processados de forma separada com vistas a contornar questões inerentes às possíveis confusões decorrentes da mistura de tais dados. Todos os dados analógicos são processados (por uma rede neural ART nebulosa e por um módulo conversor) e transformados em dados binários juntando-se, finalmente, como os demais dados binários para compor um problema exclusivamente de informações binárias, tanto na entrada como na saída da rede neural. O resultado esperado é obter um incremento de qualidade (redução do tempo de execução do treinamento/análise e maior precisão), em comparação às principais redes neurais disponíveis. Como ilustração, pode-se destacar o caso de uma imagem digital de um rosto sendo possível extrair, a partir de técnicas adequadas (por exemplo via redes neurais da família ART), uma série de informações referentes ao estado da pessoa como: tristeza, alegria, apreensão, etc. Estas informações podem ser perfeitamente extraídas como forma alternativa à representação analógica. As vantagens do emprego da forma binária tem sido exaustivamente abordada no meio científico, dispensando, por conseguinte de demais argumentações. É, portanto, com esta perspectiva que são enfocadas as aplicações neste trabalho.

Um exemplo considerando-se um sistema composto por 3 máquinas síncronas (Figura 32) [3] foi apresentado na referência [23]. Trata-se de um estudo preliminar que serviu para testar a eficiência da rede neural ART&ARTMAP nebulosa. Este exemplo é mostrado neste capítulo. A seguir, apresentam-se os resultados obtidos através do método proposto (rede neural ART&ARTMAP nebulosa), considerando-se um sistema de maior porte composto por 10 máquinas síncronas, 45 barras e 72 linhas de transmissão como mostrado na Figura 33. Este sistema corresponde a uma possível configuração do sistema sul-brasileiro. São apresentados, então, os resultados obtidos pela rede neural proposta e comparados com resultados produzidos por simulação (metodologia híbrida: método PEBS iterativo [24], que é um referencial em termos de precisão, considerando-se o modelo clássico). Nestes estudos consideram-se faltas tipo curto-circuito trifásico com tempo de eliminação (*t<sub>ch</sub>*) igual a 9 ciclos (0,15s) com saída de linha de transmissão.

O treinamento da rede é realizado usando-se um conjunto de perfis de geração e de carga e respectivas margens de segurança associadas a um conjunto de contingências. Cada perfil corresponde a um despacho de geração, em relação ao caso base (arbitrado como sendo 100%), realizado de forma pseudo-aleatória para atender a demanda, também estabelecida randômica ou pseudo-randomicamente em cada barra do sistema. O universo de variação da geração e da carga está compreendido entre 80 e 130% em relação ao caso base do sistema. Cada perfil é gerado considerando uma variação percentual em torno do estado nominal (caso base) e uma determinada semente para o processo de geração da seqüência randômica. Assim, para um mesmo percentual, diferentes sementes geram diferentes despachos de geração e diferentes perfis de carga. Este procedimento gera um conjunto adequado de padrões para a fase de treinamento. A análise comparativa entre os resultados obtidos por redes neurais e por simulação híbrida [24] é satisfatória. São considerados diferentes perfis de geração de cargas (obtidos com diferentes percentuais e diferentes sementes), se comparados aos dados usados na fase de treinamento.

## **8.2. ANÁLISE DE ESTABILIDADE TRANSITÓRIA**

Dentre os métodos mais conhecidos e consagrados na literatura para análise de estabilidade em sistemas de energia elétrica destacam-se o primeiro e o segundo Método de Lyapunov [42], análise de Autovalores [42] e Análise de Autovetores [42]. Nesta

pesquisa a análise de estabilidade será abordada através de Redes Neurais Artificiais, mais precisamente Redes Neurais da Família ART (ART&ARTMAP).

O problema da análise de estabilidade transitória, conforme estabelecido na seção 6.3, consiste no uso de dados de entrada compostos pelo vetor [64]:

$$e = [ a \ L ] \quad (8.2.1)$$

sendo:

$e$  = vetor padrão de entrada da rede neural;

$L$  = vetor contendo as informações referentes às contingências (codificação binária);

$a$  = vetor padrão de entrada da rede neural referente às informações analógicas;

$$\underline{\Delta} [ P \ Q ];$$

$$P = [ P_1 \ P_2 \ \dots \ P_n ];$$

$$Q = [ Q_1 \ Q_2 \ \dots \ Q_n ];$$

$P_i$  = potência ativa da  $i$ -ésima barra do sistema;

$Q_i$  = potência reativa da  $i$ -ésima barra do sistema;

$n$  = número de barras do sistema.

O vetor  $L$  é formado por informações referentes às contingências (codificação binária). Para fins dos propósitos desta pesquisa, este vetor pode conter informações das contingências e da topologia da rede elétrica:

- (1) curto-circuito com saída de operação de linha de transmissão;
- (2) chaveamento de linhas de transmissão;
- (3) etc.

Na saída da rede neural é usada a variável  $IMS$  (intervalo da margem de segurança) [64].

Com o propósito de estabelecer estes intervalos, usa-se o conceito de *Esforço de Deslocamento da Margem de Segurança* [51]. O esforço de deslocamento da margem de segurança é definido como sendo uma função que relaciona as margens de segurança inicial e final de um determinado intervalo:

$$J = (I - M^A) / (I - M^B) - 1 \quad (8.2.2)$$

sendo:

$J$  = esforço de deslocamento da margem de segurança;

$M^A$  = valor da margem de segurança inicial do intervalo;

$M^B$  = valor da margem de segurança final do intervalo.

A equação (8.2.2) representa uma equação de diferenças da forma [64]:

$$M(k+1) = g M(k) + h \quad (8.2.3)$$

sendo:

$g \triangleq 1 / (1 + J_{esp})$ ;

$h = 1 - g$ ;

$J_{esp}$  = valor de  $J$  especificado de acordo com o critério estabelecido.

A equação (8.2.3) é obtida a partir de (8.2.2) via substituição de  $M^A$  e  $M^B$  por  $M(k)$  e  $M(k+1)$ , respectivamente. Fazendo-se a variação do tempo discreto  $k$  entre 0 e  $\infty$ , obtém-se uma curva discreta compreendida entre o valor inicial da margem de segurança  $M(0)$  (valor de partida) e a margem de segurança final  $M(\infty) = 1$ .

Deste modo, o intervalo, em termos do conceito de margem de segurança, pode ser definido como [46], [64]:

$$IMS(k) \triangleq \{M_{inferior}(k), M_{superior}(k)\} \quad (8.2.4)$$

para  $k = 1, 2, 3, \dots, NI$

sendo:

$IMS(k)$  =  $k$ -ésimo intervalo da margem de segurança;

$NI$  = número de intervalos das  $IMS$ 's.

As equações de  $M_{superior}(k)$  e  $M_{inferior}(k)$  podem ser expressas por [64]:

$$M_{superior}(k) = 1 - n_s \exp(-fk) \quad (8.2.5)$$

$$M_{inferior}(k) = 1 - n_i \exp(fk). \quad (8.2.6)$$

sendo:

$$n_s = 1 - g M(0) - h;$$

$$n_i = \{1 - M(0)\} / (1 + J_{esp});$$

$$f = -\ln(1 + J_{esp});$$

$\ln$  = logaritmo neperiano.

A concepção utilizada neste trabalho para definir os intervalos associados às contingências é mostrada na Tabela 7, considerando-se  $J_{esp} = 0,35$  (binarização com 4 bits) e os valores da margem de segurança compreendidos em  $(-3, 1)$ , ou seja,  $M(0) = -3$ .

O número de intervalos  $NI$  determina o número de *bits* necessários para a representação dos valores da saída da rede neural. Por exemplo, se desejarmos  $NI$  entre 8 e 15, serão necessários 4 *bits*.

Atribui-se  $-\infty$  a  $M_{inferior}(I)$ , apenas para constar, visto que em situações práticas são raras as condições operativas do sistema que representem margem de segurança inferior a  $-10$ . Contingências com margens de segurança inferiores a  $-3$  e superiores a  $0,9$  podem ser consideradas *muito instáveis* e *muito estáveis*, respectivamente [64]. Na Figura30 ilustra-se a distribuição dos intervalos da margem de segurança. Deve-se observar que o conjunto central composto por  $(NI-2)$  *IMS's* corresponde à situação mais plausível de ocorrência. *IMS(1)* e *IMS(NI)* indicam contingências muito instáveis e muito estáveis, respectivamente.




Figura 30. Representação das *IMS's* no intervalo  $(-\infty, 1]$ .

A relação entre o número do intervalo  $k$  da margem de segurança  $IMS$  e o parâmetro  $J$  (esforço de deslocamento da margem de segurança) pode ser obtida como mostrado a seguir. Tomando-se dois valores discretos de  $M_{superior}(k)$  dado pela equação (8.2.5):

$$M_{superior}(1) = 1 - n_s \exp(\mathbf{f}) = M(0) \quad (8.2.7)$$

$$M_{superior}(k) = 1 - n_s \exp(\mathbf{f} k) \quad (8.2.8)$$

Tabela 7. Intervalos da margem de segurança: representação em 4 bits,  $M(0) = -3$  e  $J_{esp} = 0,35$ .

Número do Intervalo	Intervalo da Margem de Segurança ( $IMS$ )
1	$\leq -3$
2	$(-3 ; -1,9630]$
3	$(-1,9630 ; -1,1948]$
4	$(-1,1948 ; -0,6258]$
5	$(-0,6258 ; -0,2043]$
6	$(-0,2043 ; 0,10790]$
7	$(0,10790 ; 0,33920]$
8	$(0,33920 ; 0,51050]$
9	$(0,51050 ; 0,63740]$
10	$(0,63740 ; 0,73140]$
11	$(0,73140 ; 0,80110]$
12	$(0,80110 ; 0,85260]$
13	$(0,85260 ; 0,89080]$
14	$(0,89080 ; 0,91910]$
15	$\geq 0,91910$




Figura 31. Gráfico de  $IMS$  e de  $M$  considerando a margem de segurança  $\in (-\infty, 1]$ ,  $J_{esp} = 0,35$  e  $M(0) = -3$ .

### 8.3. ANÁLISE DE SEGURANÇA DE UM SISTEMA DE TRÊS BARRAS

Apresentam-se, a seguir, os resultados obtidos, através do método proposto, considerando-se um sistema composto por 3 máquinas síncronas [3] como mostrado na Figura 32. Os dados das máquinas síncronas, da carga e do sistema de transmissão encontram-se nas Tabelas 8, 9 e 10 respectivamente. Trata-se de um sistema de pequeno porte, contudo será usado para demonstrar a validade de metodologia proposta e o encorajamento para aplicações, considerando-se sistemas de energia elétrica reais de grande porte.

Nestes estudos consideram-se faltas de curto-circuito com tempo de eliminação igual a 9 ciclos (0,15s) com saída de linha de transmissão. Os valores em pu referem-se a uma base de 100MVA.

Tabela 8. Dados das máquinas síncronas.

Máquina Síncrona	Potência Mecânica (pu)	Reatâncias		$H(s)$
		$x_d$ (pu)	$x'_d$ (pu)	
1	Referência	0,1460	0,0608	9,552
2	1,63	0,8958	0,1198	3,333
3	0,85	1,3125	0,1813	2,352

Tabela 9. Dados das cargas.

Potência Elétrica (pu)	Barra de Carga		
	5	6	8
Ativa	1,25	0,90	1,00
Reativa	0,50	0,30	0,35

Tabela 10. Dados do sistema de transmissão.

Elemento do Sistema de Transmissão				
No.	Nó Inicial	Nó Final	Impedância série (pu)	Susceptância <i>Shunt</i> (pu)
1	1	4	$0,0000 + j 0,0570$	0
2	4	5	$0,0100 + j 0,0850$	$j 0,0880$
3	4	6	$0,0170 + j 0,0920$	$j 0,0790$
4	5	7	$0,0320 + j 0,1610$	$j 0,1530$
5	6	9	$0,0390 + j 0,1700$	$j 0,1790$
6	2	7	$0,0000 + j 0,6250$	0
7	7	8	$0,0080 + j 0,0720$	$j 0,7450$
8	8	9	$0,0120 + j 0,1008$	$j 0,1045$
9	3	9	$0,0000 + j 0,5860$	0



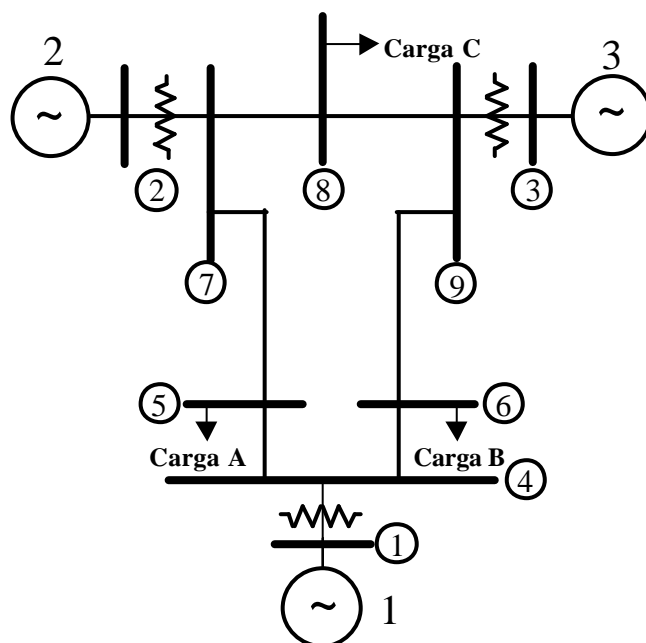


Figura 32. Sistema de energia elétrica composto por 3 máquinas síncronas.

Tabela 11. Relação de contingências.

No. Falta	Falta		
	Curto-circuito Barra	Saída do Circuito	
		Barra Inicial	Barra Final
1	4	4	5
2	4	4	6
3	5	5	7
4	5	4	5
5	6	6	9
6	6	4	6
7	7	5	7
8	7	7	8
9	8	7	9
10	8	8	9

Tabela 12. Resultados da análise de estabilidade transitória obtidos por simulação (resultados de referência) e pela rede neural ART&ARTMAP nebulosa.

No. Falta	Perfil Geração / Carga		Intervalo da Margem de Segurança ( <i>IMS</i> )	
	Percentual	Semente	Método PEBS	Rede Neural
1	87,5	067	13	13
2	87,5	067	14	14
3	87,5	067	11	11
4	87,5	067	13	13
5	87,5	067	12	13
6	87,5	067	15	15
7	87,5	067	7	7
8	87,5	067	7	7
9	87,5	067	10	9
10	87,5	067	11	11
1	92,5	567	11	11
2	92,5	567	12	12
3	92,5	567	9	9
4	92,5	567	11	11
5	92,5	567	11	11
6	92,5	567	14	15
7	92,5	567	5	5
8	92,5	567	5	5
9	92,5	567	8	8
10	92,5	567	9	9
1	97,5	668	10	11
2	97,5	668	11	12
3	97,5	668	8	8
4	97,5	668	11	11
5	97,5	668	10	10
6	97,5	668	13	13

Tabela 12. (Continuação).

No. Falta	Perfil Geração / Carga		Intervalo da Margem de Segurança (IMS)	
	Percentual	Semente	Método PEBS	Rede Neural
7	97,5	668	5	5
8	97,5	668	5	5
9	97,5	668	8	8
10	97,5	668	9	9
1	102,5	270	9	9
2	102,5	270	10	10
3	102,5	270	7	7
4	102,5	270	10	10
5	102,5	270	9	9
6	102,5	270	12	12
7	102,5	270	4	4
8	102,5	270	4	4
9	102,5	270	7	7
10	102,5	270	8	8

O conjunto de contingências adotado encontra-se descrito na Tabela 11. Trata-se das contingências mais importantes para o sistema sob estudo. O treinamento da rede neural foi realizado considerando-se um conjunto de 486 perfis de geração e de carga e respectivas margens de segurança. Cada perfil corresponde a um redespacho de geração em relação ao caso base realizado de forma pseudo-aleatória para atender a demanda, também, fixada de modo pseudo-aleatório em cada barra. O universo de variação da carga encontra-se compreendido entre 80 e 120% ( $\pm 20\%$ ) em relação à carga nominal total do sistema. Portanto, cada perfil é gerado considerando-se um percentual de variação em torno do estado nominal (caso base) e determinada semente para o processo de geração de seqüências pseudo-aleatórias. Assim, para um mesmo percentual, diferentes sementes poderão gerar diferentes despachos de geração de diferentes perfis de carga. Este procedimento gera um conjunto adequado de padrões para a fase de treinamento.

Realizado o treinamento da rede neural, os testes (análise de estabilidade transitória) podem ser efetivados, cujos resultados são mostrados na Tabela 12. Trata-se da análise comparativa entre os resultados obtidos via programa de simulação híbrida (Simul) e via redes neurais (procedimento proposto). São considerados 40 perfis de geração/carga distintos (diferentes percentuais e diferentes sementes) dos perfis utilizados no treinamento, fixados, igualmente, de forma pseudo-aleatória. O percentual e a semente usados nas análises encontram-se indicados nas colunas 2 e 3 da Tabela 12, respectivamente. A região (intervalo *IMS*) indicada pela rede neural ARTMAP nebulosa (quinta coluna da Tabela 12) corresponde ao resultado obtido via estratégia de votação [15], ou seja, a rede neural é executada diversas vezes com diferentes ordenações para o mesmo conjunto de treinamento. A predição final é dada pelas soluções geradas com maior frequência.

Pode-se observar que os resultados produzidos pelas duas metodologias são bastante próximos.

## 8.4. ANÁLISE DE SEGURANÇA DO SISTEMA SUL-BRASILEIRO

A seguir procede-se a análise de estabilidade transitória de um sistema de energia elétrica, cujo diagrama unifilar (Figura 33) corresponde a uma possível configuração do sistema da região sul do Brasil. Os dados deste sistema encontram-se relacionados no Apêndice A.

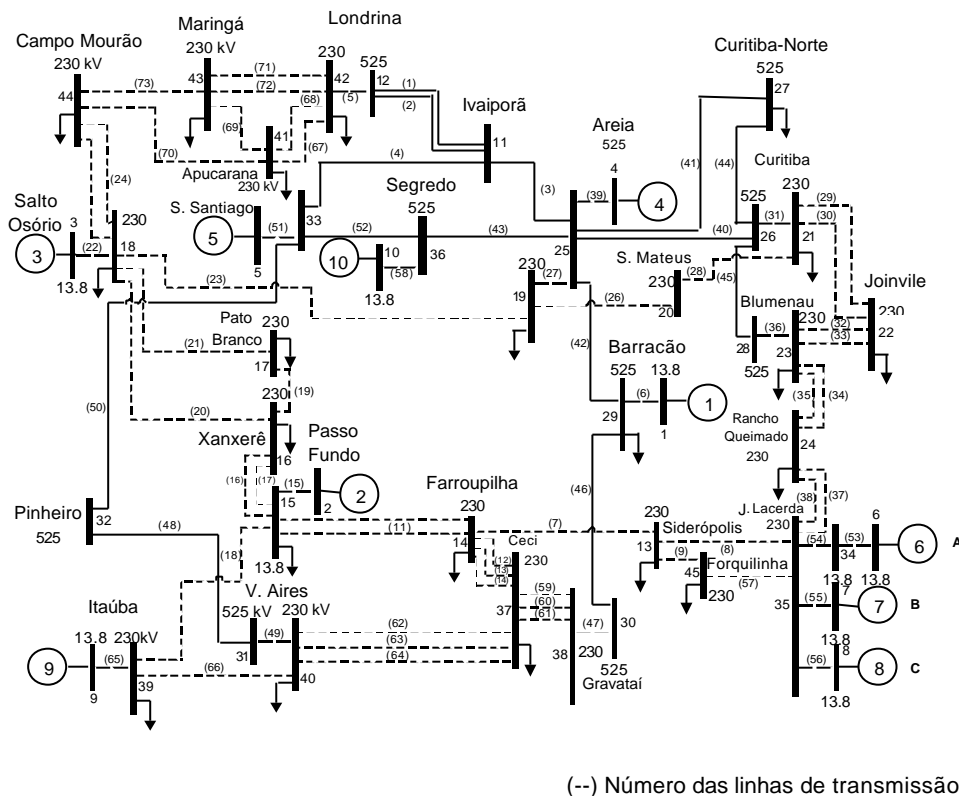


Figura 33. Diagrama unifilar do sistema elétrico de potência.

O conjunto de contingências é mostrado na Tabela 13. São consideradas 10 contingências (escolhidas arbitrariamente) visando ilustrar a metodologia proposta. Entretanto, este número pode ser aumentado, de acordo com as necessidades do usuário, sem nenhum problema quanto à sua formulação. Os intervalos da margem de segurança (*IMS's*) correspondem aos dados contidos na Tabela 7, adotando-se uma representação por 4 bits, ou seja, com  $J_{esp} = 0,35$  totalizando 15 intervalos.

O treinamento da rede neural é realizado considerando um conjunto em torno de 1817 perfis (em média 180 por contingência) de geração e de carga e as margens de segurança correspondentes (para as 10 contingências).

Tabela 13. Conjunto de contingências.

No. da Falta	Falta		
	Barra sob Curto-Circuito	Saída de Circuito	
		Barra Inicial	Barra Final
1	15	15	16
2	16	15	16
3	16	16	18
4	17	16	17
5	17	17	18
6	33	33	36
7	35	13	35
8	44	18	44
9	44	41	44
10	44	43	44

Na Tabela 14 são apresentados os parâmetros usados para a fase de treinamento da rede neural ART&ARTMAP nebulosa.

Tabela 14. Especificação dos parâmetros da rede neural.

Item	Módulo	Valor
Parâmetro de vigilância	ART	0,995
Parâmetro de vigilância	ARTa	0,9
Parâmetro de vigilância	ARTb	0,95
Parâmetro de vigilância	Inter-ART	0,9
Taxa de Treinamento	ART, ARTa, ARTb e Inter-ART	1
Parâmetro de escolha	ART, ARTa, e ARTb	0,1

O ajuste dos parâmetros da rede se deu da seguinte maneira: O parâmetro de escolha,  $\alpha$ , foi escolhido pequeno por recomendação dos autores de artigos já consagrados. O parâmetro taxa de treinamento,  $\beta$ , foi ajustado em 1 para se utilizar o treinamento rápido. O parâmetro de vigilância,  $\rho_a$ , na rede neural ARTMAP é fixado pela concepção adotada, ou seja, a saída (margem de segurança) binarizada através de 15 classes, com isso fica estabelecida a separação de classes. O parâmetro de vigilância  $\rho_b$ , da rede neural ARTMAP quem determina é a própria rede na fase de treinamento através do mecanismo *reset/match tracking*. O parâmetro de vigilância,  $\rho$ , da rede neural ART foi arbitrado considerando-se exaustivas tentativas. Uma melhor sintonia poderá ser obtida a partir de resultados de simulação.

Após a realização da fase de treinamento, a análise de estabilidade transitória pode ser realizada, cujos resultados são mostrados na Tabela 15. Trata-se da análise comparativa entre redes neurais (método proposto) e o método híbrido [24] (considerado neste trabalho como valores corretos). Os percentuais e as sementes usadas são mostrados nas colunas 2 e 3 da Tabela 15, respectivamente. Os intervalos *IMS's*, indicados pela rede neural ART&ARTMAP nebulosa, correspondem ao emprego da *estratégia de votação* [15], ou seja, a rede neural é treinada por várias vezes (por exemplo, 5 vezes), com diferentes ordenações (ordenações pseudo-randômicas) para o mesmo conjunto de dados do treinamento. A predição final é dada pela maior frequência das soluções geradas. Pode-se observar que os resultados produzidos pelas duas metodologias são bastantes próximos.

Tabela 15. Resultados da análise de estabilidade transitória obtidos por simulação (resultados de referência) e pela rede neural ART&ARTMAP nebulosa.

No. da Falta	Perfil de Geração e de Carga		Intervalo da Margem da Segurança ( <i>IMS</i> )	
	% do caso base	Semente	Método PEBS	Rede Neural ART&ARTMAP
1	130,0	403	5	5
1	122,5	333	8	8
1	122,5	603	9	10
1	120,0	79	7	7
1	120,0	38	10	10

Tabela 15. (Continuação).

No. da Falta	Perfil de Geração e de Carga		Intervalo da Margem da Segurança (IMS)	
	% do caso base	Semente	Método PEBS	Rede Neural ART&ARTMAP
1	117,5	819	8	8
1	112,5	383	9	9
1	107,5	309	11	11
1	102,5	381	11	11
1	97,5	78	13	13
1	97,5	103	13	13
1	90,0	597	15	15
2	130,0	121	9	9
2	115,0	421	11	11
2	112,5	383	13	13
2	107,5	899	12	13
2	102,5	109	13	13
2	95,0	391	13	13
2	92,5	171	14	14
2	90,0	597	12	12
2	90,0	711	13	13
3	130,0	220	7	8
3	130,0	3	8	8
3	125,0	913	5	5
3	117,5	251	10	10
3	112,5	360	12	13
3	112,5	383	12	12



Tabela 15. (Continuação)

No. da Falta	Perfil de Geração e de Carga		Intervalo da Margem da Segurança (IMS)	
	% do caso base	Semente	Método PEBS	Rede Neural ART&ARTMAP
3	105,0	371	13	13
3	105,0	719	11	11
3	95,0	497	13	13
3	90,0	597	11	11
4	127,5	288	13	13
4	125,0	380	10	9
4	120,0	38	9	9
4	117,5	163	13	13
4	115,0	131	10	10
4	115,0	421	13	13
4	112,5	383	12	12
4	107,5	899	12	12
4	105,0	931	11	12
4	102,5	96	12	12
5	122,5	240	11	11
5	120,0	611	11	11
5	117,5	805	12	12
5	112,5	360	11	11
5	112,5	71	10	10
5	107,5	599	12	12
5	107,5	899	11	11
5	95,0	123	13	13

Tabela 15. (Continuação).

No. da Falta	Perfil de Geração e de Carga		Intervalo da Margem da Segurança (IMS)	
	% do caso base	Semente	Método PEBS	Rede Neural ART&ARTMAP
5	92,5	453	12	12
6	127,5	77	9	9
6	122,5	333	11	11
6	120,0	38	9	9
6	115,0	303	10	10
6	112,5	71	9	9
6	92,5	637	11	11
7	130,0	3	1	1
7	107,5	191	9	9
7	107,5	599	8	7
7	105,0	931	9	9
7	102,5	393	10	10
7	100,0	507	12	12
7	95,0	321	15	15
7	90,0	711	14	14
8	130,0	121	8	8
8	130,0	3	8	8
8	125,0	951	7	8
8	125,0	913	12	12
8	117,5	515	10	10
8	117,5	819	12	12
8	112,5	500	11	11

Tabela 15. (Continuação).

No. da Falta	Perfil de Geração e de Carga		Intervalo da Margem da Segurança (IMS)	
	% do caso base	Semente	Método PEBS	Rede Neural ART&ARTMAP
8	95,0	391	13	13
8	95,0	497	14	14
8	92,5	453	13	13
9	130,0	121	9	8
9	122,5	867	11	11
9	120,0	270	13	13
9	110,0	51	13	13
9	105,0	371	14	14
9	97,5	103	14	14
9	90,0	791	15	15
9	90,0	458	14	14
10	102,5	96	15	14
10	92,5	453	15	15

Considerando-se os resultados apresentados anteriormente, podem-se observar os seguintes pontos:

- (1) A carga total do sistema correspondente ao caso base (100% do carregamento do sistema) é de 6.655 MW;
- (2) Assim, a geração e a carga correspondem a um espectro de variação entre 5.324 MW e 8.651,5 MW;
- (3) O treinamento da rede neural foi realizado, para as 10 contingências, tomando-se aproximadamente 1800 pares de vetores padrões (entrada e saída), em torno de 30s (3s por contingência). Não está sendo incluído o tempo destinado para a leitura e impressão das informações;

- (4) Na Tabela 15 constam 84 análises de estabilidade transitórias, considerando-se as mesmas contingências usadas na fase de treinamento, porém, com distribuição de geração e de carga diferentes realizada de modo pseudo-aleatório, buscando, simular possíveis casos reais da operação. Se o treinamento estiver adequadamente realizado, a análise de casos reais, a princípio, deverá ser confiável;
- (5) A análise é realizada, por um microcomputador de 500 MHz e 128 MB de memória RAM, em torno de 0,25 s para os 84 casos apresentados na Tabela 15.

## 8.5. OUTRAS APLICAÇÕES

Será destacada, aqui, uma série de possíveis problemas que poderão ser resolvidos pela rede neural ART&ARTMAP nebulosa, alguns problemas estão inseridos no contexto de sistemas de energia elétrica. Neste sentido, pode-se focar, por exemplo, questões relacionadas com a estabilidade de tensão [78]. Neste caso, há uma grande oferta de referências disponíveis na literatura [9], [18], [62], [63], [75], entre outras.

Outros problemas abrangem uma grande variedade de casos que estão em evidência no meio científico, alguns, um tanto visionários mas que servem de inspiração e oportunidade para aguçar o instinto humano para as coisas associadas à criatividade:

- (1) em sistemas elétricos de potência a rede neural ART&ARTMAP nebulosa pode, salvo melhor julgamento, ser empregada para a resolução, além dos problemas abordados neste trabalho:
  - (a) controle (por exemplo, de frequência e de tensão);
  - (b) proteção;
  - (c) análise de formas de ondas, combinando redes neurais e técnicas como por exemplo, a teoria de *wavelets* ;
  - (d) otimização não-linear no auxílio da busca de pontos ótimos globais para emprego numa grande variedade de problemas que envolvem otimização: despacho econômico, planejamento, etc;

- (e) previsão de cargas elétricas. Neste sentido, destaca-se a pesquisa que está sendo desenvolvida associada à referência [45], cujo objetivo é desenvolver um sistema previsional multinodal para aplicações, principalmente, em sistemas de distribuição. Neste tipo de problema é necessário dispor-se de uma técnica rápida e evidentemente com precisão satisfatória. Neste caso, a rede neural ART&ARTMAP nebulosa se apresenta como uma candidata em potencial;
  - (f) testes de circuitos e dispositivos elétricos e eletrônicos;
  - (g) desenvolvimento de sensores;
  - (h) etc.
- (2) robótica, principalmente para o desenvolvimento de mecanismo de treinamento para a realização de tarefas de forma autônoma. Aquisição e interpretação dos dados sensoriais para robôs móveis;
  - (3) monitorização e diagnóstico de falhas de sistemas (sistemas elétricos, mecânicos, etc);
  - (4) sistemas biológicos: problemas associados ao genoma estrutural e funcional, etc;
  - (5) atividades ligadas ao trabalho com textos: organização, gerenciamento, agrupamento, etc;
  - (6) auxílio na determinação da originalidade de concepções para fins de registros de patentes;
  - (7) filtragem de conteúdos no ambiente da rede mundial de computadores (*Internet*);
  - (8) previsões meteorológicas: temporais, terremotos, avalanches de neve, etc;
  - (9) processos industriais: controle de qualidade de produtos, instalações;
  - (10) reconhecimento de padrão para as mais variadas aplicações: médicas, industriais, etc;
  - (11) *data mining*, em especial com relação ao cliente com vista ao descobrimento de hábitos, tendências, classes, etc;
  - (12) processamento de sinais para as mais variadas aplicações;
  - (13) processamento de sons;
  - (14) sistemas de segurança: identificação da presença de intrusos;
  - (15) identificação de conteúdo de inovação de produtos, processos, etc;

- (16) aplicações militares: auxílio e identificação de alvos, reconhecimento;
- (17) aerofotogrametria: análise de solo, floresta, etc;
- (18) astronomia: auxílio no reconhecimento e identificação de corpos celestes;
- (19) segurança: identificação de possíveis fontes de sinistro: fogo, etc;
- (20) análise de imagens e sinais, principalmente para fins médicos: eletrocardiograma, encefalograma, ressonância magnética, radiologia, etc;
- (21) reconhecimento de escritas: caracteres, ideogramas, assinaturas, etc;
- (22) meio ambiente: detecção de mudanças e avaliação de danos ambientais;
- (23) matemática: aproximação de funções desconhecidas quaisquer;
- (24) análise de estruturas de materiais;
- (25) técnica auxiliar para o desenvolvimento de outras redes neurais, por exemplo, na determinação do número de neurônios na rede neural RBF (*Radial Base functions*) que é uma rotina crucial neste tipo de sistema neural;
- (26) sistemas computacionais avançados, especialmente quando se combina com outras técnicas disponíveis: lógica nebulosa, computação evolutiva, computação quântica, sistemas imunes artificiais, etc, compondo os chamados sistemas híbridos;
- (27) reconhecimento de códigos postais;
- (28) identificação e discriminação de odores para as mais variadas aplicações;
- (29) análise de sinais de radares;
- (30) visão artificial;
- (31) *Novelty Detection* (ND) que é um conceito semelhante à detecção de anomalias, porém, a diferença é que a ND se refere ao descobrimento de novos eventos que aparecem no ambiente que se está abordando, ou seja, não é detectar anomalias e sim algo que é novidade. Tratam-se de identificações importantes, pois, na maioria das vezes, estes eventos são causadores de danos consideráveis (prejuízos materiais, ataque à integridade pessoal, etc). A antecipação é a grande aliada para prevenir a ocorrência de sinistros, ou, pelo menos, minimizar as suas conseqüências. Neste contexto, há uma vasta gama de situações a ser explorada, por exemplo, pode-se desenvolver sistemas de identificação de intrusos (sistemas de segurança), usando-se

para o treinamento somente os dados associados aos não-intrusos, excetuando-se estes, qualquer evento é considerado como novidade (ou intruso). Esta idealização pode, a princípio, ser realizada explorando o conceito do mecanismo *match tracking* nas redes da família ART supervisionadas (ARTMAP, ART&ARTMAP, etc);

(32) outras aplicações.

Enfim, estas são algumas das aplicações possíveis de serem resolvidas pela rede neural proposta, é lógico que tais aplicações não são realizadas sem a devida lapidação. Certamente, são necessários estudos apurados sobre o comportamento de cada problema. Deve-se estabelecer o conjunto de dados a ser usados (entrada e saída para a fase de treinamento), entre outros cuidados que devem ser observados, porém, entende-se ser passíveis de resolução com o uso da rede neural ART&ARTMAP nebulosa ou outra configuração derivada dela com as possíveis inclusões de novos dispositivos e inovações.

## **8.6. CONCLUSÃO**

Neste capítulo foram apresentados e discutidos os resultados da aplicação da metodologia proposta (Rede Neural ART&ARTMAP nebulosa) para a análise de segurança de sistemas elétricos de potência, mais precisamente em análise de estabilidade transitória. Nessas aplicações foram obtidos resultados considerando-se dois sistemas. Primeiramente, um sistema composto por 3 máquinas síncronas [3]. Depois, um sistema composto por 10 máquinas síncronas, 45 barras e 72 linhas de transmissão, uma possível configuração do sistema sul-brasileiro. Os resultados para os dois testes foram comparados com resultados produzidos por simulação (metodologia híbrida: método PEBS iterativo, que é um referencial em termos de precisão, considerando-se o modelo clássico). Foram apresentados também possíveis problemas que podem ser resolvidos dentro e fora do contexto de sistemas de energia elétrica.

## CAPÍTULO 9

### CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

#### 9.1. CONCLUSÕES

Neste trabalho de pesquisa foi desenvolvida uma metodologia de análise de segurança de sistemas elétricos de potência por redes neurais. Redes neurais são estruturas que adquirem o conhecimento, sobre um determinado processo (controle, análise, reconhecimento de padrão, etc.), baseado na experiência através da aplicação de estímulos adequadamente estabelecidos na entrada e na saída (treinamento supervisionado) ou somente na entrada (treinamento não-supervisionado). Portanto, esta extração do conhecimento é de responsabilidade da rotina de treinamento. Uma vez realizado o treinamento (que demanda maior parcela do tempo de processamento), a rede encontra-se habilitada para realizar diagnósticos complexos praticamente sem custo computacional o que é bastante adequada para aplicações *on-line*. Então, é com esta perspectiva que foi desenvolvido um sistema para a análise de segurança, formulado a partir de um modelo que estabelece, de forma otimizada, as relações entre entrada e saída da rede neural, ou seja, realiza o mapeamento de funções não-lineares (multientradas e multisaídas) desconhecidas. Neste modelo foi considerado um número mínimo possível de variáveis de entrada compostas pelos vetores de potências ativas e reativas nodais (variáveis causais básicas) e pelos dados referentes às contingências e topologia da rede elétrica. As variáveis de saída correspondem a um índice de inferência (margem de segurança, para o caso da análise de estabilidade transitória, autovalor mínimo na análise de estabilidade de tensão, etc.).

Visando proporcionar a análise com precisão satisfatória, com um menor tempo de execução possível, foi proposta uma nova arquitetura de rede neural designada ART&ARTMAP nebulosa. Trata-se de uma composição que utiliza três módulos neurais ART nebulosos, sendo dois deles constituindo a conhecida rede neural ARTMAP



nebulosa. A primeira rede neural ART emprega na entrada os dados correspondentes às potências ativa e reativa nodais (dados analógicos). A saída deste módulo é representada por códigos ativos (que é inerente às redes ART) sendo convertida em código binário por conversor código ativo  $\rightarrow$  código binário. Forma-se, portanto, um conjunto de dados binários (saída do módulo ART acrescida das variáveis representativas das contingências e topologia da rede elétrica) que constitui a entrada do módulo ARTMAP nebuloso. A saída também é estabelecida por representação binária. Assim, a rede neural ARTMAP nebulosa trabalha essencialmente com informações binárias. As redes neurais ART possuem como característica primordial a plasticidade e a estabilidade, as quais são qualidades essenciais para a execução do treinamento e para a análise de modo eficiente. A rede neural ART&ARTMAP nebulosa está sendo proposta visando proporcionar um desempenho superior, em termos de precisão e rapidez, se comparada à formulação ARTMAP convencional. Desempenho este ainda maior quando comparada ao emprego de redes neurais com treinamento realizado, por exemplo, via rede neural *feedforward* com treinamento usando a técnica retropropagação [79].

Deve-se ressaltar que a rede neural ART&ARTMAP nebulosa é uma nova arquitetura que está sendo proposta para a resolução do problema da análise de segurança. Contudo, ela pode ser empregada para resolver um grande número de problemas, em destaque, na previsão de carga como está sendo abordada na referência [45] que trata do desenvolvimento de um sistema previsor multinodal. Outra característica importante a ser considerada é a preservação da plasticidade da rede neural ART&ARTMAP nebulosa o que possibilita o desenvolvimento de metodologias de análise de segurança com treinamento continuado. Pode-se, então, desenvolver esquemas eficientes para a inclusão na “memória”, de forma seletiva, através de informações coletadas na operação, padrões que venham contribuir (com grande potencial) para o aperfeiçoamento do treinamento e, como consequência, ter-se-á um sistema de análise que proporcione melhores soluções com o passar do tempo. Pode-se pensar igualmente no desenvolvimento de estudos de soluções que busquem relacionar dados da análise, por exemplo, da estabilidade transitória associada ao modelo clássico [3], [5], [57], [59], [60], que são facilmente disponibilizados, com dados gerados considerando-se modelos mais elaborados, por exemplo o modelo completo de Park. Esta correlação pode ser estabelecida através do uso de técnicas baseadas em meta-análise. Com isto, poder-se-ia analisar a estabilidade transitória mais realisticamente sem necessidade de grandes investimentos na geração de dados para a fase

de treinamento com modelos mais sofisticados, justamente nos casos em que ainda não se dispõe de índices de inferência com a mesma generosidade como ocorre com o modelo clássico.

Neste trabalho foi elaborado um teste com o uso da rede neural ART&ARTMAP nebulosa que corresponde a análise de estabilidade transitória, considerando-se, primeiramente um sistema composto por 3 máquinas síncronas e, posteriormente, um sistema multimáquinas (10 máquinas síncronas, 45 barras e 72 linhas de transmissão). Considerando-se os resultados já realizados, pode-se concluir que a rede neural proposta apresenta um excelente desempenho (boa precisão com tempo de processamento reduzidíssimo), se comparada a outras redes neurais disponíveis na literatura. Esta tem sido a grande motivação para o trato com as redes neurais da família ART e continuar com as pesquisas neste sentido. É importante ressaltar que a teoria da ressonância adaptativa [16] foi apresentada em uma concepção original (os fundamentos básicos) permitindo a incorporação de inovações [2], [12], [28]. Portanto, é uma concepção completamente flexível o que, a princípio, há sempre a possibilidade de proposições mais eficientes, especialmente, no que se refere à precisão.

## 9.2. SUGESTÕES PARA TRABALHOS FUTUROS

Os resultados desta pesquisa podem ser considerados satisfatórios (do ponto de vista da precisão e rapidez na obtenção das soluções), conforme argumentado anteriormente. Porém, sugerem-se algumas melhorias e procedimentos que podem ser implementados com o propósito de tornar a análise, através da rede neural ART&ARTMAP nebulosa, ainda mais eficiente:

- 1) introduzir novos dispositivos e procedimentos à rede neural desenvolvida, visando a melhoria das soluções. Por exemplo, incluir novos mecanismos para geração de classes e a sintonia (*match tracking*) entre a entrada e a saída da rede neural, empregar técnicas estocásticas em que se determinam probabilidades das inferências, ou seja, a informação de que uma determinada contingência possui a probabilidade  $p$  de estar contida no intervalo  $IMS$  que é uma forma interessante de abordagem;

- 2) desenvolver estratégias de implementação do treinamento continuado;
- 3) aperfeiçoar o mecanismo código ativo/código binário, por exemplo, contemplar melhorias de agrupamento de classes usando-se conceitos eugênicos;
- 4) aplicação da rede neural ART&ARMAP nebulosa que considere outros índices de segurança, por exemplo, relativos à estabilidade de tensão;
- 5) empregar a rede neural ART&ARTMAP nebulosa para o diagnóstico da estabilidade transitória para modelos mais elaborados do que o modelo clássico, *e.g.*, o modelo completo de Park [3];
- 6) desenvolvimento de um sistema neural para previsão (baseado na arquitetura ART&ARTMAP nebulosa) de cargas elétricas multinodais para aplicações em sistemas de distribuição de energia elétrica;
- 7) explorar outras aplicações, tendo como sugestão os eventos listados na Seção 8.5, em destaque a previsão de cargas elétricas, detecção de novidades, robótica, análise de sinais, monitorização e diagnóstico de falhas de sistemas, sistemas biológicos: problemas associados ao genoma estrutural e funcional que são, a princípio, alguns dos problemas que podem ser resolvidos pela rede neural proposta.

## REFERÊNCIAS

- [1] Aggarwal, R. K.; Xuan, Q. Y.; Johns, A. T.; Li, F. and Bennett, A. “A Novel Approach to Fault Diagnosis in Multicircuit Transmission Lines Using Fuzzy ARTMAP Neural Networks”, *IEEE Transactions on Neural Networks*, Vol.10, No.5, 1999, pp.1214-1221.
- [2] Anagnostopoulos, G. C. and Geordiopoulos, M. “Category Regions as New Geometrical Concepts in Fuzzy-ART And Fuzzy-ARTMAP”, *Neural Networks*, No.15, 2002, pp.1205-1221.
- [3] Anderson, P.M. and Fouad, A.A. “Power System Control and Stability”, *IEEE Series on Power Engineering*, USA, Second Edition, 2003.
- [4] Assadi, H.; Tan, A.; Etezadi-Amoli, M.; Egbert, D. and Fadali, M. S. “Application of The ARTMAP Neural Network to Power System Stability Studies”, *IEEE International Conference on Systems, Man and Cybernetics*, Vol.2, 1992, pp.1080-1085.
- [5] Athay, T.; Sherket, V. R.; Podmore, R.; Virmani, S. and Puech, C. “Transient Energy Stability Analysis”, *Conference on 'System Engineering For Power'*, Davos, Switzerland, 1979.
- [6] Azuaje, F.; Castro, L. N. and Timmis, J. “Artificial Immune Systems: A New Computational Intelligence Approach”, *Neural Networks*, Corrected Proof, Available online, 8 April, 2003.
- [7] Bartfai, G. “An Improved Learning Algorithm For The Fuzzy ARTMAP Neural Network”, *IEEE, Artificial Neural Networks and Expert Systems, Proceedings*, New Zealand, 1995, pp.34-37.

- [8] Blume, M. and Esener, S. C. "An Efficient Mapping of Fuzzy ART Onto a Neural Architecture", *Neural Networks*, Vol.10, No.3, 1997, pp.409-411.
- [9] Bose, A. and Tomsovic, K. "Automated Operating Procedures For Transfer Limits", *Final Report, PSERC Publication 01-05*, May 2001.
- [10] Cantin, M. A.; Braquiere, Y.; Savaria, Y.; Lavoie, P. and Grander, E. "Analysis of Quantization Effects in a Digital Hardware Implementation of a ART Neural Network Algorithm", *IEEE International Symposium on Circuits and Systems*, Geneva, Switzerland, 2000, pp.28-31.
- [11] Carpenter, G. A.; Gopal, S.; Macomber, S.; Martins, S. and Woodcock, C. E. "A Neural Network Method For Mixture Estimation For Vegetation Mapping", *Elsevier, Remote Sensing Environment*, Vol.70, No.3, December 1999, pp.326-338.
- [12] Carpenter, G. A. "Neural-Network Models of Learning And Memory : Leading Questions And an Emerging Framework", *Trends in Cognitive Sciences*, Vol.5, Issue.3, March 2001, pp.114-118.
- [13] Carpenter, G. A. and Grossberg, S. "A Self-Organizing Neural Network For Supervised Learning, Recognition And Prediction", *IEEE Communications Magazine*, 1992, pp.38-49.
- [14] Carpenter, G. A.; Milenova, B. L. and Noeske, B. W. "Distributed ARTMAP: A Neural Network For Fast Distributed Supervised Learning", *Neural Networks*, Vol.11, No.5, July 1998, pp.793-813.

- [15] Carpenter, G. A.; Grossberg, S.; Markuzon, N.; Reynolds, J. H. and Rosen, D. B. “Fuzzy ARTMAP: A Neural Network Architecture For Incremental Supervised Learning of Analog Multidimensional Maps”, *IEEE Transactions on Neural Networks*, Vol.3, No.5, 1992, pp.698-713.
- [16] Carpenter, G. A. and Grossberg, S. “Pattern Recognition by Self-Organizing Neural Networks”, *The MIT Press*, Cambridge, Massachusetts, USA, 1991.
- [17] Chee, P. L.; Harrison, R. F. and Kennedy, R. L. “Application of Autonomous Neural Network Systems to Medical Pattern Classification Task”, *Artificial Intelligence in Medicine*, Vol.11, No.3, 1997, pp.215-239.
- [18] Chen, K.; Hussein, A. and Wan, H-B. “ On a Classes of New And Practical Performance Indexes For Approximation of Fold Bifurcations of Nonlinear Power Flow Equations”, *Journal of Computational and Applied Mathematics*, No.140, 2002, pp.119–141.
- [19] Dagher, I.; Georgiopoulos, M.; Heileman, G. L. and Bebis, G. “Fuzzy ARTVar : An Improved Fuzzy ARTMAP Algorithm”, *IEEE International Joint Conference on*, Vol.3, 1998, pp.1688-1693.
- [20] Dasgupta, D. “Artificial Neural Networks And Artificial Immune Systems : Similarities And Differences”, *IEEE International Conference on Computational Cybernetics and Simulation*, Vol.1, Oct 1997, pp.873–878.
- [21] Dasgupta, D. and Forrest, S. “Artificial Immune Systems in Industrial Applications” *IPMM '99, Intelligent Processing and Manufacturing of Materials, Proceedings of the Second International Conference on* , Vol.1, Jul 1999, pp.257-267.
- [22] Eiben, A. E. and Schoenauer, M. “Evolutionary Computing”, *Information Processing Letters*, Vol.82, Issue 1, 15 April 2002, pp.1-6.
- [23] Ferreira, W.P.; Silveira, M.C.G.; Lotufo, A.D.P. e Minussi, C. R. “Análise de Estabilidade Transitória de Sistemas de Energia Elétrica Por Rede Neural Baseada na

- Teoria da Ressonância Adaptativa”, *5<sup>th</sup> Latin American Congress on Electricity, Generation and Transmission*, São Pedro-SP, Novembro-2003. (Artigo B-135).
- [24] Fonseca, L. G. S. and Decker, I. C. “Iterative Algorithm For Critical Energy Determination in Transient Stability of Power System”, *IFAC - Symposium Planning and Operation in Electric Energy System*, Rio de Janeiro-RJ, Brazil, 1985, pp.483–489.
- [25] Fouad, A. A. and Vittal, V. “Power System Transient Stability Analysis Using The Transient Energy Function Method”, *Prentice-Hall*, Englewood Cliffs, New Jersey, 1992.
- [26] Freitas Filho, W. “Controle de Segurança Dinâmica de Sistemas de Energia Elétrica Via Análise de Sensibilidade de Redes Neurais”, *Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Elétrica – UNESP*, Ilha Solteira-SP, Dezembro, 1996.
- [27] Georgiopoulos, M.; Fernlund, H.; Bebis, G. and Heileman, G. L. “Order of Search in Fuzzy ART And Fuzzy ARTMAP: Effect of The Choice Parameter”, *Neural Networks*, Vol.9, No.9, 1996, pp.1541-1559.
- [28] Granger, E.; Rubin, M. A.; Grossberg, S. and Lavoie, P. “A What-And-Where Fusion Neural Network For Recognition And Tracking of Multiple Radar Emitters”, *Neural Networks*, No.14, 2001, pp.325-344.
- [29] Gupta, S. and Zia, R. K. P. “Quantum Neural Networks”, *Journal of Computer and System Sciences*, Vol.63, Issue 3, November 2001, pp.355-383.
- [30] Hanzálek, Z. “A Parallel Algorithm For Gradient Training of Feedforward Neural Networks”, *Elsevier, Parallel Computing*, 1998, pp.823-829.
- [31] Haykin, S. “Neural Networks : A Comprehensive Foundation”, *Prentice-Hall*, Upper Saddle River, New Jersey, USA, 1994.

- [32] Hirvensalo, M. "Computing With Quanta - Impacts of Quantum Theory on Computation", *Theoretical Computer Science*, Vol.287, Issue 1, 25 September 2002, pp.267-298.
- [33] Jain, A. K. and Mao, J. "Artificial Neural Networks : A Tutorial", *IEEE, Computer*, March 1996, pp.31-44.
- [34] Jiriwibhakorn, S.; Coonick, A. H. and Cory, B. J. "Fast Critical Clearing Time Function Approximation Using Neural Networks And Sobol Sequences", *IEEE Power Engineering Review*, 2000, pp.51-53.
- [35] Kalogirou, S. A. "Applications of Artificial Neural Networks For Energy Systems", *Elsevier, Applied Energy*, Vol.67, 2000, pp.17-35.
- [36] Kartalopoulos, S. V. "Understanding Neural Networks And Fuzzy Logic", *IEEE Press*, New York, 1996.
- [37] Kennedy, J.; Shi, Y. and Eberhart, R. C. "Swarm Intelligence", *Morgan Kaufman*, USA, 2001.
- [38] Keyvan, S.; Song, X. and Kelly, M. "Nuclear Fuel Pellet Inspection Using Artificial Neural Networks", *Journal of Nuclear Materials*, Vol.264, No.1-2, 1999, pp.141-154.
- [39] King, R. L. "Artificial Neural Networks And Computational Intelligence", *IEEE Computer Application in Power*, 1998, pp.14-29.
- [40] King, R. L.; Russ, S. H.; Lambert, A. B. and Reese, D. S. "An Artificial Immune System Model For Intelligent Agents", *Future Generation Computer Systems*, Vol.17, Issue 4, January 2001, pp.335-343.
- [41] Koufakou, A.; Georgiopoulos, M.; Anagnostopoulos, G. and Kasparis, T. "Cross-Validation in Fuzzy ARTMAP For Large Databases", *Neural Network*, Vol.14, 2001, pp.1279-1291.



- [42] Kundur, P. “Power System Stability And Control”, *McGraw-Hill*, New York, 1994.
- [43] Kung, S. Y. “Digital Neural Networks”, *PTR Prentice-Hall*, Englewood Cliffs, New Jersey, USA, 1993.
- [44] Llobet, E.; Hines, E. L.; Gardner, J. W.; Bartlett, P. N. and Mottram, T. T. “Fuzzy ARTMAP based Electronic Nose Data Analysis”, *Sensors and Actuators B : Chemical*, Vol.61, No.1-3, 1999, pp.183-190.
- [45] Lopes, M. L. M. “Desenvolvimento de Uma Rede Neural Para Previsão de Cargas em Sistemas de Distribuição de Energia Elétrica”, Projeto de Tese de Doutorado / Bolsa de Doutorado FAPESP Proc. No. 00/15120-1, *Programa de Pós-graduação em Engenharia Elétrica, UNESP – Campus de Ilha Solteira-SP*, 2001-2005.
- [46] Marchiori, S. C. “Estabilidade Transitória de Sistemas de Energia Elétrica : Uma Metodologia de Análise Via Rede Neural ARTMAP Nebulosa”, *Dissertação de Mestrado, Programa de pós-graduação em Engenharia Elétrica, UNESP, Campus de Ilha Solteira, Ilha Solteira – SP*, Agosto 2001.
- [47] Marchiori, S. C.; Minussi, C. R. e Lotufo, A. D. P. “Rede Neural ARTMAP Nebulosa Para Análise de Estabilidade Transitória de Sistemas de Energia Elétrica”, *Learning and Nonlinear Models*, Vol.1, No.1, 2002, pp.61-78.
- [48] McNeil, F. M. and Thro, E. “Fuzzy Logic a Practical Approach”, *Academic Press*, 1994.
- [49] Mendes Filho, E. F. e Carvalho, A. C. P. L. “Tutorial Introdutório Sobre Redes Neurais Artificiais”, *Departamento de Ciências de Computação e Estatística, USP*, Fevereiro 2001.
- [50] Minussi, C. R. “Controle de Segurança Dinâmica em Sistemas de Engenharia Elétrica”, *Tese de Doutorado, Programa de Pós-Graduação em Engenharia Elétrica – UFSC, Florianópolis-SC*, Novembro 1990.

- [51] Minussi, C. R. and Freitas Filho, W. “Sensitivity Analysis For Transient Stability”, *IEE Proceedings on Generation, Transmission and Distribution*, Vol.145, No.6, 1998, pp.669-674.
- [52] Minussi, C. R. and Silveira, M. C. G. “Transient Stability Analysis of Electric Power Systems by Neural Networks”, *38<sup>rd</sup> Midwest Symposium on Circuits and Systems*, Rio de Janeiro–RJ, 1995, pp.1305-1308.
- [53] Monticelli, A. J. “Fluxo de Carga em Redes de Engenharia Elétrica”, *Editora Edgard Blücher Ltda*, São Paulo-SP, 1983.
- [54] Monticelli, A. e Garcia, A. “Introdução a Sistemas de Energia Elétrica”, *Editora da Unicamp*, Imprensa Oficial, 1999.
- [55] Narayanan, A. “An Introductory Tutorial to Quantum Computing - Quantum Computing : Theory, Applications and Implications”, *Digest No. 1997/145, IEE, Colloquium on* , 4 Jun 1997, pp.1-3.
- [56] Ono, O.; Yamamoto, K.; Ymamoto, T. and Mochiduki, I. “Application And Evaluation of DNA Computing Simulation by List Based Processing” *Control Applications, Proceedings of the 2002 International Conference on*, Vol.2, 2002, pp.825-829.
- [57] Pai, M. A. “Power System Stability”, *North Holland Control Series*, 1981.
- [58] Pao, Y. H. and Sobajic, D. J. “Combined Use of Unsupervised And Supervised Learning For Dynamic Security Assessment”, *IEEE PICA-91*, 1991, pp.278-284.
- [59] Pavella, M. “Power System Transient Stability Assessment – Tradicional vs Modern Methods”, *Pergamon, Control Engineering Practice*, Vol.6, 1998, pp.1233-1246.
- [60] Pavella, M.; Ernst, D. A. and Ruiz-Vega, D. “Transient Stability of Power Systems : A Unified Approach to Assessment And Control”, *Kluwer Academic Publishers*, 2000.

- [61] Ramuhalli, P.; Udpa L. and Udpa, S. S. “Use of Reliability Measures to Improve The Performance of Fuzzy ARTMAP Networks”, *Neural Networks, International Joint Conference on*, Vol.6, 1999, pp.4015-4020.
- [62] Seydel, R. “On a Class of Bifurcation Test Functions”, *Chaos, Solitons & Fractals*, Vol.8, No.6, 1997, pp.851–855.
- [63] Sinha, A. K. and Hazarika, D. “A Comparative Study of Voltage Stability Indices in a Power System”, *Electrical Power & Energy Systems*, No.22, 2000, pp.589-596.
- [64] Silveira, M. C. G. “Análise de Estabilidade Transitória de Sistemas de Energia Elétrica Por Redes Neurais ARTMAP Nebulosas Modulares”, Tese de Doutorado, *Programa de Pós-graduação em Engenharia Elétrica*, UNESP - Campus de Ilha Solteira – SP, Outubro-2003.
- [65] Silveira, M. C. G.; Marchiori, S. C.; Ferreira, W. P. e Minussi, C. R. “Análise de Estabilidade Transitória de Sistemas de Energia Elétrica Usando Uma Rede Neural ARTMAP Nebulosa”, *XIV Congresso Brasileiro de Automática*, Natal-RN, 2002, pp.3171-3177.
- [66] Silveira, M. C. G.; Lotufo, A. D. P. and Minussi, C. R. “Transient Stability Analysis of Electrical Power Systems Using a Neural Network Based on Fuzzy ARTMAP”, *IEEE Bologna Power Tech 2003 Conference*, Bologna – Italy, 7p. (To appear), 2003.
- [67] Simpson, P. K. “Artificial Neural Systems: Foundations Paradigms, Applications And Implementations”, *Pergamon Press*, New York, 1989.
- [68] Sobajic, D. J. and Pao, Y. H. “Artificial Neural-Net Based Dynamic Security Assessment For Electric Power Systems”, *IEEE Transactions on Power Systems*, Vol.4, No.1, 1989, pp.220-227.
- [69] Streilein, W. W.; Gaudiano, P. and Carpenter, G. A. “A Neural Network For Object Recognition Through Sonar on a Mobile Robot”, *Proceedings of The IEEE*, 1998, pp.271-276.

- [70] Terano, T.; Asai, K. and Sugeno, M. “Fuzzy System Theory And Its Applications”, *Academic Press*, New York, USA, 1987.
- [71] Tutorial <http://www.icmc.sc.usp.br/~andre/neural1.html>.
- [72] Uhrig, R. E. “Introduction to Artificial Neural Networks”, *IEEE IECON 21st International Conference on*, Vol.1, 1995, pp.33-37.
- [73] Verzi, S. J.; Heileman, G. L.; Georgiopoulos, M. and Hearly, M. J. “Boosted ARTMAP”, *Neural Networks Proceedings - IEEE*, Vol.1, 1998, pp.396-401.
- [74] Vidyasagar, M. “Nonlinear Systems Analysis”, *Prentice-Hall*, Second Edition, 1993.
- [75] Vu, K. T.; Liu, C. C.; Taylor, C. W. and Jimma, K. M. “Voltage Instability : Mechanisms And Control Strategies”, *Proceedings of the IEEE*, November 1995, Vol.83, No.11, pp.1442-1455.
- [76] Wasserman, P. D. “Neural Computing – Theory And Practice”, *Van Nostrand Reinhold*, New York, USA, 1989.
- [77] Watkins, A. and Boggess, L. “A New Classifier Based on Resource Limited Artificial Immune Systems” *Evolutionary Computation, CEC '02, Proceedings of the 2002 Congress on*, Vol.2, 2002, pp.1546–1551.
- [78] Wehenkel, L. “Machine-Learning Approaches to Power-System Security Assessment”, *IEEE Expert Intelligent Systems & Their Applications*, 1997, pp.60-72.
- [79] Werbos, P. J. “Beyond Regression: New Tools For Prediction And Analysis in The Behavioral Sciences”, *Master Thesis, Harvard University*, Cambridge, MA, USA, 1974.
- [80] Widrow, B. and Lehr, M. A. “30 Years of Adaptive Neural Networks: Perceptron, Madaline, And Backpropagation”, *Proceeding of The IEEE*, Vol.78, No.9, 1990, pp.1415-1442.

- [81] Yu, P. and Leung, A. Y. T. “A Perturbation Method For Computing The Simplest Normal Forms of Dynamical Systems”, *Elsevier, Science Direct, Journal of Sound and Vibration*, 2003, pp.123-151.

## APÊNDICE A

### DADOS DO SISTEMA DE ENERGIA ELÉTRICA

A seguir apresentam-se os dados [50] referentes a uma configuração baseada no sistema sul-brasileiro (Figura 33) composto por 10 máquinas síncronas, 45 barras e 73 linhas de transmissão (Tabelas 16, 17 e 18). Os dados referem-se a uma base de 100 MVA.

Tabela 16. Dados de barras do sistema sul-brasileiro (10 máquinas).

Identificação		Tensão		Carga		Geração	
Nº	Nome	Módulo	Ângulo	Ativa (pu)	Reativa (pu)	Ativa (pu)	Reativa (pu)
1	Barracão 13,8	1,020	-11,430	0,000	0,000	6,500	1,007
2	P. Fundo 13,8	1,040	-17,100	0,000	0,000	2,150	1,496
3	S. Osório 13,8	1,020	5,080	0,000	0,000	10,500	2,450
4	F. Areia 13,8	1,022	-6,380	0,000	0,000	11,100	3,377
5	S. Santiago 13,8	1,018	3,290	0,000	0,000	13,250	1,651
6	J. Lacerda A 13,8	1,030	-29,920	0,000	0,000	0,900	0,465
7	J. Lacerda B 13,8	1,030	-28,380	0,000	0,000	1,200	0,548
8	J. Lacerda C 13,8	1,030	-27,020	0,000	0,000	2,410	0,905
9	Itaúba 13,8	1,000	-16,150	0,000	0,000	4,900	1,365
10	Segredo 13,8	1,020	0,000	0,000	0,000	13,640	2,051
11	Ivaiporã 525	1,007	-11,180	0,000	-2,130	0,000	0,000
12	Londrina 525	0,995	-13,510	0,000	0,000	0,000	0,000
13	Siderópolis 230	0,969	-37,470	1,770	0,680	0,000	0,000
14	Farroupilha 230	0,978	-37,240	1,910	0,420	0,000	0,000
15	P. Fundo 230	0,978	-22,680	1,710	0,185	0,000	0,000
16	Xanxerê 230	0,946	-17,990	1,260	0,470	0,000	0,000
17	Pato Branco 230	0,954	-10,870	0,460	0,147	0,000	0,000
18	S. Osório 230	0,999	-1,660	2,810	0,565	0,000	0,000
19	Areia 230	0,978	-15,420	2,790	0,607	0,000	0,000

Tabela 16. (Continuação).

Identificação		Tensão		Carga		Geração	
Nº	Nome	Módulo	Ângulo	Ativa (pu)	Reativa (pu)	Ativa (pu)	Reativa (pu)
20	S. Mateus 230	0,997	-26,600	1,300	-0,706	0,000	0,000
21	Curitiba 230	0,991	-26,760	4,270	-1,250	0,000	0,000
22	Joinville 230	0,952	-33,640	3,100	0,410	0,000	0,000
23	Blumenau 230	0,967	-32,190	4,240	0,094	0,000	0,000
24	R. Queimado 230	0,963	-34,310	1,170	0,531	0,000	0,000
25	Areia 525	1,003	-10,550	0,000	0,000	0,000	0,000
26	Curitiba 525	0,986	-24,330	0,000	-1,447	0,000	0,000
27	Cur. Norte 525	0,988	-22,750	3,680	-0,756	0,000	0,000
28	Blumenau 525	0,968	-30,100	0,000	0,000	0,000	0,000
29	Barracão 525	1,010	-16,350	1,740	-1,138	0,000	0,000
30	Gravataí 525	1,019	-33,630	0,000	-1,596	0,000	0,000
31	V. Aires 525	1,027	-26,790	0,000	-1,603	0,000	0,000
32	Pinheiro 525	1,018	-13,680	0,000	-1,615	0,000	0,000
33	S. Santiago 525	1,010	-5,150	0,000	0,000	0,000	0,000
34	J. Lacerda 138	0,994	-34,310	1,260	0,398	0,000	0,000
35	J. Lacerda 230	0,996	-33,090	0,000	0,000	0,000	0,000
36	Segredo 525	1,010	-5,160	0,000	0,000	0,000	0,000
37	Ceci 230	1,012	-37,550	8,130	1,100	0,000	0,000
38	Gravataí 230	1,026	-36,940	6,120	-4,550	0,000	0,000
39	Itaúba 230	0,975	-22,960	4,040	1,350	0,000	0,000
40	V. Aires 230	1,029	-29,400	3,930	-1,110	0,000	0,000
41	Apucarana 230	0,973	-18,930	2,620	0,132	0,000	0,000
42	Londrina 230	0,989	-15,600	2,290	0,830	0,000	0,000
43	Maringá 230	0,983	-18,900	1,840	-0,398	0,000	0,000
44	C. Mourão 230	0,981	-15,340	1,390	-0,463	0,000	0,000
45	Forquilha 230	0,977	-37,360	0,901	-0,447	0,000	0,000

Tabela 17. Dados do sistema de transmissão.

Nº	Barra de Origem	Barra de Destino	Impedância	
			R(%)	X(%)
1	Ivaiporã 525	Londrina 525	0,07	1,45
2	Ivaiporã 525	Londrina 525	0,07	1,45
3	Ivaiporã 525	Areia 525	0,18	2,27
4	Ivaiporã 525	S. Santiago 525	0,14	2,04
5	Londrina 525	Londrina 230	0,00	0,63
6	Barracão 13,8	Barracão 525	0,00	1,36
7	Siderópolis 230	Farroupilha 230	3,86	19,85
8	Siderópolis 230	J. Lacerda 230	0,96	4,91
9	Siderópolis 230	Forquilha 230	0,33	1,67
10	Farroupilha 230	P. Fundo 230	4,63	23,78
11	Farroupilha 230	P. Fundo 230	4,63	23,78
12	Farroupilha 230	Ceci 230	1,77	9,10
13	Farroupilha 230	Ceci 230	1,77	9,10
14	Farroupilha 230	Ceci 230	1,77	9,10
15	P. Fundo 13,8	P. Fundo 230	0,00	4,60
16	P. Fundo 230	Xanxerê 230	1,63	8,35
17	P. Fundo 230	Xanxerê 230	1,63	8,35
18	P. Fundo 230	Itaúba 230	2,50	15,48
19	Xanxerê 230	P. Branco 230	1,63	8,35
20	Xanxerê 230	S. Osório 230	3,16	16,21
21	P. Branco 230	S. Osório 230	1,53	8,61
22	S. Osório 13,8	S. Osório 230	0,00	1,14
23	S. Osório 230	Areia 230	3,06	15,23
24	S. Osório 230	C. Mourão 230	3,44	17,60
25	S. Osório 230	C. Mourão 230	3,44	17,60
26	Areia 230	S. Mateus 230	2,45	12,56
27	Areia 230	Areia 525	0,00	3,00
28	S. Mateus 230	Curitiba 230	0,88	4,15
29	Curitiba 230	Joinville 230	1,82	9,35
30	Curitiba 230	Joinville 230	1,82	9,35



Tabela 17. (Continuação).

Nº	Barra de Origem	Barra de Destino	Impedância	
			R(%)	X(%)
31	Curitiba 230	Curitiba 525	0,00	0,62
32	Joinville 230	Blumenau 230	1,54	7,76
33	Joinville 230	Blumenau 230	1,54	7,76
34	Blumenau 230	R. Queimado 230	2,16	11,05
35	Blumenau 230	R. Queimado 230	2,16	11,05
36	Blumenau 230	Blumenau 525	0,00	0,62
37	R. Queimado 230	J. Lacerda 230	1,80	9,20
38	R. Queimado 230	J. Lacerda 230	1,80	9,20
39	F. Areia 13,8	Areia 525	0,00	0,67
40	Areia 525	Curitiba 525	0,19	2,80
41	Areia 525	Cur. Norte 425	0,19	2,74
42	Areia 525	Barracão 525	0,14	1,95
43	Areia 525	Segredo 525	0,05	0,70
44	Curitiba 525	Cur. Norte 525	0,05	0,69
45	Curitiba 525	Blumenau 525	0,12	1,75
46	Barracão 525	Gravataí 525	0,21	3,09
47	Gravataí 525	Gravataí 230	0,00	0,62
48	V. Aires 525	Pinheiro 525	0,22	3,00
49	V. Aires 525	V. Aires 230	0,00	0,62
50	Pinheiro 525	S. Santiago 525	0,14	1,95
51	S. Santiago 13,8	S. Santiago 525	0,00	1,14
52	S. Santiago 525	Segredo 525	0,05	0,70
53	J. Lacerda A 13,8	J. Lacerda 13,8	0,00	8,71
54	J. Lacerda 13,8	J. Lacerda 230	0,00	5,90
55	J. Lacerda B 13,8	J. Lacerda 230	0,00	7,01
56	J. Lacerda C 13,8	J. Lacerda 230	0,00	4,50
57	J. Lacerda 230	Forquilha 230	1,29	6,57
58	Segredo 13,8	Segredo 525	0,00	0,68
59	Ceci 230	Gravataí 230	0,22	1,11
60	Ceci 230	Gravataí 230	0,22	1,11

Tabela 17. (Continuação).

Nº	Barra de Origem	Barra de Destino	Impedância	
			R(%)	X(%)
61	Ceci 230	Gravataí 230	0,22	1,11
62	Ceci 230	V. Aires 230	2,07	9,33
63	Ceci 230	V. Aires 230	2,07	9,33
64	Ceci 230	V. Aires 230	2,07	9,33
65	Itaúba 13,8	Itaúba 230	0,00	2,36
66	Itaúba 230	V. Aires 230	2,02	11,29
67	Apucarana 230	Londrina 230	1,25	6,40
68	Apucarana 230	Londrina 230	0,89	4,61
69	Apucarana 230	Maringá 230	1,10	11,84
70	Apucarana 230	C. Mourão 230	2,29	11,74
71	Londrina 230	Maringá 230	1,72	8,84
72	Londrina 230	Maringá 230	1,72	8,84
73	Maringá 230	C. Mourão 230	1,81	9,29

Tabela 18. Dados das máquinas síncronas.

Número da Máquina Síncrona	X'd (%)	H(s)	Potência Mecânica (pu)
1	3,67	30,44	6,50
2	10,37	10,56	2,15
3	2,84	38,34	10,50
4	2,41	62,25	11,10
5	2,43	55,24	13,25
6	13,52	4,37	0,90
7	15,34	6,80	1,20
8	8,00	12,50	2,41
9	4,32	20,24	4,90
10	2,16	62,46	Referência

## APÊNDICE B

### ARTIGOS PUBLICADOS

Neste Apêndice são apresentados os artigos publicados relacionados com a pesquisa de doutorado. Deve-se ressaltar que, em consonância com as exigências do Regulamento do PPGEE (Programa de Pós-graduação em Engenharia Elétrica) da Faculdade de Engenharia de Ilha Solteira – UNESP, Art. 45, Parágrafo único, o doutorando, para fins de defesa de tese, deverá publicar ou ter sido aceito para publicação, no mínimo, dois artigos completos, relacionados com a pesquisa da tese, em periódicos, congressos ou eventos similares que possuem corpo técnico de revisores de competência reconhecida pela comunidade científica.

1. Silveira, M. C. G.; Marchiori, S. C.; **Ferreira, W. P.** e Minussi, C. R. “Análise de Estabilidade Transitória de Sistemas de Energia Elétrica Usando Uma Rede Neural ARTMAP Nebulosa”, *XIV Congresso Brasileiro de Automática (CBA 2002)*, Natal-RN, pp.3171-3177, setembro-2002.
2. **Ferreira, W.P.**; Silveira, M.C.G.; Lotufo, A.D.P. e Minussi, C. R. “Análise de Estabilidade Transitória de Sistemas de Energia Elétrica Por Rede Neural Baseada na Teoria da Ressonância Adaptativa”, *5<sup>th</sup> Latin American Congress on Electricity, Generation and Transmission*, São Pedro-SP, Novembro-2003. (Artigo B-135).

# ANÁLISE DE ESTABILIDADE TRANSITÓRIA DE SISTEMAS DE ENERGIA ELÉTRICA USANDO UMA REDE NEURAL ARTMAP NEBULOSA

MARIA DO CARMO G. SILVEIRA SANDRA C. MARCHIORI WAGNER P. FERREIRA CARLOS R. MINUSSI

*Departamento de Engenharia Elétrica – Universidade Estadual Paulista – Câmpus de Ilha Solteira  
15385-000, Ilha Solteira, SP, BRASIL*

*E-mails: carmo@feis.unesp.br sandra@dee.feis.unesp.br wagner@dee.feis.unesp.br minuissi@dee.feis.unesp.br*

**Resumo**– Este trabalho tem por objetivo o desenvolvimento de um método para a análise de estabilidade transitória de Sistemas de Energia Elétrica usando redes neurais artificiais baseadas na arquitetura ARTMAP nebulosa. Esta arquitetura busca explorar a similaridade entre os conceitos computacionais da teoria de conjuntos nebulosos e a rede neural ART (*Adaptive Resonance Theory*). As arquiteturas ART apresentam as características de estabilidade e plasticidade, as quais são qualidades imprescindíveis para a realização do treinamento e execução da análise. Visa-se, deste modo, empregar um treinamento mais rápido, se comparado com a formulação convencional do algoritmo retropropagação, conseqüentemente tornando a análise mais competitiva em comparação aos principais métodos encontrados na literatura especializada. Como ilustração da metodologia, são apresentados os resultados da análise de estabilidade transitória, considerando-se um sistema elétrico multi-máquinas.

**Abstract**– This work deals with a developing methodology to analyze electric energy systems transient stability using artificial neural networks based on fuzzy ARTMAP architecture. This architecture seeks exploring similarity with computational concepts of fuzzy set theory and ART neural network (*Adaptive Resonance Theory*). The ART architectures show plasticity and stability characteristics, which are essential qualities to do the training and execute the analysis. Therefore, by this way, it is used a very fast training when compared to the conventional back-propagation algorithm formulation, consequently the analysis becomes more competitive, compared to the principal methods found in the specialized literature. Illustrating this methodology there are presented results considering a multi-machines electric power system.

**Keywords**– Electrical Power Systems, Transient Stability Analysis; Fuzzy ARTMAP Neural Network.

## 1 Introdução

O objetivo deste trabalho é investigar a aplicação de redes neurais artificiais (Haykin, 1992) para a realização da análise de estabilidade transitória de Sistemas de Energia Elétrica (SEE). A análise de estabilidade transitória de SEE consiste na avaliação dos efeitos procedentes de perturbações que causam grandes e indesejáveis oscilações nos ângulos das máquinas síncronas. Considera-se a análise de estabilidade de primeira oscilação onde pode-se empregar o chamado modelo clássico (Anderson e Fouad, 1977; Pai, 1981). A opção por esta abordagem mais simples de modelo deve-se ao fato de que, para extrair o conhecimento deste problema, via redes neurais, é necessário impor uma rotina de dados que constitui a fase de treinamento da rede. Estes dados devem conter informações quantitativas e qualitativas de cada uma das contingências. Para efetivamente constituir uma boa capacidade de generalização (análise de situações não previstas nos casos simulados), faz-se necessária a utilização de um grande número de dados de entrada e de saída para a fase do treinamento da rede neural. Para atender estas características, no momento, salvo melhor julgamento, somente podem ser proporcionados quando se utiliza os métodos diretos de análise, mais especificamente, os métodos de energia generalizada de Lyapunov (Athay *et al.*, 1979; Fonseca e Decker, 1985). Estes métodos, embora tenham apresentado grande evolução nos últimos anos, ainda há carência de resultados práticos para modelos mais elaborados. Deve-se destacar que a simulação (resolução do sistema de equações algébricas/diferenciais não-lineares e exame

das soluções obtidas) é considerada, pela literatura especializada, um *benchmark* de análise de transitórios eletromecânicos. Nesta metodologia, pode-se simular qualquer modelo (qualquer que seja a sua sofisticação). Contudo, o grande obstáculo reside na obtenção somente da análise qualitativa, ou seja, a informação se o sistema é ou não estável para uma contingência em particular. Não é possível, a princípio, a menos que se empregue o método de tentativa e erro, saber quanto estável ou instável é o sistema. Além disto, os métodos de simulação consomem grande quantidade de tempo para a análise, isto porque empregam, entre outras rotinas, métodos de integração numérica, registros das curvas de oscilação, e envolvem a participação de um especialista para a conclusão da análise, tudo isto efetuando uma simulação por vez.

Em vista disto, neste trabalho será abordado o problema da análise de estabilidade transitória através de redes neurais, levando-se em conta o modelo clássico. Deve-se ressaltar que não há restrição quanto a adoção de modelos mais elaborados, inclusive via simulação, para a abordagem via redes neurais. Apenas é preciso evidenciar a necessidade de resultados mais completos (saber *quanto estável ou instável é o sistema* frente a uma certa perturbação).

Pretende-se, portanto, investigar o uso da rede neural ARTMAP nebulosa (Carpenter *et al.*, 1992). A rede ARTMAP é uma arquitetura baseada no treinamento supervisionado para mapeamentos multi-dimensionais (multi-entradas/multi-saída) sendo composta por dois módulos ART (*Adaptive Resonance Theory*) (Carpenter e Grossberg, 1991) e

um módulo inter-ART. As redes neurais da família ART possuem a característica de estabilidade (capacidade de aprender através do ajuste dos seus pesos) e plasticidade (capacidade de continuar a aprender com a inclusão de novos padrões, sem perder a memória com relação aos padrões anteriores). Com tais características a rede neural ARTMAP nebulosa apresenta um desempenho superior ao tradicional algoritmo retropropagação (Werbos, 1974). A rede ARTMAP nebulosa será, então, usada para avaliação da estabilidade transitória considerando-se contingências do tipo curto-circuito. Neste contexto, será desenvolvido um arranjo para avaliação da estabilidade transitória baseada na informação de tempos críticos de chaveamento e/ou o cálculo da margem de segurança (Fonseca e Decker, 1985; Pai, 1981) como um aproximador de funções complexas (análise qualitativa e quantitativa), ou, ainda, como um classificador de padrões (análise qualitativa).

Ressalta-se que na literatura especializada encontram-se poucas referências que abordam o problema da análise de estabilidade através do emprego de redes neurais (Sobajic e Pao, 1989; Pao e Sobajic, 1991; Minussi e Silveira, 1995; Minussi *et al.*, 2001; Marchiori, 2001).

## 2 Modelo do Sistema de Energia Elétrica

O comportamento dinâmico da  $i$ -ésima máquina síncrona, referida ao CA (Centro de ângulos), de um sistema composto por  $n$  máquina pode ser descrito pela seguinte equação diferencial (Athay *et al.*, 1979; Pai, 1981):

$$M_i \ddot{\theta}_i - P_i(\theta) = 0, \quad i \in N \quad (1)$$

sendo:

$$P_i(\theta) = Pm_i - Pe_i - (M_i PAC) / MT; \quad (2)$$

$$M_i = 2 H_i / \omega_s;$$

$$\omega_s \triangleq \text{velocidade síncrona do rotor} \\ = 2\pi f_0;$$

$$H_i = \text{constante de inércia};$$

$$f_0 = \text{frequência nominal do sistema};$$

$$\theta_i \triangleq \text{ângulo do rotor da } i\text{-ésima máquina} \\ \text{síncrona com relação ao CA} \\ = \delta_i - \delta_0;$$

$$\delta_i = \text{ângulo do rotor da } i\text{-ésima máquina} \\ \text{síncrona em relação a uma máquina que} \\ \text{gira com velocidade síncrona}$$

$$\delta_0 = \sum_{j \in N} M_j \delta_j;$$

$$Pm_i = \text{potência mecânica de entrada};$$

$$Pe_i = \text{potência elétrica de saída};$$

$$PAC \triangleq \text{potência acelerante do CA} \\ = \sum_{j \in N} (Pm_j - Pe_j);$$

$$MT = \sum_{j \in N} M_j;$$

$$N \triangleq \text{conjunto de índices das máquinas síncronas} \\ \text{que compõem o sistema} \\ = \{1, 2, \dots, n\}.$$

## 3 Análise da Estabilidade Transitória

A análise da estabilidade transitória de SEE, considerando-se uma contingência de índice  $r$ , pode ser efetuada utilizando-se o critério da margem de segurança (Pai, 1981):

$$M_r = (E_{crit_r} - E_{e_r}) / E_{crit_r} \quad (3)$$

sendo:

$$E_{crit_r} = \text{energia total crítica do sistema};$$

$$E_{e_r} = \text{energia total do sistema avaliada no instante} \\ \text{de eliminação do defeito } (t_e).$$

A energia crítica ( $E_{crit}$ ), bem como o tempo crítico ( $t_{crit}$ ), poderão, por exemplo, ser determinados através do método PEBS (*Potential Energy Boundary Surface*) (Athay *et al.*, 1979; Fonseca e Decker, 1985), ou por outro procedimento que apresente um resultado similar, principalmente com relação à precisão. A energia total, relativa ao sistema (1), é dada por (Athay *et al.*, 1979; Fonseca e Decker, 1985; 1990; Pai, 1981):

$$E(\theta, \omega) = E_c(\omega) + E_p(\theta) \quad (4)$$

sendo:

$$E_c(\omega) = \text{energia cinética} \\ = 1/2 \sum_{i \in N} M_i \omega_i^2; \quad (5)$$

$$E_p(\theta) = \text{energia potencial} \\ = - \sum_{i \in N} \int_{\theta_i^p}^{\theta_i} P_i(\theta) d\theta_i. \quad (6)$$

A estabilidade transitória para a  $r$ -ésima contingência pode ser analisada, via margem de segurança, da seguinte forma (Fonseca e Decker, 1985; Fonseca e Minussi, 1990):

- se  $M_r \geq 0$ , o sistema é considerado *estável*, do ponto de vista da estabilidade transitória;
- se  $M_r < 0$ , o sistema é considerado *instável*.

## 4 Rede Neural ARTMAP Nebulosa

A rede neural ARTMAP (Carpenter e Grossberg, 1991) constitui-se numa rede supervisionada (treinamento realizado baseado em estímulos de entrada e de saída), sendo formada por duas sub-redes ART (*Adaptive Resonance Theory*) (Carpenter e Gossberg, 1991): ARTa e ARTb interligadas por um módulo inter-ART que executa a função de estabelecer o “casamento” entre entrada e saída da rede neural. Na seqüência serão apresentados os

algoritmos básicos das redes neurais ART nebulosa e ARTMAP nebulosa.

#### 4.1 Algoritmo da Rede Neural ART Nebulosa

O componente ART nebulosa na rede ARTMAP nebulosa (Carpenter e Grossberg, 1991; Carpenter *et al.*, 1992) consiste de um campo de pré-processamento de neurônios,  $F_0$ , que modifica o vetor de entrada atual  $a$ , e um campo  $F_1$  que recebe ambas entradas de  $F_0$  e entradas de  $F_2$ . Não é necessário distinguir os pesos de conexão dos caminhos de *feedback* e *feedforward* entre os campos  $F_1$  e  $F_2$  no módulo ART nebuloso, ambos serão implementados pelos mesmos pesos (Carpenter e Grossberg, 1992). O algoritmo resumido da rede neural ART nebulosa consiste, basicamente, nos seguintes passos (Carpenter e Grossberg, 1992):

Passo 1. (Iniciação de pesos e parâmetros da rede).

Inicialmente, todos os pesos dos neurônios são fixados iguais a 1,  $w_{ij} = 1$ , o parâmetro de vigilância é escolhido entre 0 e 1,  $\rho \in [0, 1]$ , o parâmetro de escolha é escolhido maior do que 0,  $\alpha > 0$ , e o parâmetro da taxa de treinamento é escolhido entre 0 e 1,  $\beta \in [0, 1]$ .

Passo 2. (Codificação do vetor de entrada).

Um novo padrão de entrada  $a = (a_1, a_2, \dots, a_n)$  de  $n$  elementos em que cada elemento  $a_i$  é um número real no intervalo  $[0,1]$ . Ao padrão  $a$  é introduzida uma codificação complementar, ou seja, produz um vetor de entrada  $I$  de  $2n$  elementos, tal que (Carpenter *et al.*, 1992):

$$I \triangleq (a, a^c) \\ = (a_1, a_2, \dots, a_n, a_1^c, a_2^c, \dots, a_n^c) \quad (7)$$

sendo:  $a_i^c = 1 - a_i$ .

Esta codificação complementar é uma regra de normalização que preserva a informação de amplitude.

Passo 3. (Escolha da categoria).

A ativação  $T_j$  é calculada para cada neurônio  $j$  de  $F_2$ , usando a função escolha (Carpenter *et al.*, 1992):

$$T_j = |I \wedge w_j| / (\alpha + |w_j|), \quad (8)$$

em que o operador  $\wedge$  é o operador nebuloso *and*, definido por (Carpenter *et al.*, 1992, Furuhashi, 1994):

$$(p \wedge q)_i \triangleq \min(p_i, q_i), \text{ com } p \text{ e } q \in \mathfrak{R}^{2n},$$

e a norma  $|\cdot|$  é definida por (Carpenter *et al.*, 1992):

$$|p| \triangleq \sum_{i=1}^{2n} |p_i| \quad (9)$$

A categoria (chamada categoria ativa) escolhida é indexada por  $J$ , em que (Carpenter *et al.*, 1992):

$$T_J = \text{máx} \{T_j, j = 1, \dots, 2n\}. \quad (10)$$

Passo 4. (Teste de vigilância).

A ressonância ocorre se a função *match*:

$$|I \wedge w_J| / |I|$$

da categoria escolhida encontra o critério de vigilância:

$$|I \wedge w_J| \geq \rho |I|. \quad (11)$$

O treinamento, então, resulta como definido no Passo 5.

Do contrário, se o critério de vigilância falhar para a categoria escolhida, o valor da função escolha  $T_j$  é fixado em 0 até que o critério seja satisfeito para aquela entrada. Um novo índice  $J$  é ,então, escolhido usando-se equação (10). O processo de busca continua até que o índice  $J$  escolhido satisfaça a equação (11).

Passo 5. (Atualização do vetor protótipo).

Encerrada a busca, o vetor peso  $w_j$  é atualizado de acordo com a seguinte equação (Carpenter *et al.*, 1992):

$$w_J^{\text{nov}} = \beta (I \wedge w_J^{\text{velho}}) + (1 - \beta) w_J^{\text{velho}} \quad (12)$$

O treinamento rápido corresponde à arbitrar  $\beta = 1$ .

#### 4.2 Algoritmo da Rede Neural ARTMAP Nebulosa

A arquitetura ARTMAP (Carpenter e Grossberg, 1992) é uma rede mais sofisticada, conforme é ilustrada na Figura 1. A rede ARTMAP nebulosa (Carpenter e Grossberg, 1991) na sua forma geral, inclui dois módulos de rede neural ART nebulosa (ARTa e ARTb) cujas camadas são ligadas por um módulo inter-ART que inclui um campo de mapeamento controlando o treinamento de um mapa associativo de categorias de reconhecimento de ARTa para categorias de reconhecimento de ARTb. O campo de mapeamento também controla a regra *matching tracking* (Carpenter *et al.*, 1992), que aumenta o parâmetro de vigilância da rede ARTa por uma quantia mínima necessária para corrigir um erro preditivo (Carpenter *et al.*, 1992). As redes ARTa e ARTb são de estruturas iguais como a rede ART nebulosa descrita na seção anterior, exceto que em ARTa há uma vigilância básica usada para controlar o sistema.

Durante o treinamento supervisionado ARTa recebe um conjunto de padrões de entrada  $\{a^M\}$  e ARTb recebe um conjunto de padrões  $\{b^M\}$ , em que  $b^M$  é a predição correta dada  $a^M$  (Carpenter *et al.*, 1991). Quando uma predição em ARTa não é confirmada por ARTb, a inibição da memória associativa inter-ART ativa o processo *match tracking* (Carpenter *et al.* 1992). Este processo aumenta a vigilância em ARTa por uma quantia mínima necessária para o sistema ativar uma outra categoria em ARTa que iguala a categoria em ARTb, ou para treinar uma nova categoria em ARTa. Os mecanismos de controle interno das ARTMAP's criam categorias de reconhecimento estáveis de medida ótima por maximização da generalização preditiva em operações em tempo real (Carpenter *et al.*, 1992). A rede neural ARTMAP nebulosa realiza treinamento supervisionado como o retropropagação (Werbos, 1974). Mas diferente do algoritmo retropropagação, a rede ARTMAP nebulosa é auto-organizável, auto-estabilizável e apropriada para treinamento em tempo-real.

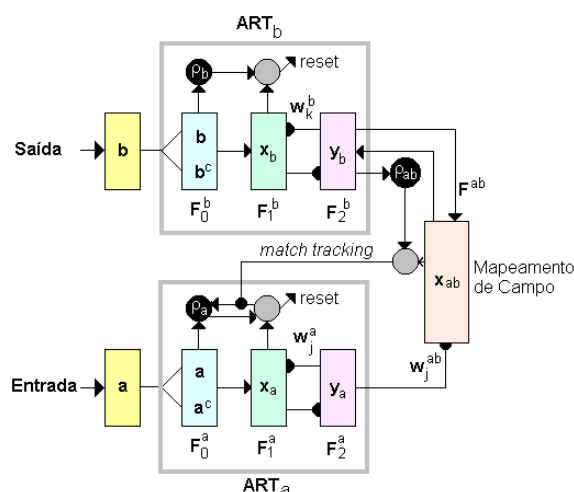


Figura 1. Arquitetura ARTMAP nebulosa.

## 5 Análise de Estabilidade Transitória: Solução Proposta Via Rede Neural ARTMAP Nebulosa

Nesta seção serão estabelecidas as entradas e saídas da rede neural. Estas informações são fornecidas por um programa computacional de análise de estabilidade transitória (SIMUL) que, a partir dos dados da rede elétrica, considerando-se uma lista de contingências (curto-circuito trifásico com saída de linha de transmissão), provém os valores das margens de segurança associadas. O programa SIMUL é uma implementação computacional baseada na integração numérica das equações diferenciais (1) e no método PEBS (Athay *et al.*, 1979; Fonseca e Decker, 1985), versão para microcomputador. Na seqüência, procedem-se a escolha e o pré-processamento das informações que serão usadas no treinamento da rede neural, compondo os estímulos de

entrada/saída. A entrada é constituída por dados analógicos (potências ativa e reativa nodais) e binários (associados às contingências: barra de falta e nós terminais do circuito que sai de operação). A saída é essencialmente representada por código binário.

### 5.1 Estímulos de Entrada

A estrutura neural proposta visa a análise de estabilidade transitória de SEE, que corresponde à determinação da margem de segurança, considerando-se faltas do tipo curto-circuito trifásico com saída de linha de transmissão. Os vetores padrões de entrada da rede neural são definidos como (Minussi *et al.*, 2001):

$$X_r = [P^T Q^T A_r^T]^T \quad (13)$$

sendo:

$X_r$  = vetor padrão referente à  $r$ -ésima contingência;

$P$  =  $[P_1 P_2 \dots P_p]^T$ ;

$Q$  =  $[Q_1 Q_2 \dots Q_p]^T$ ;

$P_i$  = potência ativa da  $i$ -ésima barra do sistema;

$Q_i$  = potência reativa da  $i$ -ésima barra do sistema;

$A_r$  = vetor que contém a informação sobre a  $r$ -ésima contingência representada em um código binário (0,+1).

Neste caso, considerando-se o modelo clássico para a análise de estabilidade transitória de primeira oscilação (Anderson e Fouad, 1977; Pai, 1981), assume-se que apenas os vetores de potência ativa e reativa são necessários. Isto porque, como a topologia da rede e demais parâmetros (constante de inércia, reatância transitória, etc.) são mantidos constantes, utilizam-se somente as variáveis causais (potência ativa e reativa) e os parâmetros que expressam alterações na rede (representação de contingências) (Minussi *et al.*, 2001). Deste modo, os ângulos e velocidades são elementos consequentes deste processo, *i.e.*, são funções da potência (ativa e reativa) e do tipo / circunstância em que a falta ocorre.

### 5.2 Estímulos de Saída

Os estímulos a serem aplicados no módulo ARTb da rede neural ARTMAP são as margens de segurança correspondentes aos vetores padrões de entrada (módulo ARTa) descritos pela equação (13). A estratégia usada neste trabalho é a utilização de intervalos de margem de segurança em que as contingências se encontram. Por exemplo, uma contingência com margem de segurança igual a 0,5 pode ser convencionalmente pertencendo ao intervalo (0,4; 0,6). Esta forma permite que se represente as contingências através de código binário e reduz o número de classes no módulo ARTb, que é uma forma mais adequada para trabalhar com a rede ARTMAP,

tornando o treinamento mais rápido e a análise mais confiável (há sempre a garantia da obtenção de soluções). Deve-se destacar que este procedimento, desde que observados os devidos cuidados, é pertinente, pois para os centros de controle não há grande necessidade de dispor de números com grande precisão e sim, a informação de *quanto estável* ou *instável* é determinada contingência. Com o propósito de estabelecer estes intervalos, será proposto o uso do conceito de *Esforço de Deslocamento da Margem de Segurança* (Minussi e Freitas, 1998):

$$\vartheta = (1 - M^A) / (1 - M^B) - 1 \quad (14)$$

sendo:

$\vartheta$  = esforço de deslocamento da margem de segurança;

$M^A$  = valor da margem de segurança inicial do intervalo;

$M^B$  = valor da margem de segurança final do intervalo.

Deste modo, o intervalo, em termos do conceito de margem de segurança, pode ser definido como (Marchiori, 2001):

$$IMS_k \triangleq (M_k^A, M_k^B) \quad (15)$$

em que:

$IMS_k$  =  $k$ -ésimo intervalo da margem de segurança.

Esta concepção será utilizada neste trabalho para definir os intervalos associados às contingências, conforme é mostrado na Tabela 1, considerando-se  $\vartheta = 0,35$  e os valores da margem de segurança compreendidos em  $(-3, 1)$ .

Tabela 1. Intervalos da margem de segurança.

No. do Intervalo	Intervalo da Margem de Segurança (IMS)
1	$\leq -3$
2	$(-3; -1,9630]$
3	$(-1,9630; -1,1948]$
4	$(-1,1948; -0,6258]$
5	$(-0,6258; -0,2043]$
6	$(-0,2043; 0,10790]$
7	$(0,10790; 0,33920]$
8	$(0,33920; 0,51050]$
9	$(0,51050; 0,63740]$
10	$(0,63740; 0,73140]$
11	$(0,73140; 0,80110]$
12	$(0,80110; 0,85260]$
13	$(0,85260; 0,89080]$
14	$(0,89080; 0,91910]$
15	$\geq 0,9191$

## 6 Aplicação

Apresentam-se, a seguir, os resultados obtidos através do método proposto, considerando-se um sistema composto por 3 máquinas síncronas

(Anderson e Fouad, 1977) como mostrado na Figura 2. Os dados das máquinas síncronas e do sistema de transmissão encontram-se nas Tabelas 2, 3 e 4. Trata-se de um sistema de pequeno porte, contudo será usado para demonstrar a validade da metodologia proposta e o encorajamento para aplicações, considerando-se sistemas de energia elétrica reais de grande porte.

Nestes estudos consideram-se faltas do tipo curto-circuito com tempo de eliminação igual a 9 ciclos (0,15s) com saída de linha de transmissão. Os valores em pu referem-se a uma base de 100MVA.

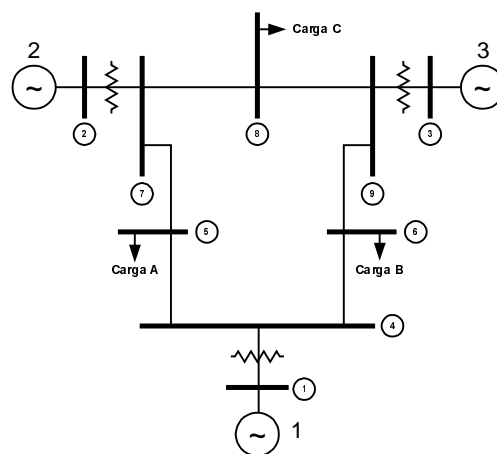


Figura 2. Sistema de energia elétrica composto por 3 máquinas síncronas.

Tabela 2. Dados das máquinas síncronas.

Máquina Síncrona	Potência Mecânica (pu)	Reatâncias		H (s)
		$x_d$ (pu)	$x'_d$ (pu)	
1	Referência	0,1460	0,0608	9,552
2	1,63	0,8958	0,1198	3,333
3	0,85	1,3125	0,1813	2,352

Tabela 3. Dados das cargas.

Potência Elétrica (pu)	Barra de Carga		
	5	6	8
Ativa	1,25	0,90	1,00
Reativa	0,50	0,30	0,35

Tabela 4. Dados do sistema de transmissão.

Elemento do Sistema de Transmissão				
No.	Nó Inicial	Nó Final	Impedância série (pu)	Susceptância Shunt (pu)
1	1	4	$0,0000 + j 0,0570$	0
2	4	5	$0,0100 + j 0,0850$	$j 0,0880$
3	4	6	$0,0170 + j 0,0920$	$j 0,0790$
4	5	7	$0,0320 + j 0,1610$	$j 0,1530$
5	6	9	$0,0390 + j 0,1700$	$j 0,1790$
6	2	7	$0,0000 + j 0,6250$	0
7	7	8	$0,0080 + j 0,0720$	$j 0,7450$
8	8	9	$0,0120 + j 0,1008$	$j 0,1045$
9	3	9	$0,0000 + j 0,5860$	0



Tabela 5. Relação de contingências.

No. Falta	Falta		
	Curto-circuito	Saída do Circuito	
		Barra	Barra Inicial
1	4	4	5
2	4	4	6
3	5	5	7
4	5	4	5
5	6	6	9
6	6	4	6
7	7	5	7
8	7	7	8
9	8	7	9
10	8	8	9

Tabela 6. Análise comparativa dos resultados da análise de estabilidade transitória gerados pelo programa SIMUL e pela Redes Neurais ARTMAP nebulosa. .

No. Falta	Perfil Geração / Carga		Intervalo IMS	
	Percentual	Semente	SIMUL	Rede Neural
1	87,5	067	13	13
2	87,5	067	14	14
3	87,5	067	11	11
4	87,5	067	13	13
5	87,5	067	12	13
6	87,5	067	15	15
7	87,5	067	7	7
8	87,5	067	7	7
9	87,5	067	10	9
10	87,5	067	11	11
1	92,5	567	11	11
2	92,5	567	12	12
3	92,5	567	9	9
4	92,5	567	11	11
5	92,5	567	11	11
6	92,5	567	14	15
7	92,5	567	5	5
8	92,5	567	5	5
9	92,5	567	8	8
10	92,5	567	9	9
1	97,5	668	10	11
2	97,5	668	11	12
3	97,5	668	8	8
4	97,5	668	11	11
5	97,5	668	10	10
6	97,5	668	13	13
7	97,5	668	5	5
8	97,5	668	5	5
9	97,5	668	8	8
10	97,5	668	9	9
1	102,5	270	9	9
2	102,5	270	10	10
3	102,5	270	7	7
4	102,5	270	10	10
5	102,5	270	9	9
6	102,5	270	12	12
7	102,5	270	4	4
8	102,5	270	4	4
9	102,5	270	7	7
10	102,5	270	8	8

O conjunto de contingências adotado encontra-se descrito na Tabela 5. Trata-se das contingências mais importantes para o sistema sob estudo. O treinamento da rede neural foi realizado considerando-se um conjunto de 486 perfis de geração e de carga e respectivas margens de segurança. Cada perfil corresponde a um redespacho de geração em relação ao caso base (dados contidos nas Tabela 2 e 3) realizado de forma aleatória para atender a demanda, também, fixado de modo aleatório em cada barra. O universo de variação da carga encontra-se compreendido entre 80 e 120% ( $\pm 20\%$ ), em relação à carga nominal total do sistema. Portanto, cada perfil é gerado considerando-se um percentual de variação em torno do estado nominal (caso base) e determinada semente para o processo de geração de seqüências aleatórias. Assim, para um mesmo percentual, diferentes sementes gerarão diferentes despachos de geração de diferentes perfis de carga. Este procedimento gera um conjunto adequado de padrões para a fase de treinamento.

Realizado o treinamento da rede neural, os testes (análise da estabilidade transitória) podem ser efetivados, cujos resultados são mostrados na Tabela 6. Trata-se da análise comparativa entre os resultados obtidos via o programa de simulação híbrida (SIMUL) e via redes neurais (procedimento proposto). São considerados 40 perfis de geração e de carga distintos (diferentes percentuais e diferentes sementes) dos perfis utilizados no treinamento, fixados, igualmente, de forma aleatória. O percentual e a semente usados nas análises encontram-se indicados nas colunas 2 e 3 da Tabela 6, respectivamente. O intervalo IMS indicada pela rede neural ARTMAP nebulosa corresponde ao resultado obtido via estratégia de votação (Carpenter *et al.*, 1992), ou seja, a rede neural é sistema treinada diversas vezes, com diferentes ordenações (aleatórias) para o mesmo conjunto de treinamento. A predição final é dada pelas soluções geradas com maior frequência. Pode-se observar que os resultados produzidos pelas duas metodologias são bastantes próximos. Para a obtenção dos resultados foi utilizado um microcomputador Pentium III (500 MHz). O tempo de processamento refere-se somente à execução do algoritmo ARTMAP, excluindo-se as operações de leitura / saída de dados:

- treinamento da rede neural : 1s
- execução da análise : 10 milissegundos.

## 7 Conclusão

Foi desenvolvido neste trabalho um procedimento de análise de estabilidade transitória de sistemas de energia elétrica multi-máquinas, através de uma rede neural ARTMAP nebulosa. Com esta arquitetura pôde-se idealizar um procedimento de análise de estabilidade transitória de sistemas elétricos de potência. Os estímulos de entrada da

rede neural são constituídos pelo vetores de potências ativa e reativa nodais (dados analógicos) e pelos dados das contingências (dados binários). As saídas correspondem às margens de segurança do sistema representadas por intervalos compreendidos entre os valores mínimo e máximo. Deste modo, foi possível representar as saídas em código binário (saídas binárias). Como ilustração da metodologia foram apresentados os resultados da análise de estabilidade transitória, via rede neural ARTMAP nebulosa, considerando-se um sistema elétrico de potência correspondente a um sistema composto por 9 barras, 9 linhas de transmissão/transformadores 3 máquinas síncronas. O treinamento foi realizado considerando-se 10 contingências do tipo curto-circuito trifásico sólido com saída de linha de transmissão. As contingências foram arbitradas como incidentes em vários pontos da rede elétrica (10 localizações). Foram considerados níveis de carregamentos arbitrados de forma aleatória dentro de um universo compreendido entre 80 e 120% da carga total do sistema. Os resultados obtidos podem ser considerados satisfatórios, ou seja, atingiram os objetivos propostos. Estes objetivos foram: investigar a aplicação de redes neurais para execução de diagnósticos da estabilidade transitória de sistemas elétricos de potência. A rede neural ARTMAP tem proporcionado a obtenção de soluções bastante rápidas (cerca de 1 segundo utilizando um microcomputador Pentium III de 500 MHz, considerando-se a execução da estratégia de votação com 5 repetições de treinamento). A qualidade das soluções foram adequadas. Contudo, foram observadas algumas imprecisões (cerca de 10%). Estas imprecisões não foram decorrentes da rede neural e sim do uso em um conjunto de treinamento não suficientemente completo. Deve-se destacar que a precisão dos resultados é dependente do volume de dados para o treinamento e, também, do número de segmentos de saída (intervalos *IMS*). Um maior número de segmentos pode ser obtido tomando-se valores menores para o parâmetro  $\vartheta$ . Contudo, para aumentar o número de intervalos será necessário utilizar um grande conjunto de pares de treinamento (número de exemplos) para reduzir as possibilidades de existência de intervalos vazios (que não contenham contingências). Intervalos vazios não oferecem oportunidades de aprendizado e, conseqüentemente, introduzem os indesejáveis focos de ruídos no treinamento. Concluindo-se, a rede neural ARTMAP nebulosa obtém respostas com grande rapidez (há compatibilidade com as aplicações *on-line*) e a precisão é dependente da implementação de um esquema adequado de treinamento, adotando-se um volume de dados de entrada/saída bem elaborado (em quantidade e qualidade suficientes).

*Os Autores agradecem à FAPESP (Fundação de Amparo à Pesquisa do Estado de São Paulo) pelo suporte financeiro – Processo nº 01/10689-9.*

### Referências Bibliográficas

- Anderson, P.M. and Fouad, A. A. (1977). Power system control and stability, IOWA State University Press, USA.
- Athay, T.; Sherket, V.R.; Podmore, R.; Virmani, S. and Puech, C. (1979). Transient energy stability analysis, Conference on 'System Engineering For Power', Davos, Switzerland.
- Carpenter, G. A. and Grossberg, S. (1991). Pattern recognition by self-organizing neural networks, The MIT Press, Cambridge, Massachusetts, USA.
- Carpenter, G. A.; Grossberg, S.; Markuzon, N.; Reynolds, J. H. and Rosen D. B. (1992). Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps, IEEE Transactions on Neural Networks, Vol. 3, No. 5, pp. 698-713.
- Fonseca, L. G. S. and Decker, I. C. (1985). Iterative algorithm for critical energy determination in transient stability of power system, IFAC – Symposium Planning & Operation in Electric Energy System, Rio de Janeiro – RJ, Brazil, pp. 483-489.
- Furuhashi, T. (1994) Advances in fuzzy logic, neural networks and genetic, Springer Verlag, USA.
- Haykin, S. (1992). Neural networks: a comprehensive foundation, Prentice-Hall, Upper Saddle River, New Jersey, USA, 1994.
- Marchiori, S. C. (2001). Estabilidade transitória de sistemas de energia elétrica: uma metodologia de análise via rede neural ARTMAP nebulosa, Dissertação de Mestrado, Universidade Estadual Paulista – UNESP, Programa de Pós-graduação em Engenharia Elétrica, Ilha Solteira-SP.
- Minussi, C. R. and Freitas Filho, W. (1998). Sensitivity analysis for transient stability, IEE Proceedings on Generation, Transmission And Distribution, Vol. 145, No. 6, pp. 669-674, 1998.
- Minussi, C. R.; Ramos, L. M.; Marchiori, S. C., Lopes, M. L. M. and P. Lotufo, A. D. (2001). Neural networks to transient stability analysis of electrical power systems, V Congresso Brasileiro de Redes Neurais, pp. 31-36, Rio de Janeiro – RJ.
- Minussi, C. R. and Silveira, M. C. G. (1995). Transient stability analysis of electric power systems by neural networks, 38<sup>th</sup> Midwest Symposium on Circuits And Systems, Rio de Janeiro – RJ, pp. 1305-1308.
- Pai, M. A. (1981). Power system stability, North Holland Control Series.
- Pao, Y.H. and Sobajic, D.J. (1991). Combined use of unsupervised and supervised learning for dynamic security assessment, IEEE PICA-91, pp. 278-284.
- Simul (1990). Programa computacional híbrido (método da energia / integração numérica) para análise da estabilidade transitória de sistemas de energia elétrica, Versão para Microcomputador, Laboratório Computacional, UNESP, Câmpus de Ilha Solteira.
- Sobajic, D. J. and Pao, Y.H. (1989). Artificial neural-net based dynamic security assessment for electric power systems, IEEE Transactions on Power Systems, Vol. 4, No. 1, February 1989, pp. 220-227.
- Werbos, P. J. (1974). Beyond regression: new tools for prediction and analysis in the behavioral sciences, Master Thesis, Harvard University, 1974.