

REDE NEURAL ARTMAP NEBULOSA PARA ANÁLISE DE ESTABILIDADE TRANSITÓRIA DE SISTEMAS DE ENERGIA ELÉTRICA

Sandra C. Marchiori Carlos R. Minussi Anna Diva P. Lotufo

Universidade Estadual Paulista – UNESP - Câmpus de Ilha Solteira

Departamento de Engenharia Elétrica

15385-000 Ilha Solteira – SP – Av. Brasil, 56

sandra@dee.feis.unesp.br minussi@dee.feis.unesp.br annadiva@dee.feis.unesp.br

Resumo – Este trabalho tem por objetivo o desenvolvimento de uma metodologia 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 *Backpropagation*, 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, através da rede neural ARTMAP Nebulosa, considerando-se um sistema elétrico de potência correspondente a uma possível configuração do sistema da região sul do Brasil composto por 45 barras, 72 linhas de transmissão e 10 máquinas síncronas.

Palavras-chave – Redes neurais, ARTMAP, lógica nebulosa, sistemas de energia elétrica, análise de estabilidade transitória.

1. INTRODUÇÃO

A análise de estabilidade transitória de Sistemas de Energia Elétrica (SEE) consiste na avaliação dos efeitos procedentes de perturbações que causam grandes e indesejáveis oscilações nos ângulos das máquinas síncronas. Esta análise pode ser realizada através das soluções das equações diferenciais não-lineares que descrevem o movimento do sistema – equação de oscilação da máquina síncrona – e posteriormente via análise da evolução da posição angular de cada máquina síncrona ao longo do tempo (simulação). As técnicas utilizadas para a simulação são precisas e não apresentam restrições quanto ao tipo de modelo empregado. Exigem, contudo, a participação de um especialista no processo, o que eleva consideravelmente o tempo de análise. Um procedimento alternativo consiste na obtenção da análise sem se resolver tais equações diferenciais. Neste contexto, encontra-se o Método Direto de Lyapunov (MDL), cujos resultados são considerados satisfatórios quando se emprega o modelo clássico ([17]). Para modelos mais elaborados, não existem, ainda, resultados concretos. Entretanto, a literatura tem demonstrado esforços neste sentido.

Tendo em vista a grande quantidade de defeitos a serem analisados, a complexidade e a grande dimensão dos atuais SEE, a simulação assim como o MDL são alternativas que ainda não oferecem totais condições para aplicações em tempo-real. Novas abordagens de análise, baseadas na inteligência artificial, em especial as redes neurais, têm sido abordadas na literatura com o propósito de superar tais dificuldades. Assim sendo, este trabalho visa investigar a aplicação de Redes Neurais Artificiais (RNA) no diagnóstico da estabilidade transitória de Sistemas de Energia Elétrica.

Redes Neurais Artificiais são concepções em *hardware* e/ou *software* baseadas no mecanismo de funcionamento do cérebro sendo, portanto, capazes de aprender com a experiência ([4, 10, 12, 22]). Deste modo, é possível executar tarefas como recuperação da informação, diagnósticos complexos, previsão, reconhecimento de padrão contendo ruído ou dados distorcidos entre outras.

A análise de estabilidade transitória utilizando redes neurais tem sido feita de forma geral via emprego de redes *feedforward*, com treinamento baseado no algoritmo retropropagação (*backpropagation*) ([24]). Esta técnica tem se mostrado eficiente, sendo considerada, pela literatura especializada, como um *benchmark* em termos de precisão. Contudo, o tempo de processamento é relativamente alto.

Desta forma, pretende-se, neste trabalho, investigar o uso da rede neural ARTMAP ([4]). Esta rede faz parte de um conjunto de propostas (ART, ART1, ART2 e ARTMAP) ([4–6]) destinado à classificação de padrões binários e/ou analógicos, com treinamento supervisionado ou não-supervisionado. A rede ARTMAP é uma arquitetura baseada no treinamento supervisionado para mapeamentos multi-dimensionais (multi-entradas/multi-saída). A formulação da rede ARTMAP através do uso da teoria de conjuntos nebulosos ([21]), designada ARTMAP nebulosa ([5, 6, 9]), tem conferido à formulação original uma sensível redução do tempo necessário à execução do treinamento. A rede ART possui 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 espera-se que esta rede apresente um desempenho superior ao tradicional *backpropagation*. A rede ARTMAP nebulosa será, então,

usada para avaliação da estabilidade transitória considerando-se contingências 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 ([7, 14]) como um aproximador de funções complexas (análise qualitativa e quantitativa), ou, ainda, como um classificador de padrões (análise qualitativa). A margem de segurança, expressa em função de energia total, pode ser interpretada como uma medida de “distância” em relação à condição de instabilidade do sistema. O modelo dinâmico do sistema adotado, neste trabalho, será o modelo clássico, com o objetivo exclusivo de reduzir o custo computacional na geração dos dados para o treinamento. Ressalta-se, entretanto, que poderão ser utilizados, a princípio, modelos mais elaborados, sem a necessidade de se promover modificações significativas na arquitetura proposta.

Será dada uma atenção especial ao desenvolvimento da rede neural tendo em vista que ela deverá ser bastante útil, também, para a resolução de outros problemas de engenharia elétrica, assim como de outras áreas do conhecimento humano.

Ressalta-se que na literatura especializada encontram-se poucas referências que abordam o problema da análise de estabilidade, através do emprego de redes neurais. Em todas elas, o problema da análise de estabilidade transitória é formulado visando a determinação dos tempos críticos para faltas de curtos-circuitos. As referências [15, 16, 20] utilizam redes neurais com treinamento realizado via o uso do algoritmo retropropagação. Em [15] é utilizado o algoritmo retropropagação com controlador nebuloso, o qual ajusta a taxa de treinamento, com o propósito de reduzir o número de ciclos e o tempo de execução na fase de treinamento. Na referência [19] a análise de estabilidade transitória é realizada através do uso da rede neural de Kohonen ([10, 22]) considerando sistemas compostos por máquina síncrona \times barra infinita. Na referência [18], a rede neural é composta por dois módulos: supervisionado e não-supervisionado executados por uma rede neural com ligação funcional, cuja finalidade é reduzir o tempo de treinamento. Há outras referências, em destaque, que abordam problemas associados aos sistemas elétricos de potência com redes neurais que empregam o conceito ART.

2. REDE NEURAL ARTMAP NEBULOSA

Uma das mais importantes características das Redes Neurais Artificiais (RNA) é a capacidade de generalização, ou seja, produzir respostas para padrões de entradas que são similares, mas não idênticos, aos padrões apresentados à rede durante o seu treinamento. Quando uma rede multicamadas é treinada com o algoritmo retropropagação (*backpropagation*) ([24]), por exemplo, espera-se que ela forneça como resposta a classificação correta correspondente ao padrão de entrada, e que ela continue a responder satisfatoriamente a quaisquer padrões de entrada apresentados futuramente. Entretanto, o conhecimento a respeito de determinado domínio do mundo real pode se modificar ao longo do tempo. O mesmo acontece com os padrões de entrada de uma RNA, que podem modificar com o tempo para acomodar as mudanças ocorridas. Assim, para um número de aplicações, o desempenho da rede pode decair gradativamente à medida que o tempo passa, uma vez que os pesos definidos na fase de treinamento não refletem as novas situações. Para adaptar novos padrões de entrada indefinidamente, um algoritmo de aprendizado de RNA deve ser plástico.

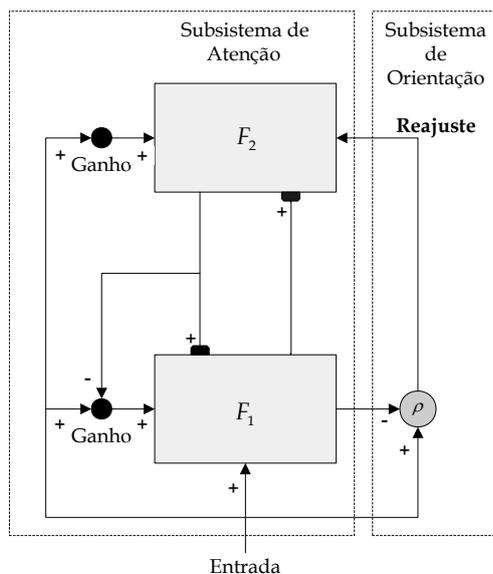
Uma alternativa para solucionar este problema seria retrainar a rede com os novos padrões de entrada. Entretanto, isto pode levar à perda de informações aprendidas anteriormente. Para preservar o conhecimento previamente aprendido, um algoritmo de treinamento de RNA deve não ser somente plástico, mas também estável. Uma outra solução seria retrainar a rede frequentemente com os novos e os antigos padrões. Isto resolveria o problema, mas está longe de representar uma solução viável. Este conflito é conhecido como dilema estabilidade-plasticidade ([4]).

Sendo assim, é necessário, então, um modelo de RNA incremental, que não precise recomeçar seu treinamento do ponto inicial a cada vez que aparecerem novos padrões de entrada e que preserve o conhecimento adquirido anteriormente. Uma família de RNA denominada ART (*Adaptive Resonance Theory*) foi desenvolvida para solucionar este dilema.

2.1 Características Básicas dos Sistemas ART

ART é um sistema que auto-organiza padrões de entrada em categorias de reconhecimento, mantendo um equilíbrio entre as propriedades de plasticidade (discriminação) e de estabilidade (generalização) ([4]). A propriedade de plasticidade define a habilidade da rede em criar novas categorias de reconhecimento, quando padrões estranhos estimulam a rede ART. A propriedade de estabilidade é responsável pela habilidade em agrupar padrões similares na mesma categoria de reconhecimento. Uma regra de similaridade que define onde agrupar os padrões é determinada por um grau de semelhança entre um padrão previamente armazenado.

Figura 1 – Arquitetura básica da rede ART1.



O primeiro modelo da família ART a ser desenvolvido foi a rede ART1. Esta rede é destinada para treinar, rápida e estavelmente, categorias de reconhecimento em resposta a uma seqüência arbitrária de padrões de entradas binárias. ART1 é formada por dois principais módulos ([4]): o *subsistema de atenção* e o *subsistema de orientação* (Figura 1). O subsistema de atenção consiste de dois campos de neurônios: F_1 , que processa os dados de entrada; e F_2 , que agrupa os padrões de treinamento em categorias de reconhecimento, em que cada campo pode consistir de várias camadas de neurônios. Estes campos são conectados com pesos de conexão *feedforward* e *feedback*. Os pesos de conexão formam os componentes da memória a longo prazo (LTM – *Long Term Memory*) do sistema e multiplica os sinais ao longo destes caminhos. O nome memória a curto prazo (STM – *Short Term Memory*) será associado com o padrão de atividade que desenvolve-se sobre um campo quando um padrão de entrada é processado. O subsistema de orientação é controlado por um parâmetro de vigilância (ρ), necessário para estabilizar o processamento em STM e o treinamento em LTM. Esta vigilância determina se um padrão de entrada pode ser incluído em uma das categorias existentes.

O processo de classificação de rede ART consiste de quatro fases principais: *reconhecimento*, *comparação*, *busca* e *treinamento* ([4]).

Cada neurônio do campo F_1 (camada de entrada) pode receber três sinais: um sinal do vetor de entrada, um sinal de *feedback* do campo F_2 (camada de saída) e um sinal da unidade controle (ganho), que são regidos pela Regra 2/3 ([4]). Esta regra determina que um neurônio somente será ativado se receber, pelo menos, dois sinais excitatórios; caso contrário, a ativação não ocorre. Na fase de reconhecimento, o vetor de entrada e o sinal de controle de ganho do campo F_1 (sinal que determina o fluxo de dados para a camada de entrada) são enviados à camada de entrada, onde será aplicada, a cada neurônio, a Regra 2/3. O vetor resultante é comparado com todos os vetores de pesos *feedforward* para encontrar o mais semelhante. Esta comparação é realizada calculando o produto interno entre o vetor de saída resultante e o vetor de pesos *feedforward* para cada neurônio do campo F_2 , como indica a seguinte equação:

$$y_j = \sum_i w_{ji} x_i \quad (1)$$

em que:

y_j = ativação do neurônio de saída j , definido pelo produto interno entre seu vetor de pesos w_j e seu vetor de entrada x . O neurônio do campo F_2 , com maior valor de ativação, é selecionado como provável categoria para armazenar o novo padrão. A inibição lateral faz com que somente o neurônio vencedor do campo F_2 fique ativo. O neurônio selecionado envia ao campo F_1 seu protótipo.

Na fase de comparação acontece um mecanismo de reajuste, que é responsável por testar a similaridade entre o vetor de entrada e o vetor de comparação, z , que é o vetor resultante da aplicação da Regra 2/3 no campo F_1 mediante o vetor protótipo dado pelo campo F_2 após a fase de reconhecimento. O teste é feito calculando a razão R , por meio da equação (2), entre o número de valores iguais a 1 de ambos os vetores e comparando o resultado desta razão com o parâmetro de vigilância ρ . Se R for maior que ρ , então, o padrão de entrada é incluído na categoria do neurônio do campo F_2 ativado. Caso contrário, outro neurônio do campo F_2 deverá ser encontrado para armazenar o vetor de entrada, e a rede entra na fase de busca.

$$R = \frac{\left\| \sum x_i z_{ij} \right\|}{\left\| \sum x_i \right\|} \quad (2)$$

Durante a fase de busca, a rede procura um novo neurônio do campo F_2 para representar o vetor de entrada atual. O neurônio da camada de saída rejeitado na fase de comparação anterior é desabilitado nesta seleção. O vetor de entrada é reapresentado, e a rede entra novamente na fase de comparação, que termina com o teste no mecanismo de reajuste para determinar a similaridade entre o novo protótipo escolhido e o vetor de entrada atual. Este processo é repetido, desativando neurônios da camada de saída, até encontrar um neurônio de saída que melhor se assemelhe ao vetor de entrada corrente, dentro dos limites do parâmetro de vigilância ρ . Se nenhum neurônio de saída for encontrado, o vetor de entrada é então desconsiderado de uma classe desconhecida, sendo alocado um neurônio de saída que não esteja associado ainda a nenhuma categoria para representá-lo.

O algoritmo de treinamento da rede ART1 é não-supervisionado e pode ser ativado a qualquer momento, permitindo que a rede aprenda novos padrões continuamente. Há dois tipos de treinamento para a rede ART1: aprendizado rápido e aprendizado lento ([4]). No aprendizado rápido, os pesos *feedforward* são ajustados para seus valores ótimos em poucos ciclos, geralmente em apenas um ciclo de treinamento. No aprendizado lento, os pesos são ajustados lentamente em vários ciclos de treinamento, possibilitando um ajuste melhor dos pesos da rede aos padrões de treinamento.

As redes ARTs são muito sensíveis a variações em seus parâmetros durante o treinamento. O parâmetro mais crítico é o parâmetro de vigilância (ρ) que controla a resolução do processo de classificação. Se ρ assume um valor baixo, e.g., a rede permite que padrões não muito semelhantes sejam agrupados na mesma categoria de reconhecimento, criando poucas classes. Se a ρ for atribuído um valor alto (próximo a 1), pequenas variações nos padrões de entrada levarão à criação de novas classes. Com o objetivo de apresentar a arquitetura ARTMAP nebulosa, metodologia utilizada nesta pesquisa, a seguir, apresenta-se o algoritmo da arquitetura ART nebulosa, que é uma generalização da rede ART1.

2.2 Algoritmo ART Nebuloso

ART nebulosa é uma generalização da rede ART1. A generalização é alcançada usando as operações da teoria de conjuntos nebulosos ao invés das operações da teoria de conjuntos binários. O componente ART nebulosa na rede ARTMAP nebulosa 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 ([4]). O algoritmo resumido da rede neural ART nebulosa consiste, basicamente, nos seguintes passos ([4, 5]):

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 arbitrado com um valor 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 $[0,1]$) sofre uma codificação complementar preliminar. Isto produz um vetor de entrada I de $2n$ elementos, tal que:

$$I = (a, a^c) = (a_1, a_2, \dots, a_n, a_1^c, a_2^c, \dots, a_n^c) \quad (3)$$

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:

$$T_j = \frac{|I \wedge w_j|}{\alpha + |w_j|}, \quad (4)$$

em que o operador \wedge é o operador nebuloso *and*, definido por:

$$(p \wedge q)_i \equiv \min(p_i, q_i), \text{ com } p \text{ e } q \in \mathfrak{R}^{2n}, \quad (5)$$

e a norma $|\cdot|$ é definida por:

$$|p| \equiv \sum_{i=1}^{2n} |p_i|. \quad (6)$$

O sistema é dito fazer a escolha da categoria quando no máximo um neurônio torna-se ativo. A categoria escolhida é indexada por J , em que:

$$T_J = \max \{T_j : j = 1, \dots, 2n\}. \quad (7)$$

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:

$$|I \wedge w_J| \geq \rho |I|. \quad (8)$$

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 o critério ser satisfeito para aquela entrada. Um novo índice J é, então, escolhido pela equação (7). O processo de busca continua até que o índice J escolhido satisfaça a equação (8).

Passo 5. Atualização do vetor protótipo

Encerrada a busca, o vetor peso w_J é atualizado de acordo com a seguinte equação:

$$w'_J = \beta (I \wedge w_J) + (1 - \beta) w_J \quad (9)$$

O treinamento rápido corresponde a fixar $\beta = 1$.

A substituição do operador de interseção *crisp* (não nebuloso) (\cap), que descreve a dinâmica da rede ART1, pelo operador nebuloso *and* (\wedge) da teoria de conjuntos nebulosos na escolha, busca e leis de treinamento de ART1, leva a uma versão mais poderosa da rede ART1. Esta generalização é no sentido de melhorar o desempenho da rede no que se refere, principalmente, ao tempo de execução do treinamento e, também, no processamento de dados analógicos.

2.3 Algoritmo ARTMAP Nebuloso

A arquitetura ARTMAP, introduzida recentemente, é uma rede mais sofisticada. É designada para treinar e realizar o mapeamento entre dois espaços de vetores, usando ambas leis de treinamento supervisionado e não-supervisionado. Este modelo é composto por duas sub-redes ART1: ARTa e ARTb. A primeira rede ARTMAP foi utilizada para classificar vetores de entradas binários, cada elemento do vetor indicando a presença ou ausência de uma dada característica. Uma rede ARTMAP mais geral foi proposta para classificar vetores de entrada cujos elementos assumem valores nebulosos, entre 0 e 1, indicando o nível de presença de cada característica. Esta generalização é alcançada substituindo os módulos ART1 de ARTMAP por módulos ART nebuloso. A nova rede é conhecida como rede ARTMAP nebulosa ([5]).

O sistema ARTMAP nebuloso, na sua forma geral, inclui dois módulos ART nebuloso (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 *match tracking* ([5, 6, 9]), que aumenta o parâmetro de vigilância da rede ARTa por uma quantia mínima necessária para corrigir um erro preditivo.

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. A arquitetura ARTMAP nebulosa é mostrada na Figura 2.

Durante o treinamento supervisionado ARTa recebe uma corrente de padrões de entrada $\{a^M\}$ e ARTb recebe uma corrente de padrões $\{b^M\}$, em que b^M é a predição correta dada a^M . Quando uma predição em ARTa não é confirmada por ARTb, a inibição da memória associativa inter-ART ativa o processo *match tracking*. 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 ([5]). A

rede neural ARTMAP nebulosa realiza treinamento supervisionado como o *backpropagation*. Mas diferente do

algoritmo *backpropagation*, a rede ARTMAP nebulosa é auto-organizável, auto-estabilizável e apropriada para treinamento em tempo-real ([5, 6]).

Baseada na observação que o treinamento da rede ARTMAP leva a diferentes pesos adaptativos e diferentes categorias de reconhecimento para diferentes ordenações de um dado conjunto de treinamento, introduz-se uma *estratégia de votação* ([9]).

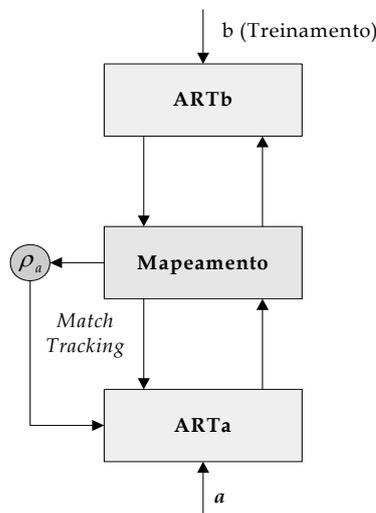


Figura 2 – Arquitetura ARTMAP nebulosa

A *estratégia de votação* usa um sistema ARTMAP que é treinado diversas vezes com diferentes ordenações para o mesmo conjunto de treinamento. A predição final é dada pelas soluções geradas com maior frequência. Como o conjunto de elementos que fazem predições errôneas varia de uma simulação para a próxima, esta estratégia cancela muitos dos erros. Existem diversas variações da rede ARTMAP, como pode ser visto, e.g., na referência [25]. Cada qual visando adaptar-se aos problemas que pretendem resolver e maximizar o seu desempenho.

3. MODELO DO SISTEMA

Apresenta-se, nesta seção, o modelo que descreve a dinâmica do sistema de energia elétrica, considerando-se as grandes oscilações (grande aumento de carga, saída de equipamento elétrico de operação, curto-circuito, etc.). Trata-se do modelo da máquina síncrona e sua integração ao sistema. Este modelo é representado por equações algébricas e diferenciais não-lineares. A análise deste modelo permite inferir sobre a estabilidade do sistema. Os defeitos a serem considerados são curtos-circuitos trifásicos combinando com a saída das linhas sob falta. Esta idealização é baseada na observação de que um curto-circuito causado por descarga atmosférica, que incide sobre o sistema de transmissão, ocorre em linha exposta, visto que os demais equipamentos encontram-se protegidos. Deste modo, quando ocorrer este evento, para fins de simplificação, transfere-se a falta para o barramento mais próximo. A eliminação da falta consiste, então, na retirada de operação, via proteção do sistema, da linha onde ocorreu a descarga atmosférica que rompeu o isolamento e provocou o curto-circuito. O curto-circuito trifásico é adotado por ser o mais severo, ainda que a sua ocorrência seja a mais rara entre todos os tipos de curtos-circuitos.

Considerando-se o caso mais severo, permite efetuar a análise para a situação mais crítica.

O objetivo desta pesquisa é investigar a aplicação de redes neurais artificiais (rede neural ARTMAP) para a realização da análise de estabilidade transitória. Considera-se a análise de estabilidade de primeira oscilação onde pode-se empregar o chamado modelo clássico ([1, 3, 8, 17]). 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 ([3, 8, 17]). 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. Os dados de entrada e de saída serão fornecidos por um programa computacional que foi implementado baseado na proposta apresentada na referência [7], que é uma metodologia que emprega a resolução das equações diferenciais (método indireto) e o método da energia (método direto). Este método é, portanto, híbrido e iterativo pois fornece o cálculo da margem de segurança (e o tempo crítico) do sistema para uma lista preestabelecida de contingências. Os resultados são bastantes precisos, cujos erros observados são apenas procedentes de arredondamentos e da tolerância adotada.

Deve-se ressaltar que não há restrição quanto à 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). Se utilizada a simulação como gerador dos estímulos de entrada/saída, a informação que se poderia obter da rede neural seria apenas: o sistema é estável, ou o sistema é instável associado a cada contingência.

Quando se empregam o modelo clássico e um método de análise fundamentado na função energia do sistema, a representação dos ângulos das máquinas síncronas, referidas ao Centro de Ângulos (CA) ([3, 17]), constitui a melhor opção, visto que as perdas elétricas, que são o grande obstáculo para a aplicação dos métodos da energia, podem ser mais facilmente incorporadas no modelo. Esta será, então, a alternativa a ser seguida nesta pesquisa.

O modelo da dinâmica do sistema de Energia Elétrica, expresso em função de ângulos/velocidades das máquinas síncronas referidos ao CA (Centro de Ângulos), constitui-se na melhor formulação quando se consideram as condutâncias de transferência – representação do efeito das perdas e cargas ativas do sistema no modelo reduzido às barras internas de geração – tendo em vista que durante o transitório eletro-mecânico, cada máquina síncrona absorve as variações da carga total do sistema proporcionalmente às suas inércias. Esta representação é, certamente, mais plausível do ponto de vista físico.

Considerando-se um Sistema de Energia Elétrica composto por ng máquinas síncronas, o comportamento dinâmico da i -ésima máquina pode ser descrito pela seguinte equação diferencial (equação de oscilação da máquina síncrona) ([1, 3, 17]):

$$M_i \ddot{\theta}_i - g_i(\theta) = 0, \quad i \in N \quad (10)$$

sendo:

$$g_i(\theta) = Pm_i - Pe_i - (M_i PCOA) / MT; \quad (11)$$

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

$$H_i = \text{constante de inércia (s)};$$

$$\omega_s \triangleq \text{velocidade síncrona (rad. elét/s)}$$

$$= 2\pi f_0;$$

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

$$\theta_i \triangleq \text{ângulo do rotor da } i\text{-ésima máquina síncrona referida ao CA (rad. elét.)}$$

$$= \delta_i - \delta_0;$$

$$\delta_i = \text{ângulo do rotor da } i\text{-ésima máquina síncrona medida com relação a uma máquina que gira à velocidade síncrona (rad. elét.);}$$

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

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

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

$$PCOA \triangleq \text{potência acelerante do CA}$$

$$= \sum_{j \in N} (Pm_j - Pe_j);$$

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

$$N \triangleq \{ 1, 2, \dots, ng \}$$

$$= \text{conjunto de índices das máquinas que compõem o sistema};$$

ng = número de máquinas síncronas.

A potência elétrica usada na equação (11), considerando-se as simplificações introduzidas no modelo clássico, pode ser calculada de várias formas. Uma delas, e mais comum, consiste em realizar o cálculo, a partir da matriz de admitância reduzida às barras internas de geração, como proposto em [1, 17]. Trata-se de um procedimento rápido do cálculo da potência elétrica, principalmente, quando esta refere-se à condição de falta (período de permanência do curto-circuito) e pós-falta (eliminação da falta com saída da linha de transmissão), empregando o método proposto na referência [14].

4. ANÁLISE DE ESTABILIDADE TRANSITÓRIA

O diagnóstico da estabilidade transitória de SEE, considerando-se uma contingência de índice r , pode ser efetuado utilizando-se o critério da margem de segurança ([3, 7, 17]):

$$M_r = (E_{crit_r} - E_{e_r}) / E_{crit_r} \quad (12)$$

sendo:

E_{crit_r} = energia total crítica do sistema;

E_{e_r} = energia total do sistema avaliada no instante de eliminação do defeito (te).

A energia crítica (E_{crit}), assim como o tempo crítico (t_{crit}), poderão ser determinados através do método PEBS (*Potential Boundary Surface*) ([3, 7]), ou por outro procedimento que apresente um resultado similar, principalmente com relação a precisão.

Ressalta-se que quando são consideradas as condutâncias de transferência, a expressão (11) não se caracteriza como uma força potencial ([14]), conseqüentemente, não é possível determinar uma função energia potencial do sistema – representada pela primeira integral do movimento – que se constitui como dependente do caminho de integração. Porém, por abuso de linguagem, neste trabalho, o termo Energia Total do Sistema será utilizado sempre que houver referência à função tipo energia. Por conseguinte, a energia total, relativa ao sistema (1), é dada por ([3, 7, 17]):

$$E(\theta, \omega) = E_c(\omega) + E_p(\theta) \quad (13)$$

sendo:

$E_c(\omega)$ = energia cinética

$$= 0.5 \sum_{i \in N} M_i \omega_i^2 \quad (14)$$

$E_p(\theta)$ = energia potencial

$$= - \sum_{i \in N} \int_{\theta^p}^{\theta_i} g_i(\theta) d\theta_i \quad (15)$$

Então, a estabilidade transitória para a r -ésima contingência pode ser avaliada, via margem de segurança, da seguinte forma ([7, 14]):

- 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*, do ponto de vista da estabilidade transitória.

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 que, a partir dos dados da rede elétrica, considerando-se uma lista de contingências (curto-circuito trifásico com saída de linha de transmissão), provem os valores das margens de segurança associadas. Na seqüência, procede-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 da estabilidade transitória de sistemas de energia elétrica que corresponde à determinação da margem de segurança, considerando-se faltas de curto-circuito trifásico com saída de linha de transmissão. Os

estímulos de entrada (X) e de saída (Y), para a fase de treinamento, são definidos usando um programa computacional híbrido ([7]), que emprega o conceito de simulação e o Método Direto de Lyapunov (método da energia). Assim, os vetores padrões de entrada da rede neural (entrada do módulo ARTa) são definidos como ([13, 16]):

$$X_r \triangleq [P^T \ Q^T \ A_r^T]^T \quad (16)$$

sendo:

X_r = vetor padrão correspondente a r -ésima contingência;

P = $[P_1 \ P_2 \ \dots \ P_{ns}]^T$;

Q = $[Q_1 \ Q_2 \ \dots \ Q_{ns}]^T$;

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

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

A_r = vetor que contém os índices das contingências representado em código binário [0,+1].

O padrão X é um vetor n -dimensional:

$$n = 2ns + nb \quad (17)$$

em que:

ns = número de barras do sistema;

nb = número de *bits* correspondente ao número (índice) da contingência.

Neste caso, levando-se em conta o modelo clássico, é razoável utilizar somente as potências ativa e reativa para a avaliação da estabilidade transitória, que corresponde à análise usando-se o critério da margem de segurança (Seção 4). Isto porque a topologia da rede e demais parâmetros (constante de inércia, reatância transitória, etc.) são considerados constantes. A idéia é utilizar somente as variáveis causais (potências ativa e reativa) e os parâmetros que expressam alterações na rede (representação das contingências).

O número de *bits* (nb) de A é consideravelmente menor do que $2ns$. Deste modo, a dimensão do vetor padrão (16) é significativamente menor, se comparada às principais propostas encontradas na literatura para a resolução do problema usando redes neurais.

Tendo em vista que os componentes do vetor de entrada da rede neural ARTMAP devem estar compreendidos entre 0 e 1, o vetor padrão (equação (16)) deverá ser normalizado. Considerando-se que o vetor A_r já satisfaz esta condição (números binários), a normalização será aplicada somente ao subvetor $[P^T \ Q^T]^T$:

$$\underline{X}_r \triangleq [\underline{S}^T \ A_r^T]^T \quad (18)$$

sendo:

$$\underline{S} = \frac{S}{|S|};$$

$$|S| = \sum_{i=1}^n |S_i|;$$

$$S = [P^T \ Q^T]^T.$$

Com isto, procura-se preservar a característica dos dados binários e formam-se dois subvetores que não apresentam interações diretas entre si, sendo, portanto, independentes. Este procedimento não é significativo para a fase de treinamento, contudo, a princípio, proporciona melhores condições para uma boa predição. Se houver necessidade, a normalização, também, poderá ser realizada considerando-se o vetor completo X_r . Poderão, ainda, ser empregadas outras formas que atendem o critério em que todos os elementos do vetor X_r estejam contidos no intervalo [0,1], por exemplo, aplicando-se a função sigmóide em cada componente, ou parte dos componentes de X_r .

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 (12).

A estratégia proposta 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 considerada como 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*, conforme estabelecido na seguinte definição ([14]):

Definição 1. Define-se *Esforço de Deslocamento da Margem de Segurança* (EDMS) como sendo uma função que relaciona as margens de segurança inicial e final de um determinado intervalo da seguinte forma:

$$\mathcal{G} = (1 - M^A) / (1 - M^B) - 1 \quad (19)$$

sendo:

\mathcal{G} = 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 ([13]):

$$I_k \triangleq (M^A_k, M^B_k) \quad (20)$$

em que:

I = intervalo considerado;

k = índice que indica o k -ésimo intervalo.

A equação (19) dá a noção de quanto a relação Ee / E_{crit} (Ee = valor da energia da contingência e E_{crit} = energia crítica da contingência), referente à margem de segurança final (M^B), é menor se comparada ao valor desta relação calculada na condição inicial (M^A). A unidade subtraída em (19) é empregada para ajustar a equação de tal modo que se tenha $\mathcal{G} = 0$ quando $M^B = M^A$ (neste caso, nenhum esforço é observado). Nota-se que \mathcal{G} é definido no intervalo $[0, +\infty)$ e possui crescimento significativo à medida que M^B se aproxima de 1.

O conceito de EDMS foi empregado na referência [14] com o propósito de resolver o problema de controle de segurança que corresponde à determinação de um perfil de geração que atenda a carga do sistema, de forma segura, do ponto de vista da estabilidade transitória. A correção a ser efetuada no sistema, a partir de um estado inseguro ($M < 0$), é terminada através de vários passos até atingir um resultado desejado ($M \geq M_{min}$, sendo M_{min} = margem de segurança mínima preestabelecida). Estes passos são idealizados via sucessivas linearizações do modelo de um sistema não-linear bastante complexo (conjunto de equações algébricas e diferenciais não-lineares). Atribuindo-se um valor fixo para \mathcal{G} , os intervalos de linearizações podem ser inferidos, ou seja, o erro em cada segmento se mantém na mesma ordem de grandeza. Portanto, o EDMS serve como um parâmetro para estabelecer a validade das linearizações e, conseqüentemente, estimar a região, no espaço de estado, em que se pode resolver o referido problema, através de um modelo linear, sem que haja comprometimento da precisão dos resultados.

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

O esforço da margem de segurança pode ser atribuído, com segurança, até o valor igual a 1,5 ([14]), *i.e.*, o erro a ser observado é relativamente pequeno. A escolha de $\mathcal{G} = 0,35$ foi fixada visando formar um grupo de intervalos que cubra todo o espectro de variação da margem de segurança e com um número razoável de segmentação. Deve-se destacar que este número pode ser arbitrado livremente, sem necessidade de efetuar alterações substanciais na rede neural. O que muda é apenas o número de *bits* na representação binária da contingência. Para uma maior precisão da margem de segurança, maior deverá ser o número de intervalos. Como ilustração, considerando-se 4, 5 e 6 *bits* pode-se trabalhar, respectivamente, com 15, 31 e 63 intervalos.

Com esta representação (Tabela 1), têm-se 15 classes de saída, independentemente do número de contingências. Esta alternativa de solução é bastante vantajosa para o treinamento da rede e, principalmente, para a atividade do treinamento continuado, pois facilmente podem inserir-se novas informações com o objetivo de tornar a extração do conhecimento mais efetiva.

Tabela 1 – Representação binária da saída da rede neural ARTMAP nebulosa.

Número	Margem de Segurança (M)	Intervalo da Margem de Segurança (I)	Representação Binária da Saída (I)
1	-3	Menor ou igual do que -3	0 0 0 1
2	-1,9630	(-3 ; -1,9630]	0 0 1 0
3	-1,1948	(-1,9630 ; -1,1948]	0 0 1 1
4	-0,6258	(-1,1948 ; -0,6258]	0 1 0 0
5	-0,2043	(-0,6258 ; -0,2043]	0 1 0 1
6	0,10790	(-0,2043 ; 0,10790]	0 1 1 0
7	0,33920	(0,10790 ; 0,33920]	0 1 1 1
8	0,51050	(0,33920 ; 0,51050]	1 0 0 0
9	0,63740	(0,51050 ; 0,63740]	1 0 0 1
10	0,73140	(0,63740 ; 0,73140]	1 0 1 0
11	0,80110	(0,73140 ; 0,80110]	1 0 1 1
12	0,85260	(0,80110 ; 0,85260]	1 1 0 0
13	0,89080	(0,85260 ; 0,89080]	1 1 0 1
14	0,91910	(0,89080 ; 0,91910]	1 1 1 0
15	0,94010	maior do que 0,9191	1 1 1 1

Ainda que as magnitudes dos intervalos sejam diferentes entre si, ou seja, tornam-se menores à medida que há aproximação da margem de segurança unitária, as “distâncias”, em termos de energia, são equivalentes. Para exemplificar, a quantidade de potência redespachada no sistema que produz uma alteração na margem de segurança de -3 para -1,9630 (Intervalo 2), produziria uma alteração da margem de segurança de 0,6374 para 0,7314 (Intervalo 10). Pode-se estender esta observação, também, aos demais intervalos. Estes resultados têm sido observados nas simulações apresentadas na referência [14]. Nota-se que neste trabalho não se aplica o redespacho de geração ou qualquer outra ação corretiva. O exemplo abordado é apenas ilustrativo, que serve unicamente para evidenciar a coerência de seu uso para a determinação dos referidos intervalos. Então, a saída será definida por:

$$Y \triangleq [I_k]^T \tag{21}$$

sendo:

Y = vetor de saída da rede neural;

I_k = vetor correspondente ao k -ésimo intervalo da margem de segurança associada à contingência representada em código binário.

O k -ésimo intervalo I_k associado à i -ésima contingência (margem de segurança M^i) é definido observando-se a relação $M^i \in I_k$.

6. APLICAÇÃO

Nesta seção serão apresentados os resultados da análise de estabilidade transitória de sistemas elétricos de potência, através da rede neural ARTMAP nebulosa, considerando-se um sistema teste que corresponde a uma possível configuração do sistema elétrico sul-brasileiro ([14]). Para o treinamento da rede neural, foram considerados quatro níveis de geração para atender a demanda de energia. Estes níveis foram adotados considerando-se quatro percentuais do caso base (correspondentes aos dados relacionados na referência [14]). Este procedimento não é tão plausível do ponto de vista da operação. A forma mais adequada é utilizar os dados do despacho diário de geração, por exemplo, através de uma estratégia de despacho econômico ([11]). Estes perfis de geração deveriam ser, por conseguinte, utilizados como dados de entrada para gerarem as margens de segurança (que é o enfoque empregado nesta pesquisa) e, conseqüentemente, obterem os intervalos das margens de segurança. Contudo, a opção, considerando tais percentuais (geração/cargas proporcionais), não invalida o emprego de despachos que são obtidos por outros procedimentos. A metodologia apresentada neste trabalho não depende do tipo de vetor que está sendo apresentado na entrada da rede. Porém, em pesquisas futuras, deverão ser incluídos estudos que contemplem, também, conjuntos de pares de treinamento mais realistas. Assim sendo, serão apresentados os resultados da análise de estabilidade transitória, através da rede neural ARTMAP nebulosa, que serão comparados com os fornecidos pelo método PEBS Iterativo ([7]). Esta comparação tem por objetivo testar a metodologia proposta. Deve-se ressaltar que, o que se pretende é propor uma metodologia de análise da estabilidade transitória para aplicações *on-line*, ou seja, que gere os diagnósticos, de forma rápida e, evidentemente, que sejam confiáveis.

Tabela 2 – Resultados da análise da estabilidade transitória (margens de segurança) obtidos através do programa PEBS Iterativo que serão utilizados no treinamento da rede neural.

Falta Número	Margem de Segurança			
	80% do Caso Base	90% do Caso Base	100% do Caso Base	110% do Caso Base
11(11-25)	0,9023	0,8502	0,7632	0,5735
13(13-45)	0,9681	0,9532	0,9327	0,9060
13(13-35)	0,9708	0,9565	0,9362	0,9095
15(14-15)	0,9045	0,8768	0,8354	0,8012
24(24-35)	0,9835	0,9748	0,9631	0,9481
18(18-19)	0,1270	-0,5417	-1,6596	-4,0761
18(16-18)	0,3865	0,0710	-0,4799	-1,8010
18(18-44)	0,4234	0,0709	-0,4804	-1,3000
25(11-25)	0,9642	0,9455	0,9097	0,7767
25(25-26)	0,9721	0,9613	0,9494	0,9342
29(29-30)	0,9414	0,8851	0,8123	0,7043
33(33-36)	0,7721	0,6845	0,5532	0,3465
35(35-45)	0,9112	0,8747	0,8260	0,7640
39(39-40)	0,6145	0,4295	0,1233	-0,2283
39(15-39)	0,7239	0,6178	0,4560	0,2475

Estes resultados foram gerados através do programa PEBS Iterativo. Este programa fornece os resultados da análise (tempo crítico e margem de segurança). Trata-se de um método híbrido constituído por um método de integração numérica (séries de Taylor truncadas, *i.e.*, são preservados somente os primeiros termos das séries) e o método da energia (que é um caso particular do método direto de Lyapunov ([17])). Este método foi escolhido porque proporciona resultados bastantes precisos, com tempo de execução reduzido. Esta precisão refere-se essencialmente quando se considerando o modelo clássico. Esta técnica, a princípio, não se aplica a modelos mais elaborados como, por exemplo, o modelo completo de Park ([1]) e tantos outros disponíveis na literatura técnica.

Tabela 3 – Dados de saída (intervalos I) para a fase de treinamento da rede neural.

Falta	Intervalo (I)			
	80% do Caso Base	90% do Caso Base	100% do Caso Base	110% do Caso Base
11(11-25)	14	12	11	9
13(13-45)	15	15	15	14
13(13-35)	15	15	15	14
15(14-15)	14	13	12	12
24(24-35)	15	15	15	15
18(18-19)	7	5	3	1
18(16-18)	8	6	5	3
18(18-44)	8	6	5	3
25(11-25)	15	15	14	11
25(25-26)	15	15	15	15
29(29-30)	15	13	12	10
33(33-36)	11	10	9	8
35(35-45)	14	13	12	11
39(39-40)	9	8	7	5
39(15-39)	10	9	8	7

Na Tabela 3 são apresentadas as saídas para o treinamento da rede neural, considerando-se as contingências relacionadas na Tabela 3 para $\rho = 0,35$. As saídas correspondem aos intervalos I , conforme definidos na Tabela 1, representados em código binário.

Na Tabela 4 são relacionados os resultados da análise de estabilidade transitória, via método PEBS Iterativo, para os perfis de geração/carga correspondentes a 85, 95, 105 e 115% medidos em relação ao caso base. Estes resultados foram obtidos com o propósito de servir como referência para comparação com os resultados obtidos com a utilização da rede neural ARTMAP nebulosa.

Tabela 4 – Resultados da análise da estabilidade transitória (margens de segurança) obtidos através do programa PEBS Iterativo para fins de comparação com os resultados gerados pela rede neural ARTMAP nebulosa.

Falta Número	Margem de Segurança			
	85% do Caso Base	95% do Caso Base	105% do Caso Base	115% do Caso Base
11(11-25)	0,8752	0,8105	0,6958	0,3985
13(13-45)	0,9614	0,9439	0,9197	0,8883
13(13-35)	0,9642	0,9473	0,9233	0,8917
15(14-15)	0,8914	0,8552	0,8124	0,7773
24(24-35)	0,9795	0,9696	0,9560	0,9375
18(18-19)	-0,1502	-0,9363	-2,3377	-4,5873
18(16-18)	0,2490	-0,1638	-1,1022	-2,8241
18(18-44)	0,2974	-0,1638	-1,1067	-2,4539
25(11-25)	0,9630	0,9316	0,8543	0,6331
25(25-26)	0,9678	0,9552	0,9417	0,9243
29(29-30)	0,9176	0,8486	0,7540	0,6744
33(33-36)	0,7325	0,6258	0,4622	0,1971
35(35-45)	0,8986	0,8496	0,7979	0,7230
39(39-40)	0,5199	0,3175	0,0000	-0,5274
39(15-39)	0,6588	0,5459	0,3823	0,1351

O treinamento da rede neural ARTMAP nebulosa foi realizado utilizando-se os seguintes parâmetros:

- Parâmetro de vigilância inicial da rede ARTa ($\bar{\rho}_a$) = 0,4;
- Parâmetro de vigilância da rede ARTb (ρ_b) = 0,99;
- Parâmetro de vigilância do módulo inter-ART (ρ_{ab}) = 0,95;
- Parâmetro de escolha α = 1;
- Parâmetro de treinamento β = 0,99;
- Número de intervalos (I) = 15.

O conjunto de pares de treinamento é constituído por 60 padrões de entrada/saída. As dimensões dos vetores de entrada e de saída são, respectivamente, 94 e 5. São considerados 15 intervalos definidos como mostrados na Tabela 1. Estes padrões são empregados visando a execução do treinamento da rede em ordem aleatória. Na ordem natural (ordem em que os vetores são lidos) os vetores são apresentados, quase sempre, numa seqüência previsível. Portanto, a ordem aleatória é empregada com o objetivo de “destruir” esta formação lógica. Neste caso, o treinamento torna-se mais eficiente e mais imune aos vícios que porventura possam estar presentes no conjunto de pares de treinamento.

Após a realização do treinamento da rede neural ARTMAP nebulosa, procede-se a obtenção das análises de contingências. Pretende-se apresentar a análise comparativa entre os resultados padrões (via método PEBS Iterativo) e os resultados obtidos pela rede neural. As comparações são efetivadas usando como função de inferência o intervalo da margem de segurança (I). Como visto anteriormente, o intervalo I refere-se ao conjunto de valores da margem de segurança compreendido entre um valor mínimo ($Mmin$) e um valor máximo ($Mmax$). Os limites de cada intervalo I são definidos usando o conceito de esforço de deslocamento da margem de segurança (\mathcal{G}). Assim, cada contingência estando contida em um determinado intervalo I ($Mmin$, $Mmax$), terá uma margem de segurança esperada entre $Mmin$ e $Mmax$ que, neste trabalho, foram definidos na Tabela 1, considerando-se para $\mathcal{G} = 0,35$. O acerto ou não desta predição é observado comparando-o com o intervalo I indicado pelo método PEBS Iterativo. Pode-se, ainda, implementar um esquema mais segmentado (maior número de intervalos I) adotando-se valores menores para \mathcal{G} com o propósito de tornar a análise mais precisa. Neste caso, ter-se-á 5 ou mais *bits* para a representação das saídas (em código binário).

Deste modo, são apresentados os resultados das análises de contingências considerando-se os níveis de carregamento iguais a 85, 95, 105 e 115%. De acordo com a *estratégia de votação*, foram executados 7 treinamentos considerando-se ordens aleatórias diferentes. Deve-se destacar que seqüências diferentes de apresentação de padrões, na fase de treinamento, produzirão alocações diferentes nas atividades F_2^a e F_2^b nas redes ARTa e ARTb, respectivamente. O módulo inter-ART proporciona o devido acerto (casamento) entre os módulos ARTa e ARTb. Em alguns casos, tendo em vista os erros de arredondamentos, bem como do mecanismo de geração dos indicadores (vencedores de ARTa e ARTb), poderão ocorrer estes ruídos. Na maioria das vezes a adoção da estratégia de votação com 5 simulações é suficiente para obter resultados satisfatórios. Este processo, ainda que realizado com repetição de treinamento, é bastante rápido. Para destacar, considerando-se o exemplo que está sendo abordado (60 padrões em que a entrada e saída possuem 94 e 5 (188 e 10 na forma com complemento) componentes, respectivamente), para uma única seqüência de treinamento são consumidos em torno de 20 centésimos de segundo para realizar a fase de treinamento (que é o maior volume de cálculo). O treinamento, com a inclusão da estratégia de votação, é realizado na ordem de 1 segundo com o equipamento computacional como anteriormente

especificado (Pentium III/500 MHz).

Considerando-se, portanto, a maior frequência de ocorrência nos casos treinados, apresentam-se na Tabela 5 as previsões fornecidas pela rede neural ARTMAP nebulosa. Nesta tabela constam, também, os resultados obtidos através do método PEBS Iterativo para fins comparativos.

Tabela 5 – Resultados comparativos das previsões fornecidas pela rede neural ARTMAP nebulosa e o algoritmo PEBS Iterativo.

Falta	Carregamento							
	85% do Caso Base		95% do Caso Base		105% do Caso Base		115% do Caso Base	
	PEBS Iterativo	ARTMAP Nebulosa	PEBS Iterativo	ARTMAP Nebulosa	PEBS Iterativo	ARTMAP Nebulosa	PEBS Iterativo	ARTMAP Nebulosa
11(11-25)	13	12	12	11	10	9	8	9
13(13-45)	15	15	15	15	15	14	13	14
13(13-35)	15	15	15	15	15	14	14	14
15(14-15)	14	13	13	13	12	12	11	12
24(24-35)	15	15	15	15	15	15	15	15
18(18-19)	6	7	4	5	2	1	1	1
18(16-18)	7	8	6	6	4	5	2	3
18(18-44)	7	6	6	5	4	3	2	3
25(11-25)	15	15	15	14	13	14	9	11
25(25-26)	15	15	15	15	15	15	15	15
29(29-30)	14	15	12	13	11	10	10	10
33(33-36)	11	11	9	10	8	8	7	8
35(35-45)	14	14	12	13	11	13	10	11
39(39-40)	9	9	7	8	6	5	5	5
39(15-39)	10	10	9	8	8	7	7	7

Analisando-se os resultados mostrados na Tabela 5, pode-se concluir que a rede neural ARTMAP nebulosa proporciona soluções que podem ser consideradas satisfatórias, em termos de precisão. Em alguns casos, não houve coincidência entre a previsão via rede neural ARTMAP nebulosa e o método PEBS Iterativo (considerado como referência em termos de precisão). Isto ocorreu, provavelmente, em consequência do número pequeno de exemplos empregados no treinamento. A precisão aumenta à medida em que se emprega conjunto de treinamento mais volumoso (maior número de estímulos). Para destacar, a rede não poderá prever contingências contidas nos intervalos 2 e 4, tendo em vista que o conjunto de treinamento não contém nenhum par de treinamento nestes intervalos (há ausência de oportunidade de ensinamento). Há intervalos em que ocorreu baixa frequência de contingências (por exemplo, os intervalos 1, 3, 6, 7, 10 e 13). Tudo isto contribui para reduzir o nível de exatidão das previsões. Há, também, outro fator intrínseco da rede neural ARTMAP importante neste contexto, ou seja, as classes são estabelecidas baseadas no emprego do conceito de hiper-retângulos, cujas dimensões dependem do tamanho dos parâmetros de vigilâncias, tanto do módulo ARTa, assim como do módulo ARTb. O parâmetro de vigilância da rede ARTb é fixado através da entrada de dados, porém, a magnitude do parâmetro de vigilância do módulo ARTa depende do mecanismo de sintonia exercido pelo módulo inter-ART. Considerando-se um conjunto de padrões de entrada/saída, através da rotina de treinamento, os agrupamentos de classes são definidos sem que haja o controle pelo usuário, que se caracteriza como uma desvantagem do método. Contudo, esta desvantagem pode ser minimizada, através do emprego de um adequado planejamento do conjunto de dados para o treinamento. Deste modo, haverá um maior ou menor número de contingências contidas em um determinado hiper-retângulo. Isto contribui para a ocorrência de casos em que a previsão falha ao indicar um determinado intervalo vizinho ao intervalo em que deveria ser a escolha correta. Para ilustrar este detalhe, toma-se como exemplo uma coleção de figuras composta por triângulos, quadrados e círculos. Deseja-se identificar as figuras semelhantes. Com o devido ajuste do parâmetro de vigilância (ρ) pode-se perfeitamente agrupar triângulos, quadrados e círculos em três classes. Cada classe deverá estar contida em um hiper-retângulo. Se atribuirmos um determinado valor para ρ , os agrupamentos poderão ser formados, por exemplo, em que um deles conterà os círculos e o outro, quadrados e triângulos. Se diminuirmos ainda mais o parâmetro ρ , haverá um único agrupamento contendo todas as figuras que poderiam ser chamadas coletivamente apenas de “coisas”. Neste caso, não há condições de fazer distinções sobre estes objetos. Deste modo, pode-se concluir que, à medida que ρ diminui, haverá um aumento da generalização e um decréscimo da precisão. No sentido inverso, aumentando-se o parâmetro de vigilância, diminuir-se-á a generalização e aumentar-se-á a precisão dos resultados. A rede ARTMAP, através da interface inter-ART, uma vez arbitrado um valor do parâmetro de vigilância da rede ARTb, estabelecerá, de forma automática, o nível de generalização e precisão dos resultados.

O tempo de processamento, referente à fase de treinamento, é assim distribuído:

- Tempo para uma etapa de treinamento:
 ≈ 12 centésimos de segundo;

- *Tempo para a realização do mecanismo da estratégia de votação (5 simulações):*
 ≈ 1 segundo.

A análise deste sistema, se empregada a rede neural *feedforward* com treinamento via algoritmo retropropagação, formulação convencional ([24]), pode ser concluída em um tempo total de processamento de 15 segundos ([15]) (treinamento realizado com aproximadamente 5400 ciclos de adaptações). Deste modo, pode-se concluir que a rede neural ARTMAP nebulosa é consideravelmente mais rápida, se comparada à rede neural retropropagação.

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. Esta rede é composta por dois módulos de redes neurais ART (*Adaptive Resonance Theory*) ([8–13]) e um módulo inter-ART que executa a interface entre as duas redes neurais, proporcionando a sintonia dos padrões de entrada e de saída. O módulo ART é uma rede neural não-supervisionada (treinamento baseado em estímulos somente de entrada). As redes neurais ART apresentam as características de estabilidade (garantia da obtenção de uma solução) e plasticidade (permite elaborar a adaptação do classificador sem destruir o conhecimento adquirido previamente). Interligando-se estas duas redes neurais (ARTa para a recepção da entrada e ARTb para a recepção da saída na fase de treinamento), através do módulo inter-ART, confere à rede ARTMAP o treinamento supervisionado. A rede neural ARTMAP, formulada através dos operadores lógico-nebulosos, além de tornar mais rápido o treinamento, se comparada à rede ARTMAP convencional ([8]), permite o mapeamento entre entradas analógicas/binárias e saídas analógicas/binárias. 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 uma possível configuração do sistema da região sul do Brasil composto por 45 barras, 73 linhas de transmissão e 10 máquinas síncronas. O treinamento foi realizado considerando-se 60 contingências de curto-circuito trifásico sólido com saída de linha de transmissão. As contingências foram arbitradas como incidentes em vários pontos da rede elétrica (15 localizações). Foram considerados 4 níveis de carregamentos lineares correspondentes a 80, 90, 100 e 105% do caso base. Para as previsões, foram consideradas as mesmas contingências, porém, com carregamentos correspondentes a 85, 95, 105 e 115%.

Os resultados obtidos podem ser considerados satisfatórios, ou seja, atingiram o objetivo proposto, que foi 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 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. 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 I). Um maior número de segmentos pode ser obtido tomando-se valores menores para o parâmetro \mathcal{S} (esforço de deslocamento da margem de segurança). 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). Todavia, há sempre a garantia na obtenção das soluções (característica de estabilidade), com precisão adequada ou não. O principal destaque da rede neural ARTMAP refere-se à característica de plasticidade. Com esta propriedade pode-se conceber mecanismos que contemplem o treinamento continuado (adaptação do classificador) sem destruir o conhecimento extraído anteriormente (observa-se que maioria das redes neurais propostas na literatura especializada, a adaptação do classificador pressupõe a reinicialização do processo, destruindo o conhecimento adquirido anteriormente). Deste modo, a rede neural estará permanentemente se aperfeiçoando o que irá proporcionar soluções cada vez mais precisas. Ressalta-se que o esquema de adaptação do classificador pode ser implementado com um tempo de execução, também, bastante reduzido. Para destacar, se utilizados no treinamento do exemplo abordado na Seção 6 os dados para previsões (carregamentos de 85 a 115% do caso base) e considerados outros perfis de geração/carga para previsões, os acertos ficam bem próximos de 100%. Assim, ter-se-iam resultados mais precisos, ainda, à medida que novos exemplos forem incorporados. Estes exemplos podem ser os resultados das simulações da análise de estabilidade que rotineiramente são obtidos pelas companhias do setor elétrico, bastando, apenas, incluir rotinas que realizem o pré-processamento destes resultados e adequadamente ser extraído o conhecimento de forma incremental pela rede neural ARTMAP.

Agradecimentos

Os Autores agradecem à FAPESP (Fundação de Amparo à Pesquisa do Estado de São Paulo) pelo suporte financeiro (Processos nº 99/04333-5 e 01/10689-9).

8. REFERÊNCIAS

- [1] P.M. Anderson, and A. A. Fouad: "Power system control and stability", IOWA State University Press, USA, 1977.
- [2] H. Assadi, A. Tan, M. Etezadi-Amoli, D. Egbert, and M.S. Fadali: "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.
- [3] T. Athay, V.R. Sherket, R. Podmore, S. Virmani, and C. Puech: "Transient energy stability analysis", Conference on System Engineering For Power, Davos, Switzerland, 1979.
- [4] G. A. Carpenter, and S. Grossberg: "Pattern recognition by self-organizing neural networks", The MIT Press, Cambridge, Massachusetts, USA, 1991.
- [5] G. A. Carpenter, S. Grossberg, N. Markuzon, J. H. Reynolds, and D. B. Rosen: "Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps", IEEE Transactions on Neural Networks, Vol. 3, No. 5, September 1992, pp. 698-713.
- [6] G. A. Carpenter, and S. Grossberg: "A Self-organizing neural networks for supervised learning, recognition, and prediction", IEEE Communications Magazine, September 1992, pp.38-49.
- [7] L. G. S. Fonseca, and I. C. Decker: "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, 1985, pp. 483-489.
- [8] A. A. Fouad, and V. Vittal: "Power system transient stability analysis using the transient energy function method", Prentice Hall, Englewood Cliffs, New Jersey, 1992.
- [9] E. Granger, M. A. Rubin, S. Grossberg, and P. Lavoie: "A what-and-where fusion neural network for recognition and tracking of multiple radar emitters", Neural Networks, No. 14, 2001, pp. 325-344.
- [10] S. Haykin: "Neural networks: a comprehensive foundation", Prentice-Hall, Upper Saddle River, New Jersey, USA, 1994.
- [11] L. K. Kirchmayer: "Economic operation of power systems", John Wiley & Sons, New York, 1958.
- [12] S. Y. Kung: "Digital neural networks", PTR Prentice-Hall, Englewood Cliffs, N. Jersey, USA, 1993.
- [13] S. C. Marchiori: "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, Agosto-2001.
- [14] C. R. Minussi, and W. Freitas Filho: "Sensitivity analysis for transient stability", IEE Proceedings on Generation, Transmission And Distribution, Vol. 145, No. 6, pp. 669-674, 1998.
- [15] C. R. Minussi, L. M. Ramos, S. C. Marchiori, M. L. M. Lopes, and A. D. P. Lotufo: "Neural networks to transient stability analysis of electrical power systems", V Congresso Brasileiro de Redes Neurais, pp. 31-36, Rio de Janeiro – RJ, 2001.
- [16] C. R. Minussi, and M. C. G. Silveira: "Transient stability analysis of electric power systems by neural networks", 38th Midwest Symposium on Circuits And Systems, Rio de Janeiro – RJ, 1995, pp. 1305-1308.
- [17] M. A. Pai: "Power system stability", North Holland Control Series, 1981.
- [18] Y. H. Pao and D.J. Sobajic "Combined use of unsupervised and supervised learning for dynamic security assessment", IEEE PICA-91, pp. 278-284.
- [19] Y. M. Park, G. W. Kin, H. S. Cho, and K. Y.N Lee: "A new algorithm for Kohonen layer learning with application to Power system stability analysis", IEEE Transactions on Systems, Man, And Cybernetics, Vol. 27, No. 6, December 1997, pp. 1030-1033.
- [20] D. J. Sobajic, and Y.H. Pao: "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.
- [21] T. Terano, K. Asai, and M. Sugeno: "Fuzzy systems theory and its application", Academic Press, New York, USA, 1987.
- [22] P. D. Wasserman: "Neural computing - theory and practice", Van Nostrand Reinhold, New York, USA, 1989.
- [23] L. Wehenkel: "Machine-learning approaches to power-system security assessment", IEEE Expert Intelligent Systems & Their Applications, September/October 1997, pp. 60-72.
- [24] P. J. Werbos: "Beyond regression: new tools for prediction and analysis in the behavioral sciences", Master Thesis, Harvard University, 1974.
- [25] J. R. Williamson "Gaussian ARTMAP: a neural network for fast incremental learning of noisy multidimensional maps", Neural Networks, Vol. 9, No. 5, July 1996, pp. 881-897.