



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

Avaliação das condições de operação de sistemas elétricos de potência com relação à estabilidade de tensão utilizando redes neurais artificiais

Autor: Alberto Jiménez Cifuentes

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

Trabalho apresentado à Faculdade de Engenharia Elétrica e de Computação da UNICAMP como parte dos requisitos exigidos para a obtenção do título de Mestre em Engenharia Elétrica.

Comissão Examinadora:

Prof. Dr. Carlos Alberto de Castro Jr.	FEEC/UNICAMP
Prof. Dr. Alexandre P. Alves da Silva	COPPE/UFRJ
Prof. Dr. Luiz Carlos Pereira da Silva	FEEC/UNICAMP
Prof. Dr. Eduardo Nobuhiro Asada	FEEC/UNICAMP

Campinas, março de 2005.

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

J564a	Jiménez Cifuentes, Alberto Avaliação das condições de operação de sistemas elétricos de potência com relação à estabilidade de tensão utilizando redes neurais artificiais / Alberto Jiménez Cifuentes. --Campinas, SP: [s.n.], 2005. Orientador: Carlos Alberto de Castro Junior Dissertação (Mestrado) - Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação. 1. Sistemas de energia elétrica. 2. Redes neurais (Computação). 3. Sistemas de energia elétrica – Estabilidade. 4. Colapso (Eletricidade). 5. Potência reativa (Engenharia elétrica). I. Castro Junior, Carlos Alberto de. II. Universidade Estadual de Campinas. Faculdade de Engenharia Elétrica e de Computação. III. Título.
-------	---

Titulo em Inglês: Voltage stability assesment via artificial neural networks

Palavras-chave em Inglês: Electric power systems, Artificial neural networks, Stability of electric power systems, Voltage collapse e Reactive power

Área de concentração: Sistemas de Energia Elétrica

Titulação: Mestre em Engenharia Elétrica

Banca examinadora: Alexandre Pinto Alves da Silva, Luiz Carlos Pereira da Silva e Eduardo Nobuhiro Asada

Data da defesa:17/03/2005

Agradecimentos

São inúmeras as pessoas a quem gostaria de dizer o quanto sou imensamente grato pela contribuição e pelo apoio na realização desse trabalho. Foram dois anos muito proveitosos, se levadas em consideração todas as possibilidades de crescimento acadêmico e pessoal.

- A Deus em primeiro lugar.
- Ao Professor Carlos Alberto de Castro Jr. pela disposição para trabalhar comigo, excelente orientação, confiança, amizade e respeito.
- À Universidade Estadual de Campinas (UNICAMP) e à Universidade Nacional da Colômbia (UNAL) pela sua excelente qualidade acadêmica.
- À Coordenação de aperfeiçoamento pessoal de nível superior (CAPES) pelo apoio financeiro, essencial na realização deste trabalho de pesquisa.
- Ao meu grande amigo e irmão Enrique Niño por acreditar incondicionalmente em mim.
- Ao Departamento de Sistemas de Energia Elétrica (DSEE), a seus professores pela disposição e respeito que demonstraram sempre, à Miriam von Zuben pelo suporte eficaz, à Edna Servidone ser sempre prestativa e paciente. Sem o aporte de todos eles não existiria um ambiente tão propício para o desenvolvimento da pesquisa.
- Aos meus amigos do DSEE Walmir de Freitas, Marcos Rider, Adriana Schiffer, Irênio Júnior, Madson Cortes, Luis Zárate, Antônio Guerra, Maurício Salles, Ana Carolina Canoas, Ahda P. Grilo, Marcos Guimarães, Alexandre de Assis Mota, Lia Toledo Moreira Mota, José Carlos de Melo Vieira Jr. e João Ângelo Bosco Silva pela sua paciência e amizade.
- Ao povo brasileiro por me permitir conhecer parte da sua rica cultura.
- Ao Jairo e à Johana por terem aberto as portas de sua casa para mim
- À Piedade pela sua preocupação por meu bem-estar desde a minha chegada ao Brasil.

*Dedico este trabalho
à minha mãe, Inés;
à minha esposa, Magda;
à minha filha, Alejandra*

Resumo

As mudanças no setor elétrico têm influído de maneira drástica nas condições de operação dos sistemas, levando-os a operar próximos da sua máxima capacidade. Por esta razão, estimar a proximidade do ponto de operação da rede aos limites do sistema de forma eficiente tem se tornado uma tarefa fundamental na operação de sistemas elétricos de potência. Do ponto de vista da estabilidade de tensão é interessante conhecer a margem de carregamento, já que ela fornece uma idéia precisa da proximidade do sistema ao colapso de tensão. Este trabalho propõe o treinamento de redes neurais artificiais para avaliar a margem de carregamento sob condições de operação normais e de contingência a partir das informações coletadas da previsão de carga e usando diferentes grandezas mensuráveis diretamente do sistema ou através de cálculos simples, visando a aplicação desta metodologia num ambiente de tempo real.

Palavras-chave: Sistemas de potência, redes neurais artificiais, estabilidade de tensão, colapso de tensão, margens de segurança.

Abstract

Deregulation of electricity industry has drastically changed the operating conditions of power systems (*PS*). This fact leads them to operate close to their maximum capability. Thus, estimating efficiently the proximity of the operating point to its limits has become an essential task in *PS*. In static voltage stability analysis it is interesting to know the load margin (*LM*), which gives the proximity to the collapse point. This work proposes a neural network training in order to evaluate the *LM* not only under normal operating conditions, but also disturbance conditions, using either collected data of several measured parameters available from the system or through simple computations toward applying this methodology on real systems under on-line analysis.

Keywords: Power systems, artificial neural networks, voltage stability, voltage collapse, security margins.

Sumário

1	Introdução	1
2	Estabilidade de sistemas elétricos de potência	5
2.1	Aspectos gerais	6
2.1.1	Transmissão de potência ativa [11]	6
2.1.2	Transmissão de potência reativa	8
2.2	Estabilidade de ângulo do rotor [12]	9
2.3	Estabilidade de Tensão [10, 11]	10
2.3.1	Classificação da Estabilidade de Tensão [11]	10
2.3.1.1	Tamanho da perturbação	11
2.3.1.2	Período de análise	11
2.3.2	Metodologias de análise da Estabilidade de Tensão [11]	12
2.3.2.1	Abordagem Dinâmica	12
2.3.2.2	Abordagem Estática	13
2.4	Colapso de Tensão	14
2.4.1	Ilustração do fenômeno	15
2.4.2	Deteção e prevenção do colapso de tensão	19
3	Estimação da margem de estabilidade de tensão usando <i>RNA</i>'s	21
3.1	Introdução	21
3.2	Cenário de aplicação	21
3.3	Estrutura proposta	27
3.3.1	Variáveis de entrada	28
3.3.1.1	Variáveis do fluxo de carga	28

3.3.1.2	Vetor tangente	33
3.3.1.3	Índice lpq	33
3.3.2	Principal Component Analysis (PCA) [48]	35
3.3.3	Rede neural multicamada	39
3.4	Testes	40
3.4.1	Região de operação	41
3.4.2	Aplicação do PCA	43
3.4.3	Estrutura da RNA	45
4	Resultados	49
4.1	Introdução	49
4.2	Topologia base	50
4.2.1	Sistema de 30 barras	50
4.2.2	Sistema de 57 barras	54
4.2.3	Sistema de 118 barras	57
4.2.4	Sistema de 300 barras	60
4.3	Situações de contingências	63
4.3.1	Sistema de 30 barras	64
4.3.2	Sistema de 300 barras	67
5	Conclusões	71
	Referências Bibliográficas	73
A	Redes Neurais Artificiais	81
A.1	Introdução	81
A.2	Modelo Biológico	82
A.3	Modelo Matemático [48]	84
A.3.1	Arquiteturas típicas	86
A.4	Aprendizado em RNA 's	88
A.4.1	Treinamento supervisionado	90
A.4.2	Treinamento não supervisionado [48]	90

A.4.2.1	Programação Neurodinâmica	90
A.4.2.2	Aprendizado auto-organizado	91
A.5	Redes neurais multicamada	91
A.5.1	Algoritmos de treinamento	92
A.5.1.1	Back-propagation [56]	92
A.5.1.2	Algoritmos de treinamento baseados em técnicas de otimização [57]	94
A.5.2	Aproximação de funções	96
A.5.3	Processamento de dados	96
B	Divulgação da pesquisa	99

Lista de Figuras

2.1	Modelo de rede de duas barras.	6
2.2	Curva Potência-ângulo.	7
2.3	Curva Potência reativa-ângulo.	8
2.4	Circuito equivalente.	16
2.5	Diagrama fasorial para rede de duas barras.	16
2.6	Curva PV para sistema de duas barras.	18
2.7	Espaço de soluções.	19
2.8	Indicadores de proximidade ao colapso de tensão.	20
3.1	Curva de previsão de demanda.	22
3.2	Distribuição probabilística do erro de previsão.	23
3.3	Margens de estabilidade de tensão previstas, $\sigma_e = 1.2\%$	24
3.4	Margens de estabilidade de tensão previstas, $\sigma_e = 3\%$	24
3.5	Margens de estabilidade de tensão previstas, $\sigma_e = 6\%$	24
3.6	Variações máximas e mínimas de carga ($\sigma_e = 1.2\%$).	25
3.7	Variações máximas e mínimas de carga ($\sigma_e = 3\%$).	25
3.8	Variações máximas e mínimas de carga ($\sigma_e = 6\%$).	25
3.9	Margens previstas para diferentes topologias.	26
3.10	Estrutura proposta	27
3.11	Estrutura proposta com divisão do sistema em áreas	27
3.12	Comportamento da tensão.	29
3.13	Comportamento do ângulo.	29
3.14	Comportamento da potência ativa.	30
3.15	Comportamento da potência reativa.	30

3.16	Comportamento dos fluxos de potência ativa.	31
3.17	Comportamento dos fluxos de potência reativa.	31
3.18	Comportamento das perdas de potência ativa.	32
3.19	Comportamento das perdas de potência reativa.	32
3.20	Inversa do vetor tangente.	33
3.21	Índice l_{pq}	35
3.22	Resultados de treinamento para $\sigma_e = 1.2\%$	41
3.23	Resultados de treinamento para $\sigma_e = 3\%$	42
3.24	Resultados de treinamento para $\sigma_e = 6\%$	42
3.25	Resultados de treinamento sem redução de entradas.	43
3.26	Resultados de treinamento aplicando PCA $\sigma_{PCA}^2 = 1 \times 10^{-3}$	44
3.27	Resultados de treinamento aplicando PCA $\sigma_{PCA}^2 = 1 \times 10^{-5}$	44
3.28	Resultados de treinamento com 1 neurônio na camada escondida.	45
3.29	Resultados de treinamento com 5 neurônios na camada escondida.	46
3.30	Resultados de treinamento com 7 neurônios na camada escondida.	46
4.1	Treinamento com índice l_{pq} como entrada.	50
4.2	Testes de validação usando índice l_{pq} como entrada.	51
4.3	Treinamento com V, P, Q como entradas para 3 áreas do sistema.	51
4.4	Testes de validação usando V, P, Q como entradas para 3 áreas do sistema.	52
4.5	Treinamento com vetor tangente como entrada.	54
4.6	Testes de validação usando vetor tangente como entrada.	55
4.7	Treinamento com V, P, Q como entradas	55
4.8	Testes de validação usando V, P, Q como entradas	56
4.9	Treinamento com a magnitude de tensão como entrada.	58
4.10	Testes de validação usando a magnitude de tensão como entrada.	58
4.11	Treinamento com V, P, Q como entradas para 3 áreas do sistema.	59
4.12	Testes de validação usando V, P, Q como entradas para 3 áreas do sistema.	59
4.13	Treinamento com V, P, Q como entradas.	61
4.14	Testes de validação usando V, P, Q como entradas.	61
4.15	Treinamento com V, P_p, Q_p como entradas para 3 áreas do sistema.	62

4.16	Testes de validação usando V, P_p, Q_p como entradas para 3 áreas do sistema.	62
4.17	Testes de validação usando V, P_p, Q_p como entradas para 3 áreas do sistema.	64
4.18	Testes de validação para condições de contingência.	65
4.19	Testes de validação para condições de contingência.	65
4.20	Testes de validação para condições de contingência.	66
4.21	Testes de validação usando V, P_p, Q_p como entradas.	68
4.22	Testes de validação para condições de contingência.	68
4.23	Testes de validação para condições de contingência.	69
4.24	Testes de validação para condições de contingência.	69
A.1	Neurônio biológico.	83
A.2	Modelo matemático do neurônio biológico.	84
A.3	Funções de ativação típicas.	86
A.4	Rede neural de camada única.	87
A.5	Rede neural multicamada.	87
A.6	Rede neural recorrente.	88
A.7	Treinamento supervisionado.	90
A.8	Programação neurodinâmica.	91
A.9	Rede neural 3-3-2.	92
A.10	Pré-processamento de dados.	97

Lista de Tabelas

3.1	Faixa de variação da potência.	26
3.2	Redução do número de entradas em sistema IEEE 30.	37
3.3	Redução do número de entradas em sistema IEEE 57.	38
3.4	Redução do número de entradas em sistema IEEE 118.	38
3.5	Redução do número de entradas em sistema IEEE 300.	38
4.1	Configurações testadas no sistema IEEE de 30 barras.	53
4.2	Configurações testadas no sistema IEEE de 57 barras.	57
4.3	Configurações testadas no sistema IEEE de 118 barras.	60
4.4	Configurações testadas no sistema IEEE de 300 barras.	63
4.5	Testes no sistema IEEE de 30 barras para casos de contingência.	67
4.6	Testes no sistema IEEE de 300 barras para casos de contingência.	70

Capítulo 1

Introdução

O modelo do setor elétrico vem experimentando mudanças radicais durante os últimos anos tais como a liberação dos preços, a introdução da concorrência entre os diferentes agentes do mercado e a privatização dos ativos do setor. Estas são algumas das mudanças que vêm forçando as empresas a otimizar seus recursos minimizando custos para serem competitivas, o qual faz com que os investimentos na ampliação da capacidade instalada não acompanhem o crescimento da demanda.

Estes fatos têm colaborado para levar os sistemas elétricos a operarem muito próximos de seus limites, forçando a necessidade de implementar procedimentos e ferramentas que permitam conhecer com eficiência o grau de proximidade a esses limites, fazendo a operação segura e permitindo tirar o máximo proveito dos recursos disponíveis no sistema.

Tradicionalmente os problemas de estabilidade eram associados à perda de sincronismo dos geradores e à incapacidade de satisfazer a carga demandada. Isto mudou quando foram observados eventos nos quais a frequência e os ângulos de fase das tensões não se alteraram de forma sensível, mas as magnitudes das tensões sofreram sérias variações.

O problema da instabilidade de tensão foi analisado por diferentes abordagens, e hoje existem na literatura diversos procedimentos que permitem avaliar o nível de segurança em termos da estabilidade de tensão. Um deles consiste em calcular a margem de carregamento, a qual fornece a distância entre ponto de operação e o limite da rede, em termos de fácil interpretação.

No entanto, os métodos atuais de cálculo da margem ainda não satisfazem as necessidades de eficiência desejadas pelos operadores do sistema e resultam lentos e pouco aplicáveis em situações em tempo real. Por outro lado, ferramentas novas como a inteligência artificial, especialmente as Redes Neurais Artificiais (*RNA's*) vêm mostrando resultados interessantes em inúmeras aplicações em diversos campos do conhecimento.

As *RNA*'s têm se caracterizado por sua habilidade na solução de problemas complexos, altamente não lineares, onde a solução é obtida sem necessidade da formulação analítica de um modelo. Em lugar disso, um processo conhecido como “*treinamento*” mapeia a função desejada através de um conjunto de exemplos entrada-saída. Além disso, após serem treinadas fornecem a resposta com mínimo esforço computacional.

Estas características fazem que as *RNA*'s sejam ideais como alternativa de solução do problema de avaliação da margem de carregamento em sistemas elétricos de potência. Isto vem sendo explorado desde começos da década de 90 em trabalhos como os apresentados por Vadari e Venkata [1] onde os autores formularam em 1991 conceitos teóricos sobre as possibilidades da aplicação de metodologias de inteligência artificial na avaliação da estabilidade de sistemas elétricos. Nesse mesmo ano Hui e Short [2] sugeriram uma abordagem baseada no mínimo valor singular, monitorando o comportamento da barra crítica do sistema, usando como vetor de entrada as injeções de potência, a compensação de reativos e uma variável discreta que representava a posição do tap. Whenkel [3] realizou comparações entre as diferentes técnicas de aprendizagem de redes neurais para o caso específico da avaliação da margem de estabilidade de tensão.

A partir de trabalhos como os citados acima o número de publicações que usavam as redes neurais como ferramenta de avaliação das condições de estabilidade multiplicaram-se, incluindo diferentes abordagens de análise do problema e tipos de redes neurais diferentes das multicamada que têm sido as preferidas. El-Keib e Ma [7] estimaram a menor margem de energia a partir de fatores de sensibilidade e recentemente, Chen e Mohler [4] analisaram o efeito que a dinâmica da carga tem na estabilidade de tensão usando redes neurais recorrentes aproveitando a habilidade da rede neural de captar as principais sensibilidades da carga, para posteriormente avaliar a estabilidade usando análise modal.

Dado que uma das principais dificuldades de aplicar *RNA*'s para resolver problemas relacionados com os sistemas de potência é a grande dimensão dos conjuntos de treinamento. Foram apresentadas alternativas para minimizar os dados requeridos em trabalhos como o de Jeyasurya [5], onde foi proposta a utilização de técnicas estatísticas para reduzir o número de variáveis de entrada. Em [7] foram analisados métodos de sensibilidade para escolher as grandezas que seriam usadas no treinamento da *RNA*. Posteriormente em [6], aproveitando a estrutura formulada em [5], foram feitas comparações entre dois métodos de redução do conjunto de dados, avaliando a capacidade de generalização e os efeitos dos diferentes métodos de treinamento de *RNA*'s no desempenho e o no esforço computacional necessário para realizar essa tarefa.

Nos trabalhos anteriormente citados mostrou-se que as *RNA*'s conseguiam estimar eficientemente a margem de estabilidade de tensão para uma estrutura topológica dada usando um conjunto reduzido de dados de entrada. No entanto, para casos de contingências os autores sugeriam o treinamento de redes neurais para cada condição topológica de forma separada.

Neste trabalho serão estudadas diferentes alternativas que permitem estimar de forma precisa e rápida a margem de estabilidade de tensão, visando sua aplicação em tempo real tanto para condições normais de operação quanto sob a ocorrência de contingências. Para isto, é proposta a delimitação eficiente do cenário de operação a partir das informações obtidas do processo de previsão de carga, e a análise de várias configurações de variáveis de entrada que permitam obter informações precisas da operação do sistema com relação à estabilidade de tensão sob diferentes estruturas topológicas usando uma única *RNA*.

Durante o desenvolvimento deste trabalho apresentam-se conceitos básicos de estabilidade de sistemas elétricos de potência, focando-se principalmente em métodos estáticos da análise de estabilidade, como são as curvas PV. Logo após é descrito o método proposto definindo o cenário de aplicação, a metodologia de obtenção, seleção e dimensionamento dos conjuntos de treinamento assim como sua estrutura e algumas considerações sobre as incidências dos principais parâmetros. Os resultados obtidos para condições de operação normais e de contingência são apresentados neste mesmo capítulo. Finalmente aparecem algumas conclusões e comentários adicionais referentes aos tópicos tratados, ao método proposto e são sugeridas algumas idéias para futuros trabalhos de pesquisa.

Uma descrição geral das Redes Neurais Artificiais incluindo a apresentação de seus fundamentos, modelos básicos, diferentes tipos de redes, e os algoritmos usados para o treinamento; pode ser encontrada nos anexos da dissertação.

Capítulo 2

Estabilidade de sistemas elétricos de potência

A estabilidade de sistemas elétricos de potência pode ser definida como a propriedade de manter um estado de equilíbrio sob condições normais de operação, e de atingir um novo estado de operação aceitável após a ocorrência de perturbações. [10]

Outros conceitos referentes à estabilidade em sistemas elétricos foram propostos em [42], sendo definida a *Estabilidade de Regime Permanente* como a condição de operação, onde, após sofrer uma pequena perturbação o sistema encontra uma estado de operação idêntico ou muito próximo da condição pré-distúrbio. Para este sistema, o *Limite de estabilidade de Regime Permanente* é uma condição de operação para a qual o sistema é estável, mas onde uma pequena perturbação numa direção desfavorável pode levá-lo à instabilidade.

A análise de estabilidade de um sistema relaciona-se com o seu comportamento quando sujeito a distúrbios. A magnitude e severidade desses distúrbios é muito ampla. Eles podem apresentar-se em forma de alterações de carga, as quais ocorrem de forma permanente obrigando o sistema a ajustar seu estado de operação. O sistema também deve ser capaz de suportar grandes perturbações, como por exemplo, um curto-circuito numa linha de transmissão, a perda de um grande gerador ou o desligamento de uma carga importante. Por exemplo, no caso de um curto-circuito em algum equipamento importante, seguido pelo isolamento da falta graças à atuação dos relés de proteção; o que causa variações nas transferências de potência, nas velocidades dos rotores das máquinas e nas tensões nas barras próximas a falta. Estas alterações nas variáveis do sistema farão os equipamentos de controle atuarem para levar o sistema de forma rápida e segura a um estado de operação estável. Os efeitos das ações de controle e a mesma perturbação que poderiam levar o sistema para um estado de instabilidade são analisadas a partir de várias ópticas dependendo da abordagem do problema, tal como apresentado nas seções seguintes deste capítulo.

Embora a estabilidade de sistemas elétricos de potência seja um único problema, re-

sulta muito mais prático e conveniente enfrentá-lo diferenciando os fatores mais relevantes envolvidos, os quais geralmente são classificados segundo os critérios a seguir:

- A natureza física da instabilidade
- A dimensão da perturbação
- Os dispositivos e o intervalo de tempo considerados para a determinação das condições de estabilidade
- Os métodos de análise mais apropriados para o cálculo e determinação das condições de estabilidade

2.1 Aspectos gerais

Nesta seção serão apresentados os conceitos básicos da transmissão de potência elétrica através de um modelo simples de um sistema de duas barras (ver Figura 2.1), porém bastante descritivo dos processos de transmissão, o qual permite obter algumas idéias sobre a operação segura da rede.




Figura 2.1: Modelo de rede de duas barras.

2.1.1 Transmissão de potência ativa [11]

A figura 2.1 apresenta um sistema composto por dois geradores síncronos, interligados por uma linha de transmissão modelada por uma reatância equivalente. Assumindo ambas tensões fixas, e calculando os fluxos de potência para a barra r (receptora), tem-se:

$$\begin{aligned}
 S_r &= P_r + jQ_r = E_r I^* \\
 &= E_r \left[\frac{E_s \cos \delta + j E_s \sin \delta - E_r}{jX} \right]^* \\
 &= \frac{E_s E_r}{X} \sin \delta + j \left[\frac{E_s E_r \cos \delta - E_r^2}{X} \right]
 \end{aligned}$$

$$P_r = \frac{E_s E_r}{X} \sin \delta = P_{max} \sin \delta \quad (2.1)$$

$$Q_r = \frac{E_s E_r \cos \delta - E_r^2}{X} \quad (2.2)$$

Analogamente, para a barra s (emissora):

$$P_s = \frac{E_s E_r}{X} \sin \delta = P_{max} \sin \delta \quad (2.3)$$

$$Q_s = \frac{E_s^2 - E_s E_r \cos \delta}{X} \quad (2.4)$$

As equações 2.1 e 2.3 são iguais já que as perdas foram desconsideradas na modelagem. Plotando a equação 2.1 ou 2.3 é possível verificar que a máxima transferência de potência ocorre para $\delta = 90^\circ$ (figura 2.2). Este ponto também representa o limite de estabilidade do sistema, pois para ângulos menores de 90° considera-se a operação estável e a partir desse valor entra-se na região instável.




Figura 2.2: Curva Potência-ângulo.

A observação anterior pode ser verificada supondo a barra r como infinita com velocidade e ângulo fixos e simulando um acréscimo da potência mecânica injetada no gerador da barra s , isto produziria um aumento do ângulo δ , que no caso da região instável, o incremento no ângulo produziria uma redução na potência elétrica fornecida, seguida de uma nova aceleração, e um novo aumento do ângulo, o que obrigaria o desligamento da máquina. Já na região estável, o aumento na potência mecânica seria compensado pelo incremento da potência elétrica, resultando num novo estado estável de operação.

Para ângulos pequenos é válido linearizar as expressões 2.1 e 2.3 assumindo $\sin \delta \cong \delta$, e reescrevê-las como $P \cong P_{max} \delta$. Ficando claro que a transmissão de potência ativa está estreitamente relacionada com a abertura angular entre as barras do sistema.

2.1.2 Transmissão de potência reativa

Dada a relevância que tem a transmissão de potência reativa para a estabilidade de tensão, é interessante analisar as exigências da rede para a transmissão de grandes quantidades de potência ativa. Isto pode ser feito assumindo $E_s = E_r$ e plotando as equações 2.2 e 2.4. Observa-se no gráfico da figura 2.3 que para altos níveis de transferência de potência ativa são necessárias grandes quantidades de potência reativa no sistema, sendo necessário gerar a mesma quantidade de potência ativa e reativa no limite de estabilidade ($\delta = 90^\circ$).




Figura 2.3: Curva Potência reativa-ângulo.

Usando o modelo da figura 2.1 para avaliar a potência reativa que pode ser transmitida pela linha, e supondo o fluxo de potência ativa igual a zero. As equações de potência nas barras em termos de $V_s \angle \theta$ e $V_r \angle \theta$ ficam:

$$Q_r = \frac{V_s V_r \cos \theta - V_r^2}{X} \quad (2.5)$$

$$Q_s = \frac{V_s^2 - V_s V_r \cos \theta}{X} \quad (2.6)$$

Baseando-se na suposição de que $P_s = P_r = 0$, e reescrevendo as equações de forma aproximada usando $\cos \theta \cong 1$, tem-se:

$$Q_r = \frac{V_r (V_s - V_r)}{X} \quad (2.7)$$

$$Q_s = \frac{V_s (V_s - V_r)}{X} \quad (2.8)$$

Das equações anteriores observa-se que a transmissão de potência reativa depende principalmente da magnitude da tensão, e que os fluxos de potência reativa vão da barra de

maior, para a de menor tensão.

Uma outra consideração importante a ser analisada, devido ao impacto negativo que tem sobre a operação econômica do sistema, é o efeito que a transmissão de potência reativa tem sobre as perdas do sistema geral, pois elas afetam a operação econômica do mesmo. Calculando as perdas em função da transferência de potência têm-se:

$$I^2 = I \cdot I^* = \left[\frac{P - jQ}{\bar{V}^*} \right] \cdot \left[\frac{P + jQ}{\bar{V}} \right] = \left[\frac{P^2 + Q^2}{V^2} \right]$$
$$P_{loss} = I^2 R = \left[\frac{P^2 + Q^2}{V^2} \right] R \quad (2.9)$$

$$Q_{loss} = I^2 X = \left[\frac{P^2 + Q^2}{V^2} \right] X \quad (2.10)$$

De 2.9 e 2.10 é possível observar que para minimizar as perdas no sistema é necessário reduzir a transferência de potência reativa e manter um perfil de tensão alto.

Dos conceitos tratados nesta seção, é importante salientar os seguintes fatos, pois serão relevantes no desenvolvimento da metodologia proposta neste trabalho.

- P está estritamente ligado com δ .
- Q está acoplado com V .
- Para satisfazer grandes demandas de potência ativa requerem-se injeções importantes de reativos.
- A transmissão de potência reativa não é conveniente pois eleva as perdas no sistema.
- A transmissão de potência reativa requer diferenças de tensão importantes entre as barras de geração e carga do sistema.

2.2 Estabilidade de ângulo do rotor [12]

A estabilidade de ângulo do rotor corresponde à habilidade das máquinas síncronas do sistema interligado de permanecer em sincronismo. O problema de estabilidade envolve o estudo das oscilações eletromecânicas inerentes ao sistema de potência, analisando fundamentalmente a maneira pela qual as saídas de potência dos geradores síncronos variam enquanto os ângulos dos rotores oscilam.

A estabilidade corresponde a uma situação de equilíbrio entre forças opostas. Máquinas síncronas interconectadas mantêm o sincronismo umas com as outras através de um mecanismo de atuação de forças de restabelecimento do equilíbrio, que ocorre sempre que aparecem forças que tendem a acelerar ou desacelerar uma ou mais máquinas com relação às demais. Em uma situação de regime permanente, há um equilíbrio entre o conjugado mecânico de entrada e o conjugado elétrico de saída de cada máquina, e a velocidade permanece constante. Quando o sistema é perturbado, os rotores das máquinas sofrerão aceleração ou desaceleração, que pode ser quantificada através da modelagem das máquinas usando as leis de movimento de corpos em rotação. Se um gerador temporariamente acelera em relação aos demais, a posição angular do seu rotor em relação àquela das máquinas mais lentas sofrerá um avanço. A diferença angular resultará em uma transferência de parte da carga das máquinas mais lentas para as mais rápidas. Isto tende a reduzir a diferença de velocidade e portanto a diferença angular. Porém, devido às não linearidades dos componentes do sistema, alguns distúrbios podem levar a situações em que o aumento da diferença angular é acompanhado por uma diminuição na transferência de carga entre os geradores. Nestes casos, a diferença angular aumenta ainda mais, levando à instabilidade. Sob situações de distúrbio, a estabilidade do sistema depende da existência de forças de restabelecimento suficientes para compensar os aumentos das diferenças angulares.

2.3 Estabilidade de Tensão [10, 11]

A estabilidade de tensão em sistemas de elétricos de potência pode ser definida como a habilidade do sistema em manter magnitudes de tensão aceitáveis em todas as barras tanto em condições normais de operação, quanto após a ocorrência de perturbações [10].

Um sistema entra em estado de instabilidade de tensão, quando uma perturbação, seja aumento de carga ou alguma modificação na configuração sistema, causa um progressivo e incontrolável declínio nas tensões, associado principalmente à incapacidade do sistema de atender a demanda de potência reativa necessária para manter as tensões em níveis aceitáveis.

Situações extremas de carregamento do sistema podem desencadear fenômenos de instabilidade de tensão, devidos aos grandes fluxos de potência ativa e reativa que circulam através das reatâncias indutivas do sistema de transmissão, causando quedas de tensão importantes nas barras envolvidas.

2.3.1 Classificação da Estabilidade de Tensão [11]

Devido à grande complexidade do fenômeno de instabilidade de tensão, resulta conveniente dividir o estudo em diferentes categorias a fim de facilitar sua análise.

2.3.1.1 Tamanho da perturbação

Para fins de estudo, o problema de estabilidade de tensão é dividido em duas categorias de acordo com o tamanho da perturbação analisada:

- *Pequenas perturbações*: estuda a estabilidade após a ocorrência de distúrbios leves, tais como pequenas variações de carga. Sob esta abordagem as características das cargas e as interações entre os dispositivos de controle e proteção têm um papel fundamental, sendo válida a utilização de modelos de regime permanente.

De esta forma, abordagens e modelos de regime permanente podem ser usados com sucesso na determinação de margens de estabilidade, identificar fatores determinantes no fenômeno, e estudar uma ampla gama de condições de operação, incluindo cenários pós-contingência.

- *Grandes perturbações*: estuda o fenômeno frente a ocorrência de grandes perturbações como podem ser faltas ou a perda de unidades geradoras importantes. Com a particularidade que este tipo de eventos exige uma análise minuciosa dos componentes do sistema, sendo necessária uma modelagem detalhada através de sistemas de equações algébrico-diferenciais não-lineares, analisando o comportamento da rede por um período de tempo suficientemente amplo que permita a atuação de equipamentos com tempos de resposta longos.

2.3.1.2 Período de análise

A necessidade de analisar problemas associados com a resposta do sistema a distúrbios severos, que vêm acompanhados de grandes variações na tensão, frequência e fluxos requerem a modelagem de dispositivos de ação lenta que geralmente são desconsiderados em estudos de estabilidade transitória (caldeiras, controle de geração, sistema de proteção, etc). Tudo isto trouxe conceitos novos como a estabilidade de médio e longo prazo. Segundo estes conceitos, os períodos de tempo para análise considerados são:

- *Curto prazo (transitório)*: está associada ao regime transitório do sistema com tempos que oscilam entre 0 e 10 segundos. Em eventos deste tipo é difícil diferenciar com clareza se o fenômeno está relacionado com instabilidade de ângulo do rotor ou com estabilidade de tensão, já que ambas podem coexistir.
- *Médio prazo*: estes tipos de eventos estão relacionados principalmente à ação dos taps dos transformadores e dos reguladores de tensão de distribuição assim como também

com a resposta dos limitadores de corrente de campo dos geradores envolvendo tempos entre 10 segundos a alguns minutos. Esta condição geralmente relaciona-se com variações abruptas de carga, grandes distúrbios, após os quais o sistema pode ser estável sob o ponto de vista transitório pela existência de cargas dependentes da tensão, mas pode-se tornar instável alguns minutos depois pela ação dos limitadores de corrente de campo e dos reguladores de tensão que reduzem o corte natural de carga sensível a tensão.

- *Longo prazo*: os tempos de ocorrência vão de 10 minutos a dezenas de minutos, estando influenciados, além das características do cenário de médio prazo, pela ação de equipamentos de controle de resposta lenta, esquemas de proteção e mesmo pela intervenção do operador do sistema.

2.3.2 Metodologias de análise da Estabilidade de Tensão [11]

A instabilidade de tensão é um processo essencialmente dinâmico, ditado basicamente pelo comportamento dinâmico das cargas e a interação dos mecanismos de controle. Porém análises realizadas [25] mostraram que sob certas condições, análises estáticas e dinâmicas podem levar a resultados similares, mas também mostraram que para algumas situações devem ser consideradas as características dinâmicas dos componentes do sistema.

Na literatura encontra-se uma grande quantidade de trabalhos relacionados à estabilidade de tensão baseados em diversos métodos que podem ser reunidos em dois grupos principais, segundo o enfoque usado. Em seguida são apresentadas essas abordagens.

2.3.2.1 Abordagem Dinâmica

Esta abordagem considera o fenômeno de forma detalhada, possibilitando uma maior compreensão dos mecanismos que afetam o perfil de tensão do sistema. A principal restrição desta abordagem reside na grande complexidade da modelagem, já que é preciso desenvolver modelos para os equipamentos do sistema, resultando em um sistema de equações algébrico-diferenciais não lineares de alta ordem, o qual aumenta as exigências computacionais para resolvê-los.

Simulações de incidentes de instabilidade de tensão evidenciam a necessidade de incluir modelos detalhados dos transformadores reguladores, cargas sensíveis a tensão (impedância, corrente e também de potência constante), como motores de indução e as controladas termostaticamente, que são as principais responsáveis pelo colapso de tensão [25].

Uma primeira aproximação baseia-se na linearização das equações dinâmicas do sistema, simplificando desta forma a análise do comportamento da rede na vizinhança do ponto

de operação. Esta abordagem é conhecida como *análise de pequenas perturbações*, que usa a estrutura da matriz Jacobiana e algumas informações como seus autovalores e outros índices que permitem tirar informações da estabilidade em regime permanente do sistema [23, 24].

A teoria matemática das bifurcações tem se apresentado como uma alternativa útil na análise não linear. Nelas, a instabilidade de tensão é caracterizada por uma mudança nos valores do modelo que representa o sistema de potência. Usam-se modelos estáticos antes da bifurcação, e modelos dinâmicos imediatamente após a bifurcação. A bifurcação é causada pela anulação de um autovalor do sistema que acontece no ponto de colapso de tensão [9].

As simulações não lineares no domínio do tempo permitem a reprodução mais precisa possível do fenômeno da instabilidade de tensão, sendo úteis na coordenação dos dispositivos de controle e de proteção. Porém implicam em alto custo computacional, e além disso, não fornecem informações em relação à estabilidade de tensão. As suas aplicações estão restritas à investigação e esclarecimento de eventos específicos de colapso de tensão [29].

2.3.2.2 Abordagem Estática

Os métodos estáticos de análise de estabilidade são essencialmente baseados nas equações do fluxo de potência ou alguma generalização das mesmas. Em geral, estes métodos buscam responder questões relativas do estado de operação com respeito ao limite de estabilidade de tensão, bem como os mecanismos da instabilidade [8].

Os métodos tradicionais de análise mais conhecidos e usados pelas empresas de energia elétrica são os de curvas P-V e Q-V obtidas para as barras do sistema. Essas curvas são obtidas a partir de sucessivas soluções de fluxos de carga convencional, o que incrementa o esforço computacional. Das curvas Q-V obtêm-se informações do comportamento da tensão numa barra enquanto a potência reativa injetada varia, permitindo obter a margem de reativos para cada barra da rede. As curvas P-V são obtidas de forma análoga e fornecem informação da demanda máxima que o sistema conseguirá atender.

Análises baseadas nas sensibilidades, partem das equações linearizadas dos fluxos de carga associando um decréscimo na tensão de uma barra a um incremento da demanda de potência reativa. O termo de sensibilidade é representado por $\Delta V/\Delta Q$. Sob o critério anterior, um sistema define-se como estável, se o valor de $\Delta V/\Delta Q$ for maior que zero para todas as barras do sistema [10], ou seja, a injeção de reativos em qualquer barra do sistema fará sua tensão aumentar. No limite de estabilidade os valores da sensibilidade tornam-se infinitos implicando em singularidade da matriz Jacobiana. Isto seria equivalente à ocorrência de uma bifurcação sela-nó, causada pela anulação de um autovalor do sistema.

Métodos de cálculo baseados em índices tem sido propostos amplamente na literatura.

tura [13, 46], buscando prover informações da proximidade ao colapso mediante um escalar (índice). Eles resultam interessantes, pois são rápidos quando comparados com outros métodos. Geralmente são baseados nas soluções dos fluxos de carga ou na matriz Jacobiana, com base no fato de que o colapso de tensão acontece no ponto onde esta matriz torna-se singular. Medidas do grau de singularidade da Jacobiana como o mínimo valor singular [30], mínimo autovalor e o grau de dominância da diagonal desta matriz [31] têm sido propostas.

Métodos de cálculo de margens medem a distância entre o ponto de operação e o limite de estabilidade do sistema, com a vantagem sobre os índices de serem facilmente interpretáveis pois possuem significado físico. Mas por outro lado consomem maior tempo computacional, apresentando limitações na aplicação em tempo real. Em [32] foi proposto um método direto para a obtenção do ponto de máximo carregamento. O método baseia-se na solução de um sistema de equações algébricas não lineares de grandes dimensões e de difícil solução. Porém, os métodos iterativos têm sido preferidos. Dobson [33] propôs um método para estimar a margem de segurança no espaço de parâmetros através de vetores normais à superfície de bifurcação, baseado na geometria da bifurcação sela-nó.

Com base em [28], Zeng e Galiana [34] propuseram um método simples de obtenção do ponto de máximo carregamento, que é estimado através de uma extrapolação feita a partir de alguns pontos de operação conhecidos. Em [35, 36] apresentou-se um algoritmo baseado em linearizações sucessivas das equações de fluxo de carga, e métodos que propõem determinar o quanto pode-se aumentar a carga de um sistema, até que as equações de fluxo de carga deixem de apresentar solução.

Métodos baseados em otimização também foram propostos na literatura, como por exemplo em [37–39]. Recentemente alguns estudos procuram incluir técnicas de inteligência artificial, como as redes neurais artificiais (*RNA's*), graças a sua capacidade de resolver problemas altamente não lineares [5, 6].

2.4 Colapso de Tensão

O colapso de tensão pode resultar como conseqüência de uma série de eventos associados com instabilidade, levando a perfis de tensão abaixo dos valores aceitáveis e podendo resultar em um blecaute total ou parcial devido a desligamentos em cascata de transformadores, geradores e linhas de transmissão.

Alguns incidentes mostraram que o colapso de tensão está associado com *bifurcações*, ou seja, pequenas alterações dos parâmetros do sistema podem resultar em comportamentos oscilatórios (*bifurcação de Hopf*) ou queda monotônica das tensões da rede (*bifurcação sela-nó*).

Este fenômeno é caracterizado por uma queda gradual das magnitudes das tensões em certas barras durante um período de tempo, até a ocorrência de uma queda abrupta. Por esta razão, o colapso poder ser considerado mais propriamente invariável que transitório, como um fenômeno dinâmico aperiódico não oscilatório, relativamente lento com constantes de tempo que variam de entre alguns segundos e vários minutos.

Nas últimas décadas têm acontecido inúmeros incidentes de instabilidade de tensão em diferentes lugares do mundo, entre os quais estão os colapsos de 1978 [17] e 1987 [18] ocorridos na França, o do Japão também em 1987 [16], o blecaute de 1982 na Bélgica [18], os eventos ocorridos na Suécia em 1982 e 1983 [17, 19, 20]. Recentemente, chamam a atenção os incidentes ocorridos na costa nordeste dos Estados Unidos e Canadá em 2003 [40] e os acontecidos no Brasil em 2005 [41].

Os incidentes com colapso de tensão relatados, em geral, estão intimamente ligados a redes com elevadas transferências de potência, e manifestam-se frequentemente como problemas ligados a uma área específica do sistema, ou seja, têm caráter local. O colapso de tensão ocorre quando o consumo de reativos é tal que o sistema não consegue atender a demanda de carga. Situação que é piorada pela atuação do controle automático dos *taps* dos transformadores e da redução dos níveis de excitação da geração.

Alguns incidentes envolvendo colapso de tensão foram causados por um inesperado aumento no nível de carga, às vezes combinado com condições anormais de operação do sistema, em momentos de grandes transferências de potência que foram agravados por distúrbios da rede, como a perda de uma linha de transmissão importante, de um gerador ou de um transformador, o que faz crescer substancialmente a demanda de reativos.

Em alguns casos a situação foi piorada pela atuação dos dispositivos de controle de tensão que em lugar de aliviar, aumentaram ainda mais a demanda de reativos, fazendo com que as tensões em certas barras da rede continuassem caindo [21, 22, 27]. Este fenômeno é conhecido como ação reversa dos OLTC (on-load tap changer). Assim, caso o sistema não tenha sido planejado adequadamente e não possua suporte local de reativos e procedimentos de emergência apropriados, um decréscimo monotônico de tensão acabará levando-o à perda de sua integridade.

2.4.1 Ilustração do fenômeno

Considere um cenário básico, onde o sistema elétrico de potência é representado por uma barra de geração tipo *slack*, e uma barra de carga tipo *PQ*, conectadas através de uma linha de transmissão modelada por uma impedância, tal como é apresentado na figura 2.4.

Embora o circuito apresentado seja um sistema extremamente simples, pode representar




Figura 2.4: Circuito equivalente.

um sistema maior, onde o restante da carga modela-se por um circuito equivalente Thévenin visto da barra de carga. Na figura 2.5 apresenta-se o diagrama fasorial das grandezas elétricas.




Figura 2.5: Diagrama fasorial para rede de duas barras.

A partir do diagrama fasorial, é possível chegar à seguinte expressão:

$$E^2 = (V + \Delta V_R)^2 + \Delta V_X^2 \quad (2.11)$$

Os termos ΔV_R e ΔV_X mostrados no diagrama fasorial, podem ser expressos da seguinte forma:

$$\begin{aligned} \Delta V_R &= RI \cos \phi + XI \sin \phi \\ \Delta V_X &= XI \cos \phi - RI \sin \phi \end{aligned} \quad (2.12)$$

A potência complexa na barra está dada por:

$$P + jQ = VI \cos \phi + jVI \sin \phi \quad (2.13)$$

Substituindo 2.12 e 2.13 em 2.11, para incluir os termos referentes à potência ativa e reativa, tem-se:

$$E^2 = \left(V + \frac{RP + XQ}{V} \right)^2 + \left(\frac{XP - RQ}{V} \right)^2 \quad (2.14)$$

Manipulando a equação 2.14, obtém-se:

$$E^2 = V^2 + 2(RP + XQ) + (R^2 + X^2) \left(\frac{P^2 + Q^2}{V^2} \right)$$

$$V^4 + [2(RP + XQ) - E^2] V^2 + (R^2 + X^2)(P^2 + Q^2) = 0 \quad (2.15)$$

Fazendo $x = V^2$ na equação 2.15, chega-se a uma expressão quadrática da forma:

$$ax^2 + bx + c = 0$$

onde,

$$\begin{aligned} a &= 1 \\ b &= 2(RP + XQ) - E^2 \\ c &= (R^2 + X^2)(P^2 + Q^2) \end{aligned}$$

As soluções para expressão 2.15 representadas por V^H e V^L , as quais correspondem às partes superior e inferior da curva respectivamente

$$V^H = \left(\frac{-b + d^{1/2}}{2a} \right)^{1/2} \quad (2.16)$$

$$V^L = \left(\frac{-b - d^{1/2}}{2a} \right)^{1/2} \quad (2.17)$$

Na qual d representa o discriminante da equação quadrática 2.15, dado por:

$$d = b^2 - 4ac \quad (2.18)$$

$$= E^4 + 4[2PQRX - E^2(RP + XQ) - R^2Q^2] \quad (2.19)$$

Para um dado fator de potência, conforme a carga aumenta, V^H decresce enquanto V^L aumenta; continuando de essa forma até que $V^H = V^L$, o que ocorre quando $d = 0$, conhecido como ponto crítico.

Na figura 2.6, apresenta-se o comportamento da magnitude da tensão na barra de carga em função da potência ativa demandada, mantendo fixo o valor de potência reativa $Q_2 = 0$.




Figura 2.6: Curva PV para sistema de duas barras.

O ponto crítico (P^{cr}, V^{cr}) ou ponto de máximo carregamento (PMC), constitui a fronteira entre a região factível (onde as equações do fluxo de potência têm solução) e a região infactível (onde não apresentam solução). Este ponto representa uma bifurcação sela-nó, que é caracterizado por apresentar o determinante da matriz Jacobiana nulo, portanto, a partir de um consumo superior a P^{cr} não haverá convergência do fluxo de carga. A potência crítica P^{cr} também representa a máxima potência que pode ser entregue à carga, portanto, é o ponto de máximo carregamento do sistema (PMC).

À medida que os níveis de transmissão aumentam, a relação R/X diminui, de forma que a reatância é muito mais representativa que a resistência. Portanto é válido desprezar o valor da resistência ($R = 0$). De esta maneira, a condição de solução da equação 2.15 ($d \geq 0$), ficaria:

$$-P^2 - \frac{E^2}{X}Q - \left(\frac{E^2}{2X}\right)^2 \geq 0 \quad (2.20)$$

Fazendo $Q = 0$, será possível obter o limite de potência ativa que pode ser entregue na barra de carga. Realizando um procedimento análogo para achar a máxima potência reativa que pode ser transmitida (assumindo $P = 0$), tem-se:

$$\begin{aligned} P &\leq \frac{E^2}{2X} \\ Q &\leq \frac{E^2}{4X} \end{aligned}$$

Ordenando convenientemente a equação 2.20, nota-se que corresponde a uma parábola

representado no plano $[P \times Q]$ da forma:

$$-\frac{QX}{E^2} - \left(\frac{PX}{E^2}\right)^2 + \frac{1}{4} \geq 0 \quad (2.21)$$

Qualquer solução para esta equação poderá ser representada como um ponto que pertence a um espaço de duas dimensões, delimitados pela curva mostrada na figura 2.7. Nota-se que abaixo da curva tem-se duas soluções, acima dela nenhuma e uma solução só sobre a própria curva. Desta forma fica claro que a máxima carga reativa não poderá exceder $E^2/4X$, enquanto resulta possível atender qualquer potência ativa desde que a reserva de reativos seja suficiente. O anteriormente exposto demonstra mais uma vez a dificuldade de transportar grandes quantidades de potência reativa através do sistema de transmissão.




Figura 2.7: Espaço de soluções.

2.4.2 Detecção e prevenção do colapso de tensão

Para se determinar o grau de segurança de um sistema com relação à estabilidade de tensão, é importante obter meios para estimar a distância do ponto de operação do sistema ao ponto crítico, que sob certas condições corresponde ao ponto de máximo carregamento ou ponto de bifurcação sela-nó.

A partir da figura 2.8, que representa uma curva PV típica, é possível compreender alguns dos principais indicadores de proximidade ao colapso encontrados na literatura e enunciados anteriormente neste capítulo.

O primeiro deles (ΔV_{HL}), expressa a proximidade ao colapso em função da distância entre os pontos superior e inferior da curva [43]. Para este índice, o ponto de máximo carregamento do sistema encontra-se no ponto onde a diferença é nula. Uma outra opção está representada pela derivada da potência com relação à tensão (dP/dV), conhecido na literatura




Figura 2.8: Indicadores de proximidade ao colapso de tensão.

tura como o *vetor tangente* [44], que tende para zero ao se aproximar do ponto crítico.

Por último temos as margens de segurança ao colapso de tensão que são distâncias existentes entre o ponto de operação e o ponto de máximo carregamento (*PMC*), que corresponde ao máximo aumento de carga que pode ser transmitida pela rede, de forma a manter o sistema operando ainda na região estável. Esta distância é dada por grandezas físicas, como a potência consumida (MW, MVar ou MVA) ou a admitância das cargas, por exemplo. De acordo com a Figura 2.8, a margem de segurança ΔP a ser obtida, é dada por:

$$\Delta P = P_{cr} - P_0 \quad (2.22)$$

É este último indicador de proximidade ao colapso que este trabalho pretende calcular através da aplicação de redes neurais artificiais (*RNA*) aproveitando as qualidades que elas possuem na solução de problemas altamente não lineares dispensando a obtenção de modelos matemáticos complexos.

No capítulo seguinte são apresentados alguns fundamentos básicos da teoria das *RNA*'s, como os modelos matemáticos, algoritmos de treinamento e algumas considerações particulares que permitirão completar a base teórica da metodologia que será usada durante o presente trabalho de pesquisa.

Capítulo 3

Estimação da margem de estabilidade de tensão usando *RNA*'s

3.1 Introdução

Tal como foi apresentado no capítulo 2, existem diferentes abordagens para analisar o problema da estabilidade de tensão e múltiplas ferramentas para detectar a proximidade ao colapso. No caso específico deste trabalho, aborda-se a análise do ponto de vista estático usando como indicador de proximidade ao colapso a margem de estabilidade de tensão. A idéia fundamental é usar *RNA*'s multicamada para mapear a relação entre as variáveis do sistema de potência e a margem, sob diferentes condições de operação incluindo a ocorrência de contingências com o objetivo de incluir a metodologia proposta num ambiente de tempo real, de tal forma que seja possível contar com informações rápidas e precisas sobre o estado de operação da rede a respeito da estabilidade de tensão.

3.2 Cenário de aplicação

Dadas as inúmeras opções de operação que pode ter um sistema elétrico de potência e a impossibilidade das *RNA*'s de aprender um conjunto ilimitado de estados, é necessário delimitar o ambiente onde a *RNA* vai operar. Para este fim é proposta uma estratégia de treinamento baseada na informação da previsão da demanda. A partir dela é realizada a simulação do estado do sistema numa faixa de operação dentro da qual se estima provável que opere o sistema e onde se espera que a *RNA* seja capaz de estimar a margem com precisão tanto em condições normais de operação quanto após a ocorrência de contingências.

A metodologia parte do suposto que a curva de previsão de carga é conhecida com antecedência. Em uma curva como a retratada na figura 3.1 a demanda está expressa em termos do carregamento total do sistema.




Figura 3.1: Curva de previsão de demanda.

A carga em cada barra é calculada usando o valor de carregamento $\lambda(t)$ e a potência do caso base P_0 , de acordo com a seguinte expressão:

$$P_{prev} = P_0(1 + \lambda(t)) \quad (3.1)$$

Levando em conta que existe um erro no processo de previsão de carga é necessário introduzir essa informação no treinamento da rede neural para estabelecer uma região onde provavelmente operaria o sistema, restringindo assim o cenário de aplicação da *RNA*. A amplitude dessa região, dentro da qual deverá operar satisfatoriamente a rede neural é definida modelando estatisticamente o erro de previsão em termos da média μ_e e desvio padrão do erro σ_e , de acordo com a equação 3.2. Para isto é assumida uma distribuição probabilística normal do erro similar à apresentada na figura 3.2.

$$e = f(\mu_e, \sigma_e) \quad (3.2)$$

A expressão 3.2 que representa o erro de estimação de carga, pode ser incluída na equação 3.1 através do termo $\mathbf{k}_P$ representa a incerteza da previsão de demanda.

$$P(t) = P_{prev}(t)\mathbf{k}_P \quad (3.3)$$

onde, $\mathbf{k}_P$ corresponde a um vetor aleatório de variação de carga que inclui o erro de previsão, μ_e representa o erro médio de previsão de carga que para o caso deste trabalho é considerado igual a zero; e σ_e a variável responsável pela amplitude da região de operação na qual se esperam bons resultados da *RNA*

$$\mathbf{k}_P = 1 + \mathbf{e}(\mu_e, \sigma_e) \quad (3.4)$$




Figura 3.2: Distribuição probabilística do erro de previsão.

Analogamente para a potência reativa têm-se:

$$Q(t) = Q_{prev}(t)\mathbf{k}_Q \quad (3.5)$$

No caso de $\mathbf{k}_P$ e $\mathbf{k}_Q$ serem diferentes ter-se-ia também uma variação aleatória no ângulo da carga. Contudo neste trabalho foi assumido o fator de potência constante, fazendo $\mathbf{k}_P = \mathbf{k}_Q$.

O conjunto de treinamento é formado simulando as condições de operação do sistema ao longo da curva de previsão de carga. No caso específico deste trabalho, o estado da rede elétrica e a margem são calculados à cada hora, usando as equações 3.3 e 3.5 com um vetor de variação de carga diferente em cada simulação, completando dessa forma um conjunto de 24 padrões entrada-saída para cada curva de previsão de carga. Nas figuras 3.3, 3.4 e 3.5 é apresentada a margem calculada segundo este procedimento para o sistema IEEE de 30 barras [64] para valores de $\sigma_e = 1.2\%$, $\sigma_e = 3\%$ e $\sigma_e = 6\%$ respectivamente, todas elas usando $\mu_e = 0$. Nas figuras 3.6, 3.7 e 3.8 mostram as variações máximas e mínimas em torno do valor previsto para cada barra do sistema. É importante salientar que na etapa de simulação das condições de operação dos sistemas testados foram levados em consideração os limites de potência reativa em barras PV.

É importante aclarar que nesta dissertação o ponto de máximo carregamento *PMC* é calculado rodando fluxos de carga sucessivos, aumentando o carregamento do sistema até o ponto de não-convergência do algoritmo. Enquanto a margem de estabilidade de tensão é calculada usando a expressão 2.22.

Os diferentes valores de desvio padrão do erro, usados nas simulações apresentadas são usados ao longo deste trabalho para testar a resposta da rede neural em cenários mais amplos de operação. A tabela 3.1 resume os intervalos máximos da variação aleatória de carga para os valores de σ_e usados durante o presente trabalho.




Figura 3.3: Margens de estabilidade de tensão previstas, $\sigma_e = 1.2\%$.




Figura 3.4: Margens de estabilidade de tensão previstas, $\sigma_e = 3\%$.




Figura 3.5: Margens de estabilidade de tensão previstas, $\sigma_e = 6\%$.




Figura 3.6: Variações máximas e mínimas de carga ($\sigma_e = 1.2\%$).




Figura 3.7: Variações máximas e mínimas de carga ($\sigma_e = 3\%$).




Figura 3.8: Variações máximas e mínimas de carga ($\sigma_e = 6\%$).

Tabela 3.1: Faixa de variação da potência.

Desvio padrão (σ)	Média de variação máxima	Variação máxima*
1.2%	3.43%	5%
3%	9.24%	11%
6%	17.7%	23%

* Valores aproximados

As informações acima apresentadas correspondem à simulação das condições de operação dos sistemas elétricos sem levar em conta a ocorrência de contingências. Simulações deste tipo foram realizadas para os sistemas IEEE de 30, 57, 118, e 300 barras [64] a fim de validar a resposta das *RNA*'s com sistemas de diferentes tamanhos. O mesmo procedimento é realizado repetindo a simulação com as mesmas condições de carga para cada uma das condições topológicas do sistema que serão consideradas, que no caso deste trabalho serão as contingências simples correspondentes ao desligamento de ramos para os sistemas IEEE de 30 e 300 barras.

A figura 3.9 mostra o cenário de operação do sistema IEEE de 30 barras para várias condições de contingência, onde se espera que a *RNA* forneça resultados aceitáveis da estimativa da margem de carregamento.




Figura 3.9: Margens previstas para diferentes topologias.

3.3 Estrutura proposta

Para resolver o problema de estimativa da margem, é necessário definir adequadamente alguns parâmetros que podem afetar o desempenho da *RNA*, como a escolha dos dados de entrada, a própria arquitetura da rede neural, o método de treinamento. Todos estes parâmetros formarão a estrutura de aplicação da *RNA*. Neste trabalho é adotada uma configuração similar à proposta em [6], a qual consiste de três partes principais:

- Variáveis de entrada da *RNA*.
- Aplicação do procedimento de redução da dimensão das variáveis de entrada.
- Rede neural artificial multicamada.




Figura 3.10: Estrutura proposta

Segundo os resultados apresentados em [6], com a estrutura mostrada na figura 3.10 é possível estimar com precisão a margem de estabilidade de tensão para uma única configuração topológica. Nesse mesmo artigo o autor sugere o treinamento de forma independente de um conjunto de *RNA*'s para serem aplicadas separadamente em cada contingência possível. Porém, neste trabalho de pesquisa pretende-se avaliar o comportamento das *RNA*'s e explorar alternativas que permitam estimar a margem com uma única *RNA*, obtendo resultados aceitáveis para uma lista grande de contingências simples. Para alcançar este objetivo foram estudados os aspectos fundamentais de cada uma das partes da estrutura utilizada. Nas seguintes seções deste capítulo são apresentadas as análises realizadas.




Figura 3.11: Estrutura proposta com divisão do sistema em áreas

A figura 3.11 apresenta uma estrutura alternativa baseando-se no fato de que o fenômeno de instabilidade de tensão pode ser considerado local, já que o aumento da demanda em

algumas áreas do sistema têm uma incidência maior na margem de estabilidade de tensão do sistema. Por essa razão, é sugerida uma divisão do sistema em áreas segundo um critério que permita identificar regiões com diferentes níveis de influência sobre a estabilidade de tensão. No caso deste trabalho é proposta uma divisão usando como parâmetro o nível de tensão de cada barra no *PMCD*. Desta forma o sistema será dividido em áreas que são caracterizadas por manter perfis altos, médios e baixos de tensão, sendo esta última a área considerada crítica para a estabilidade de tensão. Posteriormente, as informações de cada área da rede elétrica são processadas separadamente.

3.3.1 Variáveis de entrada

Para obter um treinamento bem sucedido da rede neural é necessário escolher variáveis de entrada que estejam relacionadas com o problema a ser resolvido. No caso da estimação da margem de estabilidade de tensão, é lógico usar como entradas grandezas que de alguma forma reflitam o fenômeno da instabilidade de tensão, como é o caso da tensão, a potência reativa e ativa, os fluxos, as perdas e também alguns índices de proximidade ao colapso.

Já que um dos objetivos do trabalho é desenvolver uma ferramenta que seja capaz de estimar a margem de estabilidade suficientemente rápido para ser implementada num ambiente de tempo real, é definida como premissa fundamental escolher grandezas que sejam mensuráveis da rede ou que sejam de cálculo simples para minimizar o esforço computacional.

Dentro das variáveis citadas anteriormente estão os índices de proximidade ao colapso. Eles são incluídos pois descrevem de uma forma mais direta o estado do sistema com relação à estabilidade de tensão e representam uma estimativa da proximidade ao colapso, além disso possuem a vantagem adicional de ser facilmente calculáveis. Nas seções seguintes são apresentados alguns resultados obtidos para o sistema teste IEEE de 30 barras [64] que mostram o comportamento das variáveis testadas como entradas da rede neural com relação à estabilidade de tensão, incluindo os índices avaliados neste mesmo processo.

3.3.1.1 Variáveis do fluxo de carga

A primeira idéia que surge ao pensar em selecionar as entradas a partir das quais a *RNA* deverá estimar a margem de carregamento, é usar as variáveis de estado do sistema, as demandas de potência ativa e reativa, assim como também aquelas grandezas que normalmente se encontram disponíveis nos centros de controle como os fluxos pelas linhas ou as perdas do sistema. Por esta razão vale a pena observar seu comportamento com relação ao limite de estabilidade, já que isto permite entender melhor a relação entre estas variáveis e o parâmetro que se deseja estimar. Os gráficos seguintes apresentam esta relação.

Os valores de tensão e ângulo de fase podem ser obtidos através da solução das equações

de fluxo de carga e são mostrados nas figuras 3.12 e 3.13




Figura 3.12: Comportamento da tensão.




Figura 3.13: Comportamento do ângulo.

O comportamento das potências ativas e reativas está associado à forma em que tenha sido modelado o crescimento da carga ao longo da curva PV. Para este trabalho a carga foi modelada com fator de potência constante, ou seja, as potências ativa e reativa aumentam proporcionalmente:

$$\begin{aligned} P &= P_0(1 + \lambda) \\ Q &= Q_0(1 + \lambda) \end{aligned} \quad (3.6)$$

onde, P_0 e Q_0 correspondem aos valores iniciais da potência ativa e reativa, e λ um escalar que representa a variação percentual da carga. A evolução da potência ativa líquida numa barra

de carga do sistema é apresentada na figura 3.14 e na figura 3.15 mostra-se o comportamento da potência reativa líquida numa barra com uma componente de geração e de carga. Para esta última, observa-se uma mudança no comportamento da variável uma vez atingido o limite de reativos do gerador.




Figura 3.14: Comportamento da potência ativa.




Figura 3.15: Comportamento da potência reativa.

Após resolver o problema de fluxo de carga, os fluxos nos ramos podem ser calculados usando as seguintes expressões, as quais são encontradas em [65] como segue:

$$\begin{aligned}
 P_{mk} &= V_m^2 g_{km} - a_{km} V_k V_m [g_{km} \cos(\theta_{km} + \varphi_{km}) - b_{km} \sin(\theta_{km} + \varphi_{km})] \\
 Q_{mk} &= -(b_{km} + b_{km}^{sh}) V_m^2 + a_{km} V_k V_m [g_{km} \sin(\theta_{km} + \varphi_{km}) + b_{km} \cos(\theta_{km} + \varphi_{km})]
 \end{aligned} \tag{3.7}$$

em que g_{km} é a condutância do ramo, b_{km} é a susceptância e b_{km}^{sh} a susceptância shunt equivalente. Os parâmetros do transformador estão definidos por a_{km} que é a relação de transformação e φ_{km} que representa o ângulo defasador. As variáveis de estado são V_k que corresponde a magnitude da tensão nodal e θ_{km} à abertura angular do ramo.

As figuras 3.16 e 3.17 mostram a evolução dos fluxos de potência em função do carregamento.




Figura 3.16: Comportamento dos fluxos de potência ativa.




Figura 3.17: Comportamento dos fluxos de potência reativa.

Da mesma forma, as perdas nas linhas do sistema podem ser calculadas mediante a seguinte formulação:

$$\begin{aligned}
 P_{perdas} &= g_{km}[(a_{km}V_k)^2 + V_m^2 - 2a_{km}V_kV_m \cos(\theta_{km} + \varphi_{km})] \\
 Q_{perdas} &= -b_{km}^{sh}[(a_{km}V_k)^2 + V_m^2] - b_{km}[(a_{km}V_k)^2 + V_m^2 - 2a_{km}V_kV_m \cos(\theta_{km} + \varphi_{km})]
 \end{aligned}
 \tag{3.8}$$

e suas evoluções são mostradas nas figuras 3.18 e 3.19.




Figura 3.18: Comportamento das perdas de potência ativa.




Figura 3.19: Comportamento das perdas de potência reativa.

3.3.1.2 Vetor tangente

Este índice parte da representação do sistema de potência usando as equações algébricas do fluxo de potência da seguinte forma:

$$f(x, \lambda) = 0 \quad (3.9)$$

onde x representa o vetor das variáveis de estado do sistema (magnitudes e ângulos de fase das tensões), e λ é um escalar que geralmente está associado ao carregamento do sistema.

O vetor tangente ($dx/d\lambda$) é aplicado para determinar a forma em que as variáveis do sistema mudam respeito do parâmetro λ , e pode-se calcular diretamente usando a expressão:

$$\frac{dx}{d\lambda} = J^{-1} \frac{df}{d\lambda} \quad (3.10)$$

onde J corresponde à matriz Jacobiana do fluxo de carga, que se torna singular no ponto de máximo carregamento. Da equação 3.10 podem-se identificar as variáveis mais sensíveis às variações de λ , pois elas terão os maiores valores. Já que o vetor tangente tem um comportamento crescente com relação ao carregamento, que tende para infinito no ponto crítico, é preferível usar sua inversa como índice de proximidade ao colapso, pois ela cai para zero no mesmo ponto.




Figura 3.20: Inversa do vetor tangente.

3.3.1.3 Índice lpq

Este índice baseia-se nos fluxos de potência ativa e reativa pelos ramos do sistema [45], sendo deduzido a partir das equações gerais dos fluxos de potência mostradas na equação (3.7). Manipulando estas equações chega-se a uma expressão do tipo:

$$\begin{aligned}
0 = & U^2[1 - 2 \sin(A) z_{km} b_{km}^{sh} + z_{km}^2 b_{km}^{sh\ 2}] \\
& + U[-a_{km}^2 V_k^2 - 2 \cos(A) z_{km} P_{mk} - 2 \sin(A) z_{km} Q_{mk} + 2 z_{km}^2 b_{km}^{sh} Q_{mk}] \\
& + z_{km}^2 P_{mk}^2 + z_{km}^2 Q_{mk}^2
\end{aligned} \tag{3.11}$$

em que $A = \delta_{km}$, $B = \theta_{km} + \varphi_{km}$ e $U = V_m^2$.

Definindo:

$$\begin{aligned}
a &= 1 - 2 \sin(A) z_{km} b_{km}^{sh} + z_{km}^2 (b_{km}^{sh})^2 \\
b &= -a_{km}^2 V_k^2 - 2 \cos(A) z_{km} P_{mk} - 2 \sin(A) z_{km} Q_{mk} + 2 z_{km}^2 b_{km}^{sh} Q_{mk} \\
c &= z_{km}^2 (P_{mk}^2 + Q_{mk}^2)
\end{aligned}$$

A equação 3.11 fica da forma quadrática $aU^2 + bU + c = 0$ cuja solução é dada por:

$$U = \frac{-b \pm \sqrt{b^2 - 4ac}}{2a}$$

Já que $U = V_m^2$, para obter valores de V_m reais e positivos, devem-se cumprir as seguintes condições:

$$I : b^2 - 4ac \geq 0$$

$$II : \frac{-b + \sqrt{b^2 - 4ac}}{2a} \geq 0$$

ou

$$III : \frac{-b - \sqrt{b^2 - 4ac}}{2a} \geq 0$$

A condição I está relacionada com a distância entre as tensões da parte superior e inferior da curva PV [45], e é usada como índice de proximidade ao colapso. Da equação 3.12 é possível definir que o índice tem um comportamento decrescente que tende para zero no limite de estabilidade de tensão. O comportamento deste índice para a linha que liga as barras 15 e 23 no sistema IEEE de 30 barras pode ser observado na figura 3.21.

$$l_{pq} = b^2 - 4ac \geq 0 \tag{3.12}$$




Figura 3.21: Índice lpq .

3.3.2 Principal Component Analysis (PCA) [48]

Em muitas das aplicações onde são usadas as *RNA*'s é comum verificar que o número de entradas é muito elevado. Além disso, a informação que elas fornecem é redundante, tal como é o caso dos sistemas de elétricos de potência. Por estas razões resultaria interessante contar com algum procedimento que permitisse representar o conjunto de dados por um número reduzido de dados “*eficazes*” que contenham as principais características dos dados originais.

Suponha-se o caso de um vetor $\mathbf{x}$ de dimensão m que se deseja transmitir usando l canais, onde $l < m$. Se simplesmente o vetor $\mathbf{x}$ fosse truncado, ter-se-ia do ponto de vista estatístico um erro médio quadrático igual à soma das variâncias dos elementos eliminados de $\mathbf{x}$. A metodologia do PCA permite achar uma matriz de transformação linear $\mathbf{T}$ tal que o truncamento $\mathbf{T}\mathbf{x}$ resulte ótimo no sentido de minimizar o erro médio quadrático.

Seja $\mathbf{X}$ um vetor randômico de dimensão m que representa o ambiente de interesse. Assumindo que o vetor $\mathbf{X}$ possui média igual a zero. $E[\mathbf{X}] = 0$. Seja $\mathbf{q}$ um vetor unitário também de dimensão m , sobre o qual o vetor $\mathbf{X}$ será projetado. A projeção é definida pelo produto interno dos vetores $\mathbf{X}$ e $\mathbf{q}$, da seguinte forma:

$$\mathbf{A} = \mathbf{X}^T \mathbf{q} = \mathbf{q}^T \mathbf{X} \quad (3.13)$$

Sujeito a:

$$\|\mathbf{q}\| = (\mathbf{q}^T \mathbf{q})^{\frac{1}{2}} \quad (3.14)$$

A Projeção $\mathbf{A}$ é uma variável aleatória com média e variância relacionadas com o vetor randômico $\mathbf{X}$. Dado que a média do vetor $\mathbf{X}$ é igual a zero, o valor médio da projeção $\mathbf{A}$ é também igual a zero:

$$E[\mathbf{A}] = \mathbf{q}^T E[\mathbf{X}] = 0$$

A variância de $\mathbf{A}$, é portanto, igual ao seu valor médio quadrático, o que se pode escrever da seguinte forma:

$$\begin{aligned}
 \sigma^2 &= E[A^2] \\
 &= E[(\mathbf{X}^T \mathbf{q})(\mathbf{q}^T \mathbf{X})] \\
 &= \mathbf{q}^T E[\mathbf{X}\mathbf{X}^T] \mathbf{q} \\
 &= \mathbf{q}^T \mathbf{R} \mathbf{q}
 \end{aligned} \tag{3.15}$$

Onde $\mathbf{R}$ é uma matriz simétrica ($\mathbf{R} = \mathbf{R}^T$) que corresponde à matriz de correlação do vetor $\mathbf{X}$

$$\mathbf{R} = E[\mathbf{X}\mathbf{X}^T] \tag{3.16}$$

Os vetores de projeção devem ser calculados adequadamente para que representem a direção de máxima variabilidade do conjunto de dados. Isto é feito a partir da decomposição em autovalores e autovetores da matriz de correlação, o que pode ser representado matematicamente da seguinte forma:

$$\mathbf{R} = \sum_{i=1}^m \lambda_i \mathbf{q}_i \mathbf{q}_i^T \tag{3.17}$$

Onde, λ_i corresponde aos autovalores e $\mathbf{q}_i$ aos autovetores da matriz de correlação do conjunto de dados $\mathbf{X}$. os quais possuem as seguintes características:

- Os autovetores da matriz $\mathbf{R}$ correspondem às direções de máxima variabilidade do conjunto de dados.
- Os autovalores da matriz $\mathbf{R}$ representam a variância do novo conjunto de dados
- Os autovalores estão arranados em ordem decendente ($\lambda_1 > \lambda_2 > \dots > \lambda_m$), sendo $\lambda_1 = \lambda_{\max}$

Do ponto de vista da seleção estatística de características, o método *PCA* representa uma técnica de redução dimensional. Especificamente, é possível reduzir o número de características necessárias para representar o conjunto de dados desprezando os termos com variâncias pequenas, tomando os l maiores autovalores da matriz de correlação $\mathbf{R}$.

O vetor aproximado ($\hat{\mathbf{x}}$) após o truncamento dos l primeiros termos, pode ser achado da seguinte forma:

$$\hat{\mathbf{x}} = \sum_{j=1}^l a_j \mathbf{q}_j$$

O erro de aproximação $\mathbf{e}$ é igual à diferença entre o vetor original $\mathbf{x}$ e o vetor aproximado $\hat{\mathbf{x}}$, de acordo com a seguinte expressão:

$$\begin{aligned}
\mathbf{e} &= \mathbf{x} - \hat{\mathbf{x}} \\
&= \sum_{j=1}^m a_j \mathbf{q}_j - \sum_{j=1}^l a_j \mathbf{q}_j \\
&= \sum_{j=l+1}^m a_j \mathbf{q}_j
\end{aligned} \tag{3.18}$$

A variância total dos $l - m$ elementos devidos ao erro de aproximação está dado por:

$$\sum_{j=l+1}^m \sigma_j^2 = \sum_{j=l+1}^m \lambda_j$$

Dado que os autovalores $\lambda_{l+1}, \dots, \lambda_i$ são os menores da matriz de correlação. Pode-se dizer que quanto mais próximos de zero sejam esses autovalores, mais efetiva será a redução da dimensão pois a maioria da informação contida no conjunto original será preservada.

Do procedimento anterior fica claro que a redução do conjunto de dados está estreitamente ligada ao valor da variância mínima especificada. Portanto, especificando um valor x para a variância, o procedimento deve reter aqueles elementos que contribuem com uma variância superior ao $x\%$ no conjunto inicial.

Com o fim de clarificar o efeito da aplicação do *PCA* sob o conjunto de variáveis do sistema, são apresentadas algumas tabelas que mostram o tamanho da redução conseguida com este método. Os resultados resumidos nas tabelas 3.2, 3.3, 3.4 e 3.5 foram obtidos selecionando aqueles elementos que representam o 99,9 % da variabilidade do conjunto original de dados.

Tabela 3.2: Redução do número de entradas em sistema IEEE 30.

Variável	Sem PCA	Com PCA
Magnitude de tensão	30	1
Ângulo de fase de tensão	30	1
Pot. ativa	30	1
Pot. reativa	30	2
Fluxos de pot. ativa	41	1
Fluxos de pot. reativa	41	3
Perdas de pot. ativa	41	1
Perdas de pot. reativa	41	3
Índice lpq	41	2
Vetor tangente	60	4

Tabela 3.3: Redução do número de entradas em sistema IEEE 57.

Variável	Sem PCA	Com PCA
Magnitude de tensão	57	1
Ângulo de fase de tensão	57	1
Pot. ativa	57	2
Pot. reativa	57	3
Fluxos de pot. ativa	80	2
Fluxos de pot. reativa	80	4
Perdas de pot. ativa	80	2
Perdas de pot. reativa	80	3
Índice lpq	80	2
Vetor tangente	114	1

Tabela 3.4: Redução do número de entradas em sistema IEEE 118.

Variável	Sem PCA	Com PCA
Magnitude de tensão	118	1
Ângulo de fase de tensão	118	2
Pot. ativa	118	2
Pot. reativa	118	4
Fluxos de pot. ativa	186	2
Fluxos de pot. reativa	186	4
Perdas de pot. ativa	186	2
Perdas de pot. reativa	186	4
Índice lpq	186	2
Vetor tangente	236	3

Tabela 3.5: Redução do número de entradas em sistema IEEE 300.

Variável	Sem PCA	Com PCA
Magnitude de tensão	300	1
Ângulo de fase de tensão	300	3
Pot. ativa	300	2
Pot. reativa	300	3
Fluxos de pot. ativa	411	3
Fluxos de pot. reativa	411	3
Perdas de pot. ativa	411	7
Perdas de pot. reativa	411	2
Índice lpq	411	2
Vetor tangente	600	8

Os resultados apresentados nas tabelas anteriores demonstram que a afirmação realizada sobre o alto grau de redundância da informação contida nas variáveis é verdadeira, dado

o elevado nível de redução alcançado. Também é possível observar que para sistemas maiores o número de elementos preservados pelo PCA não varia consideravelmente.

3.3.3 Rede neural multicamada

Segundo a estrutura definida no início desta seção, as redes neurais multicamada foram escolhidas para resolver o problema da estimação da margem de estabilidade de tensão, graças a qualidades como a capacidade de aproximar funções não lineares mediante o mapeamento da superfície do problema, a tolerância a falhas, sua alta velocidade de resposta após o treinamento, que as tornam uma excelente alternativa para aplicações em tempo real como a que se pretende estudar neste trabalho de pesquisa. Por estas e outras características descritas no capítulo A que este tipo de *RNA* é eleita para enfrentar o problema proposto. Porém, não é suficiente determinar o tipo de rede neural a aplicar, pois existem outros parâmetros que podem afetar o resultado que se pretende alcançar tal como foi apresentado anteriormente.

Os aspectos mais importantes a serem considerados com maior detalhe são os seguintes:

- A estrutura da rede neural deve ser o primeiro quesito a considerar, pois sabe-se que as *RNA*'s derivam seu poder computacional do alto grau de paralelismo de suas unidades de processamento e que armazenam o conhecimento adquirido sobre o ambiente em que operam na sua malha de interconexões. É por esta razão que redes com um maior número de neurônios têm a capacidade de mapear superfícies mais complexas. No entanto, o treinamento de redes neurais grandes não é uma tarefa simples, chegando em alguns casos à não convergência do algoritmo de treinamento.

Adicionalmente, redes neurais com um número exagerado de neurônios em suas camadas, geralmente apresentam uma generalização pobre, ou seja o algoritmo de treinamento converge com valores muito pequenos de erro, porém quando apresentados dados novos à rede neural os erros são grandes em comparação com os obtidos no treino. Devido a estes comportamentos indesejados é que faz-se necessário testar várias configurações para assim eleger aquela que forneça os menores erros para padrões nunca antes apresentados à *RNA*.

- O tamanho do conjunto de treinamento pode afetar o processo de treinamento, pois se forem pequenos demais fariam com que a rede não aprendesse a se comportar adequadamente em toda a região de operação gerando maus resultados para dados diferentes dos conhecidos. Por outro lado com um conjunto de treinamento grande isto não aconteceria pois se garante que a rede vá ser treinada com suficiente informação do problema que se quer resolver. Porém se forem usados conjuntos maiores que o necessário ter-se-ia um treino lento.

- O algoritmo de treinamento é outro fator decisivo num projeto de redes neurais, pois dele depende em grande medida o sucesso do processo. Para decidir qual é o melhor algoritmo a ser usado numa aplicação específica é importante lembrar as principais características de cada algoritmo encontrado na literatura (ver seção A.5.1) e adicionalmente fazer alguns testes comparativos entre aqueles algoritmos que se adaptam melhor ao problema particular que se está analisando.

Em geral métodos de segunda ordem apresentam-se como os mais indicados para o treinamento de *RNA*'s, pois eles, além de usar a informação do gradiente, usam a também dados da matriz Hessiana da função do erro. Isto lhes permite chegar com maior probabilidade às soluções globais se comparados com métodos de primeira ordem. As principais deferências entre eles estão na forma em que calculam e armazenam a matriz Hessiana, o que determina o tempo computacional e a quantidade de memória requerida.

Em [6] é apresentado um estudo comparativo do desempenho de diferentes algoritmos de treinamento para uma estrutura similar à adotada neste trabalho mostrando que o algoritmo de Levenberg-Marquardt oferece os melhores resultados em termos do erro, mas o tempo computacional exigido pelo método aumenta significativamente com o número de parâmetros da *RNA*. Baseado nos resultados apresentados por Repo [6] escolheu-se o algoritmo de Levenberg-Marquardt como método padrão para este trabalho.

3.4 Testes

Da forma que foi mencionado na seção anterior. No modelo proposto existem vários parâmetros que podem afetar o resultado final; como são a amplitude do cenário de operação, a estrutura da *RNA*, o tamanho do conjunto de dados e a estrutura da *RNA*.

O objetivo principal desta seção é observar a incidência dos critérios avaliados sobre os resultados gerais conseguidos com a aplicação da metodologia proposta. Por esta razão foi eleito o sistema IEEE de 30 barras que por sua simplicidade permite apreciar com maior facilidade os efeitos analisados.

Adicionalmente aos parâmetros avaliados, é possível analisar ao longo desta seção o tamanho do conjunto de padrões de treinamento, sendo possível determinar se uma mudança num determinado parâmetro leva a necessidade de usar um conjunto maior de padrões de treinamento.

3.4.1 Região de operação

Os gráficos mostrados nas figuras 3.22, 3.23 e 3.24 a seguir correspondem a cenários de operação descritos pelas figuras 3.3, 3.4 e 3.5. Tal como foi dito neste capítulo, as regiões de operação são definidas pelo parâmetro σ_e que é usado na etapa de simulação e conformação do conjunto de treino.

Para ter uma base de análise adequada optou-se por manter fixos os parâmetros restantes. Os resultados foram obtidos a partir do treinamento de uma rede neural conformada por um neurônio na camada escondida, usando como variáveis de entrada a tensão e as potências ativas e reativas, além disso aplicou-se *PCA* adotando uma variância mínima de $\sigma_{PCA}^2 = 1 \times 10^{-3} p.u.$, o que quer dizer que só serão escolhidas as características que representem 99,9% da variabilidade dos dados.




Figura 3.22: Resultados de treinamento para $\sigma_e = 1.2\%$.




Figura 3.23: Resultados de treinamento para $\sigma_e = 3\%$.




Figura 3.24: Resultados de treinamento para $\sigma_e = 6\%$.

Pode-se ver que para intervalos de operação mais amplos o processo de treinamento da rede neural converge com erros mais altos. Além disso, faixas de operação estreitas favorecem o treinamento, no sentido que a *RNA* obtém bons níveis de generalização usando um número mínimo de padrões de treinamento, tal como pode ser apreciado nas figuras 3.22 e 3.23. Nesses dois casos é necessário usar só os dados do caso base e uma curva de demanda sem incluir variações aleatórias de carga (24 padrões de treinamento).

3.4.2 Aplicação do *PCA*

O efeito da aplicação do *PCA* no treino das *RNA*'s é avaliado usando os resultados conseguidos do treinamento de uma rede neural com seis neurônios na camada escondida, Usou-se como entrada a potência reativa em cada barra do sistema. Considerando a região de operação de maior amplitude ($\sigma_e = 6\%$).

A figura 3.25 contém os resultados para o treinamento sem usar o método de redução de entradas. Nela foram excluídas só os dados de aquelas barras onde a potência líquida injetada era igual a zero, obtendo no total 22 entradas. As figuras 3.26 e 3.27 correspondem aos casos de treino para $\sigma_{PCA}^2 = 1 \times 10^{-3} p.u.$ e $\sigma_{PCA}^2 = 1 \times 10^{-5} p.u.$ respectivamente.




Figura 3.25: Resultados de treinamento sem redução de entradas.




Figura 3.26: Resultados de treinamento aplicando PCA $\sigma_{PCA}^2 = 1 \times 10^{-3}$.




Figura 3.27: Resultados de treinamento aplicando PCA $\sigma_{PCA}^2 = 1 \times 10^{-5}$.

O primeiro efeito causado por usar um maior número de variáveis de entrada é naturalmente o aumento no tempo de treinamento, embora seja possível atingir níveis de erro inferiores. O qual é verdadeiro só para casos onde o número de entradas não seja muito elevado.

Por outro lado, a aplicação do *PCA* resulta na obtenção de erros de validação menores com um conjunto de treinamento relativamente pequeno quando comparado com os resultados sem o uso do método. Porém, é necessário escolher adequadamente o valor de σ_{PCA}^2 pois mantendo um número maior de entradas pode-se em alguns casos conseguir melhores resultados em termos do erro relativo, tal como se vê nas figuras 3.26 e 3.27.

3.4.3 Estrutura da *RNA*

Uma das etapas importantes num projeto de *RNA*'s é a determinação da estrutura da *RNA*, que no caso específico das redes multicamada consiste em determinar o número de camadas e a quantidade de neurônios em cada uma delas, de forma a obter os melhores resultados.

O processo de seleção realiza-se comparando os resultados obtidos para diferentes configurações, no exemplo apresentado a seguir são comparadas respostas de *RNA*'s conformadas por um, cinco e sete neurônios (3.28, 3.29, e 3.30) dispostos numa única camada escondida. Usando para o treinamento um conjunto de entradas composto pela tensão e as potências ativa e reativa, o qual é reduzido aplicando uma variância de $1 \times 10^{-3} p.u.$ no *PCA*. A região de operação esta definida por uma variância de 6% para o vetor de variação aleatória de carga, que corresponde ao cenário mais amplo contemplado (fig. 3.24).




Figura 3.28: Resultados de treinamento com 1 neurônio na camada escondida.




Figura 3.29: Resultados de treinamento com 5 neurônios na camada escondida.




Figura 3.30: Resultados de treinamento com 7 neurônios na camada escondida.

Nos casos mostrados nas figuras 3.28, 3.29 e 3.30, resulta preferível usar uma estrutura de 5 ou 7 neurônios, pois com elas é possível lograr erros relativos máximos menores que com uma arquitetura de um neurônio na camada escondida. Mas generalizar a idéia que redes neurais grandes resolvem o problema não é necessariamente válida, pois no capítulo 4 mostra-se que sistemas maiores onde o número de entradas aumenta também é possível conseguir bons resultados com redes pequenas de um ou 3 neurônios.

Este procedimento deve ser realizado para encontrar a estrutura de rede neural que responde melhor à configuração que está sendo usada (conjunto de variáveis, número de dados de entrada, etc). Por essa razão não é possível afirmar que exista uma única estrutura de rede neural que resolva o problema da margem de carregamento para o sistema especificado. Porém, em geral redes com menor quantidade de neurônios apresentam uma melhor característica de generalização, embora sua precisão seja menor.

Capítulo 4

Resultados

4.1 Introdução

Neste capítulo são apresentados os resultados obtidos com a aplicação da metodologia proposta em sistemas teste IEEE de 30, 57, 118, e 300 barras, disponíveis na referência [64]. Sendo usado como critério de avaliação do desempenho das *RNA*'s para a estimativa das margens de estabilidade de tensão, são usados os erros relativo e absoluto, definidos pelas expressões 4.1 e 4.2 respectivamente.

$$e_{rel} = \frac{MET_{calc} - MET_{RNA}}{MET_{calc}} \quad (4.1)$$

$$e_{abs} = |MET_{calc} - MET_{RNA}| \quad (4.2)$$

onde MET_{calc} corresponde à margem de estabilidade calculada e MET_{RNA} à margem estimada pela rede neural.

Na primeira parte são exploradas diferentes configurações de variáveis de entrada sob vários cenários de operação, todas elas sem considerar a ocorrência de contingências. Nessa seção são incluídos gráficos do processo de treinamento, os quais descrevem o comportamento dos erros para os conjuntos de treino e validação conseguidos com diferentes quantidades de padrões de treinamento. Também são mostrados os valores esperados e os estimados pela *RNA*, o que permite apreciar a qualidade dos resultados.

Os resultados conseguidos na primeira parte são usados como base na aplicação do método para os sistemas IEEE de 30 e 300 barras em condições de contingência. Supondo um erro de previsão de demanda na faixa de $\pm 4\%$ simula-se o estado do sistema para uma lista de contingências simples, que no caso deste trabalho só inclui saída de ramos. As informações de previsão de demanda são incluídas no conjunto de dados de treinamento segundo o modelo proposto no capítulo anterior, usando um valor de $\sigma_e = 1.2\%$ e curvas de previsão similares às apresentadas no capítulo anterior.

Para avaliar a resposta das *RNA*'s frente a contingências são apresentados gráficos dos erros associados a cada uma das topologias da lista considerada. Também são ilustrados os piores casos, onde o resultado da *RNA* apresenta os maiores erros de estimação da margem de estabilidade de tensão.

Embora a quantidade de simulações feitas permita incluir só alguns gráficos, no final de cada seção é apresentada uma tabela que resume os resultados de cada configuração de variáveis de entrada e sistema testado. É importante salientar que as tabelas foram preenchidas com a resposta das *RNA*'s para dados de validação, quer dizer, com dados diferentes dos usados para o treinamento, permitindo avaliar desta forma a capacidade de generalização da *RNA*.

4.2 Topologia base

Para cada rede elétrica testada são apresentados resultados de duas das configurações avaliadas escolhidas aleatoriamente, em cada uma delas são mostrados o comportamento dos erros relativo e absoluto e uma comparação entre a margem calculada e a estimada pela rede neural conseguidas com a arquitetura que fornece os melhores resultados para cada configuração de variáveis de entrada usada.

4.2.1 Sistema de 30 barras

As figuras 4.1 e 4.2 foram obtidas usando o índice lpq como entrada a uma *RNA* com cinco neurônios na camada escondida e como parâmetro de redução do conjunto de entradas $\sigma_{PCA} = 1 \times 10^{-5}$. Esta configuração permite treinar a rede com um conjunto relativamente pequeno de padrões, pois 10 conjuntos de treinamento (curvas de carga) compostos por 24 padrões entrada-saída cada um deles, são necessárias para obter um erro relativo médio entorno de 1,7% o que representa uma resposta aceitável tal como se vê na figura 4.2.




Figura 4.1: Treinamento com índice l_{pq} como entrada.




Figura 4.2: Testes de validação usando índice l_{pq} como entrada.

Dividindo o sistema em 3 áreas como apresentado na seção 3.3, escolhendo uma combinação da tensão com as potências ativa e reativa como entradas e aplicando um valor de $\sigma_{PCA} = 1 \times 10^{-3}$, conseguem-se resultados como os apresentados nas figuras 4.3 e 4.4. Esta configuração permite obter aproximações muito boas, com erros mínimos e um esforço mínimo de treinamento, pois têm-se bons resultados a partir de 240 padrões de treinamento ou seja que para cada hora da demanda de carga são necessárias dez simulações de variações aleatórias de carga segundo o procedimento descrito no capítulo 3.




Figura 4.3: Treinamento com V, P, Q como entradas para 3 áreas do sistema.




Figura 4.4: Testes de validação usando V, P, Q como entradas para 3 áreas do sistema.

A tabela 4.1 resume os resultados obtidos com a aplicação da metodologia proposta para diferentes configurações de variáveis e distintos níveis de redução de entradas. Já que este é um sistema pequeno, é factível treinar a *RNA* sem usar o procedimento de redução da dimensão das entradas. Comparando os resultados obtidos sem a aplicação do *PCA* e as respostas da *RNA* após a o uso do procedimento, demonstra-se a utilidade do *PCA*, pois, embora se consigam erros menores com o conjunto completo de variáveis isto não resulta significativo. Além disso, o tempo computacional consumido no treinamento aumenta consideravelmente com o número de entradas.

Outra forma de redução do número de entradas testada foi escolher as grandezas de barras específicas do sistema segundo critérios associados aos índices de proximidade ao colapso avaliados, por exemplo no caso do vetor tangente foram escolhidas 5 e 10 barras com menores valores do índice. Com o índice lpq foi aplicada uma estratégia semelhante para 1 e 5 linhas de menor valor, assim como também uma combinação de dois critérios onde eram usados como dados de entrada à *RNA* os índices das m linhas ligadas as n barras de menor tensão do sistema (lpq , n menor V , m menor). Esta alternativa de redução de entradas resulta menos eficiente que o *PCA* pois com um número maior de entradas não consegue erros menores que os obtidos com a aplicação do *PCA*.

Tabela 4.1: Configurações testadas no sistema IEEE de 30 barras.

Var. Entrada	σ_{PCA}	$\sigma_e = 6\%$				$\sigma_e = 1.2\%$			
		Ent.	Neur.	e_{med}	e_{max}	Ent.	Neur.	e_{med}	e_{max}
Tensão (V)		29	1	0,5	3				
Tensão (V)	1,0E-03	1	1	2,0	10	1	9	0,4	2
Tensão (V)	1,0E-05	2	9	1,8	10				
Pot. Ativa (P)		22	3	1,2	4,5				
Pot. Ativa (P)	1,0E-03	1	1	6,0	70	1	3	1,2	8
Pot. Ativa (P)	1,0E-05	6	1	1,8	10				
Pot. Reativa (Q)		22	3	1,2	6				
Pot. Reativa (Q)	1,0E-03	2	1	2,2	15	2	3	0,5	3,5
Pot. Reativa (Q)	1,0E-05	10	1	1,5	9				
Flx. ativos (P_{km})		39	3	0,4	3				
Flx. ativos (P_{km})	1,0E-03	1	1	5,0	45	1	1	1,0	7
Flx. ativos (P_{km})	1,0E-05	7	6	1,5	7				
Flx. reativos (Q_{km})		41	3	0,5	4				
Flx. reativos (Q_{km})	1,0E-03	3	1	1,9	8	2	1	0,4	2
Flx. reativos (Q_{km})	1,0E-04	5	6	1,9	7				
Perdas ativas (P_p)		28	3	0,6	4				
Perdas ativas (P_p)	1,0E-03	1	3	5,0	40	1	1	1,0	6
Perdas ativas (P_p)	1,0E-05	4	3	1,8	10				
Perdas reativas (Q_p)		37	3	0,5	4				
Perdas reativas (Q_p)	1,0E-03	3	3	1,9	10	2	3	0,8	5
Perdas reativas (Q_p)	1,0E-05	6	6	1,5	5				
Vetor tangente (v_{tan})		56	9	0,5	4				
Vetor tangente (v_{tan})	1,0E-03	5	9	1,3	8	5	6	0,4	2
v_{tan} , 10 menores		20	6	1,5	13	20	9	0,4	2,3
v_{tan} , 5 menores		10	9	1,0	13				
Índice lpq (l_{pq})		41	3	0,5	4				
Índice lpq (l_{pq})	1,0E-03	2	9	1,7	9	2	3	0,4	2
Índice lpq (l_{pq})	1,0E-05	4	6	1,5	5				
l_{pq} , 1 menor l_{pq}		1	9	3,0	15	1	3	0,6	4
l_{pq} , 5 menor l_{pq}		5	9	1,7	10				
l_{pq} , 1 menor V , 1 menor		1	6	3,0	15				
l_{pq} , 1 menor V , 2 menor		2	6	2,4	15				
l_{pq} , 10 menor V , 1 menor		10	6	1,7	8	10	1	0,4	2,5
V, P, Q		76	3	0,5	4				
V, P, Q	1,0E-03	4	1	1,5	5	4	3	0,4	2
P_{km}, Q_{km}	1,0E-04	7	6	1,0	5	4	6	0,3	1,9
P_p, Q_p	1,0E-04	6	3	1,5	7	4	3	0,6	3
V, P_p, Q_p	1,0E-04	8	3	1,2	4	6	3	0,3	1,8
l_{pq} , 3 áreas	1,0E-03	3	6	1,5	5				
V, P, Q , 3 áreas	1,0E-03	15	6	1,5	5	11	3	0,3	1,6
P_p, Q_p , 3 áreas	1,0E-03	17	6	0,6	4	10	1	0,4	1,8
V, P_p, Q_p , 3 áreas	1,0E-03	20	3	0,4	2,6				

(3 áreas: Sistema dividido em 3 áreas. n menor: Índices das n menores valores do índice; n menor V , m menor: Índices das m linhas ligadas as n barras de menor tensão)

Em geral, com as variáveis testadas, pode-se chegar a níveis de erro aceitáveis com exceção de alguns casos como os resultados obtidos usando de forma independente a potência ativa, os fluxos ativos e as perdas ativas quando especificada uma variância alta no PCA (1×10^{-3}). Para este sistema, configurações de variáveis agrupadas em áreas oferecem os menores erros, tal como se vê no caso da tensão e as perdas ativas e reativas, onde o erro relativo médio é de 0,4% e no pior dos casos o valor máximo não ultrapassa os 2,6%.

4.2.2 Sistema de 57 barras

O vetor tangente foi um dos índices de proximidade ao colapso usado e os resultados obtidos usando-o em conjunto com uma variância do *PCA* de $\sigma_{PCA} = 1 \times 10^{-5}$ são apresentados nas figuras 4.5 e 4.6. Embora o erro médio não seja excessivamente alto os erros máximos podem atingir valores elevados em alguns pontos. Aliás, para melhorar os resultados é necessário usar conjuntos de treinamento grandes e reduzir a variância do *PCA* para aumentar o número de entradas, que neste caso foi de 10.

Aplicando novamente a idéia de combinar diferentes variáveis, mas nesta oportunidade usando a tensão com a potência ativa e a reativas como entradas, e usando $\sigma_{PCA} = 1 \times 10^{-3}$ como critério de redução de entradas, o que restringe o número de variáveis a 25, obtém-se um erro relativo médio entorno de 1.5% e inferiores a 10%.




Figura 4.5: Treinamento com vetor tangente como entrada.




Figura 4.6: Testes de validação usando vetor tangente como entrada.

Observando as figuras 4.7 e 4.8 nota-se que para as mesmas condições esta última configuração é mais precisa e também exige um número menor de padrões de treinamento que o uso do vetor tangente, pois a partir de 15 curvas de treino o erro fica estável (fig. 4.7).




Figura 4.7: Treinamento com V, P, Q como entradas




Figura 4.8: Testes de validação usando V, P, Q como entradas

A lista de combinações de variáveis de entrada usadas no treinamento das *RNA*'s para o sistema de 57 barras encontra-se na tabela 4.2. Com este sistema ainda é possível fazer o treinamento sem redução do número de entradas, permitindo obter menores erros. Mas o uso simultâneo de variáveis somado com a divisão do sistema em áreas permite em alguns casos melhorar os níveis de estimação.

O treinamento da *RNA* usando os dados das dez barras com menores valores vetor tangente mostrou-se útil, melhorando os resultados conseguidos com a aplicação do *PCA*. Porém, escolhendo os elementos de entrada segundo critérios baseados no índice *lpq*, como a linha de menor índice ou a linha ligada as barras de menor tensão, não foram obtidos erros menores que os encontrados aplicando o *PCA*.

Tabela 4.2: Configurações testadas no sistema IEEE de 57 barras.

Var. Entrada	σ_{PCA}	$\sigma_e = 6\%$				$\sigma_e = 1.2\%$			
		Ent.	Neur.	e_{med}	e_{max}	Ent.	Neur.	e_{med}	e_{max}
Tensão (V)		57	1	1,0	7				
Tensão (V)	1,0E-03	1	3	5,5	80	1	3	1,0	8
Tensão (V)	1,0E-04	2	6	3,0	15	2	3	0,7	3,5
Pot. Ativa (P)		42	3	1,2	5				
Pot. Ativa (P)	1,0E-03	2	1	10,0	200	1	1	2,4	28
Pot. Ativa (P)	1,0E-05	8	1	9,0	100				
Pot. Reativa (Q)		42	3	1,5	10				
Pot. Reativa (Q)	1,0E-03	4	6	8,0	130	3	3	1,5	15
Pot. Reativa (Q)	1,0E-05	12	1	8,0	140				
Flx. ativos (P_{km})		80	1	1,2	7,5				
Flx. ativos (P_{km})	1,0E-03	2	3	11,0	200	1	3	2,2	25
Flx. ativos (P_{km})	1,0E-05	13	6	6,0	60				
Flx. reativos (Q_{km})		80	9	1,3	7				
Flx. reativos (Q_{km})	1,0E-03	4	6	4,0	40	3	3	1,0	9
Flx. reativos (Q_{km})	1,0E-04	8	3	4,0	25				
Perdas ativas (P_p)		55	3	1,2	9				
Perdas ativas (P_p)	1,0E-03	2	6	13,0	200	1	6	2,5	28
Perdas ativas (P_p)	1,0E-05	12	6	4,0	30				
Perdas reativas (Q_p)		76	3	1,2	6,5				
Perdas reativas (Q_p)	1,0E-03	3	3	9,0	100	2	3	2,3	23
Perdas reativas (Q_p)	1,0E-05	14	9	2,0	10				
Vetor tangente (v_{tan})		114	3	0,5	6,5				
Vetor tangente (v_{tan})	1,0E-05	10	9	2,8	22	11	3	0,6	3
v_{tan} , 10 menores		20	9	1,5	13	20	1	0,5	7
Índice lpq (l_{pq})		80	6	1,4	12				
Índice lpq (l_{pq})	1,0E-05	8	6	2,0	15	4	3	0,7	5
l_{pq} , 1 menor l_{pq}		1	9	2,6	12	1	3	0,6	2,5
l_{pq} , 5 menor l_{pq}		5	9	2,5	10				
l_{pq} , 5 menor V , 1 menor l_{pq}		5	6	2,5	10				
l_{pq} , 10 menor V , 1 menor l_{pq}		10	6	2,3	10	10	3	0,5	2
V, P, Q		141	3	1,0	6				
V, P, Q	1,0E-03	7	6	3,0	22	5	3	0,7	5
V, P, Q	1,0E-04	12	3	1,5	10				
P_{km}, Q_{km}	1,0E-04	12	9	3,1	21	6	3	0,9	6
P_p, Q_p	1,0E-04	13	9	2,6	22	7	6	1,0	7
V, P_p, Q_p	1,0E-04	15	6	1,6	10	9	6	0,4	2,3
V , 3 áreas	1,0E-05	6	6	2,2	9				
P , 3 áreas	1,0E-03	6	9	3,0	30				
Q , 3 áreas	1,0E-03	8	6	2,2	22				
l_{pq} , 3 áreas	1,0E-03	6	9	2,4	9	6	1	0,5	2,3
l_{pq} , 3 áreas	1,0E-05	19	6	1,6	13				
V, P, Q , 3 áreas	1,0E-03	17	6	1,2	8	11	1	0,4	2,5
P_p, Q_p , 3 áreas	1,0E-03	22	3	1,3	10	13	3	0,3	2,8
V, P_p, Q_p , 3 áreas	1,0E-03	25	3	1,3	6,6				

(3 áreas: Sistema dividido em 3 áreas. n menor: Índices das n menores valores do índice;
 n menor V , m menor: Índices das m linhas ligadas as n barras de menor tensão)

4.2.3 Sistema de 118 barras

A resposta da *RNA* usando como variável de entrada simplesmente a magnitude de tensão e $\sigma_{PCA} = 1 \times 10^{-5}$ é apresentada nas figuras 4.9 e 4.10. Observa-se o treinamento poder ser feito com um conjunto de treinamento bastante reduzido, porém, tanto o erro relativo quanto o absoluto são grandes e não foi possível diminuí-lo aumentando o número de padrões de treino. A comparação entre os valores calculados e os estimados deixa ver que a *RNA* consegue captar a dinâmica geral do sistema, mas com erros importantes.




Figura 4.9: Treinamento com a magnitude de tensão como entrada.




Figura 4.10: Testes de validação usando a magnitude de tensão como entrada.

A combinação da tensão e das potências ativa e reativa agrupadas em 3 pacotes correspondentes a diferentes áreas do sistema e processadas com uma variância mínima para o *PCA* de 1×10^{-4} permite obter melhores resultados, tal como se mostra nas figuras 4.11 e 4.12 com erros médios relativos de aproximadamente 1% e máximos de 7%.




Figura 4.11: Treinamento com V, P, Q como entradas para 3 áreas do sistema.




Figura 4.12: Testes de validação usando V, P, Q como entradas para 3 áreas do sistema.

Para o sistema de 118 barras é possível estimar a margem de estabilidade de tensão a partir da aplicação de uma única variável obtendo erros médios que podem se considerar aceitáveis segundo os resultados apresentados na tabela 4.3, mas com a desvantagem de terem erros máximos elevados, como no caso da rede treinada usando a potência reativa.

Este inconveniente é resolvido pelo uso conjunto de variáveis o que mantém os erros médios num patamar similar, uniformizando a resposta da *RNA* e reduzindo os valores dos desvios máximos atingidos.

Tabela 4.3: Configurações testadas no sistema IEEE de 118 barras.

Var. Entrada	σ_{PCA}	$\sigma_e = 6\%$				$\sigma_e = 1.2\%$			
		Ent.	Neur.	e_{med}	e_{max}	Ent.	Neur.	e_{med}	e_{max}
Tensão (V)	1,0E-05	2	6	6,0	40	2	6	1,5	17
Tensão (V)	1,0E-06	4	9	3,5	22				
Pot. Ativa (P)	1,0E-04	12	3	4,0	80	2	9	1,5	15
Pot. Reativa (Q)	1,0E-04	24	6	1,6	14	5	9	0,9	6
Flx. ativos (P_{km})	1,0E-04	5	9	2,5	30	2	6	1,3	14
Flx. reativos (Q_{km})	1,0E-04	10	6	1,5	15	5	3	1,0	8
Perdas ativas (P_p)	1,0E-04	8	9	1,7	14	2	6	1,6	14
Perdas reativas (Q_p)	1,0E-04	9	3	2,0	13,5	3	9	1,6	15
Vetor tangente (v_{tan})	1,0E-04	18	6	3,5	27	14	3	1,5	7
v_{tan} , 10 menores		20	9	6,5	35	20	6	1,9	11
Índice lpq (l_{pq})	1,0E-04	3	3	2,8	19	2	6	1,5	18
Índice lpq (l_{pq})	1,0E-05	8	6	2,7	19				
l_{pq} , 1 menor l_{pq}		10	9	2,0	13	10	3	1,2	9
l_{pq} , 10 menor V , 1 menor l_{pq}		10	9	3,2	17	10	3	1,3	8
V, P, Q	1,0E-03	7	3	2,0	14	5	6	1,0	6
V, P, Q	3,0E-05	26	6	1,0	7				
P_{km}, Q_{km}	1,0E-04	15	6	1,3	16	7	9	1,0	6,8
P_p, Q_p	1,0E-04	17	9	1,1	8	5	9	1,5	12
V, P_p, Q_p	1,0E-04	18	3	1,0	8	6	6	1,4	10
V , 3 áreas	1,0E-05	6	6	4,0	25				
P , 3 áreas	1,0E-03	15	9	2,2	15				
Q , 3 áreas	1,0E-03	22	9	1,2	11				
l_{pq} , 3 áreas	1,0E-03	6	3	4,4	30	5	6	1,2	9
l_{pq} , 3 áreas	1,0E-04	14	9	2,0	18				
V, P, Q , 3 áreas	1,0E-03	16	6	1,7	12	14	9	0,9	5
V, P, Q , 3 áreas	1,0E-04	39	3	0,9	12				
V, P, Q , 3 áreas	1,0E-05	16	6	1,1	7	6	6	1,0	7,5
P_p, Q_p , 3 áreas	1,0E-03	25	6	1,6	12	17	6	1,0	8
V, P_p, Q_p , 3 áreas	1,0E-03	28	6	1,5	11				

(3 áreas: Sistema dividido em 3 áreas. **n menor**: Índices das n menores valores do índice;
n menor V, **m menor**: Índices das m linhas ligadas as n barras de menor tensão)

4.2.4 Sistema de 300 barras

Dado que o sistema de 300 barras tem uma margem de carregamento bastante pequena da forma que se encontra na referência [64], é necessário diminuir a carga base do sistema para aplicar uma curva de demanda como a apresentada na figura 3.1, de tal forma que no horário de máxima demanda a carga será a estabelecida em [64], enquanto na hora de menor consumo a carga será 70% menor, isto força a rede neural a estimar a margem numa região de operação mais ampla.

As figuras 4.13 e 4.14 mostram o comportamento da *RNA* quando treinada usando simultaneamente a tensão a potência ativa e a reativa e um $\sigma_{PCA} = 1 \times 10^{-5}$. Esta configuração não é das melhores, pois os erros conseguidos são altos.




Figura 4.13: Treinamento com V, P, Q como entradas.




Figura 4.14: Testes de validação usando V, P, Q como entradas.

Usando como entradas uma combinação das tensões, perdas ativas e reativas com o sistema dividido em 3 áreas e aplicando PCA com uma variância mínima de 1×10^{-3} deixando um total 30 entradas após a redução são conseguidos resultados bons, com erros de estimação bem pequenos, em média 0,5% para um conjunto de dados completamente desconhecido para

a rede neural. Os resultados são mostrados nas figuras 4.15 e 4.16




Figura 4.15: Treinamento com V, P_p, Q_p como entradas para 3 áreas do sistema.




Figura 4.16: Testes de validação usando V, P_p, Q_p como entradas para 3 áreas do sistema.

Na tabela 4.4 observa-se que as perdas de potência ativa têm um papel importante na

estimação da margem no sistema de 300 barras, pois particularmente, é a única variável que sendo usada independentemente fornece resultados aceitáveis. Pode-se melhorar o comportamento da rede neural com a combinação de outras grandezas como a magnitude de tensão e as perdas de potência reativa. A divisão do sistema em áreas mostra-se novamente como uma boa alternativa para aumentar a sensibilidade da *RNA*.

Tabela 4.4: Configurações testadas no sistema IEEE de 300 barras.

Var. Entrada	σ_{PCA}	$\sigma_e = 6\%$				$\sigma_e = 1.2\%$			
		Ent.	Neur.	e_{med}	e_{max}	Ent.	Neur.	e_{med}	e_{max}
Tensão (V)	1,0E-04	2	9	11,0	200	2	6	1,7	19
Pot. Ativa (P)	1,0E-04	4	9	8,0	100	2	6	1,5	15
Pot. Reativa (Q)	1,0E-04	11	6	7,0	100	5	9	1,7	17
Flx. ativos (P_{km})	1,0E-04	9	6	4,0	40	2	6	1,5	17
Flx. reativos (Q_{km})	1,0E-04	11	9	5,0	100	5	6	1,4	16
Perdas ativas (P_p)	1,0E-04	15	3	0,8	10	6	3	1,0	7
Perdas reativas (Q_p)									
Perdas reativas (Q_p)	1,0E-04	4	9	7,0	70	2	6	1,7	15
Vetor tangente (v_{tan})	1,0E-04	24	9	1,0	16	17	9	0,5	7
v_{tan} , 10 menores		20	6	5,0	50	20	6	0,6	9
Índice lpq (l_{pq})	1,0E-04	3	6	10,0	100	3	9	1,7	20
l_{pq} , 1 menor l_{pq}		10	3	6,0	40	10	3	0,9	10
l_{pq} , 10 menor V , 1 menor l_{pq}		10	3	4,0	50	10	6	0,6	6
V, P, Q	1,0E-03	6	6	14,0	200	5	6	1,5	15
V, P, Q	1,0E-05	64	9	10,0	180	9	6	1,0	6
P_{km}, Q_{km}	1,0E-04	20	9	2,0	35	7	3	1,1	10
P_p, Q_p	1,0E-04	19	9	0,6	5	8	6	0,8	5
V, P_p, Q_p	1,0E-04	21	9	0,5	5	10	6	0,7	6,6
V , 3 áreas	1,0E-03	8	9	5,4	60				
P , 3 áreas	1,0E-03	12	9	8,2	110				
Q , 3 áreas	1,0E-03	17	9	4,2	55				
l_{pq} ; 3 áreas	1,0E-03	7	6	20,0	200	7	6	1,6	16
l_{pq} ; 3 áreas	1,0E-04	12	9	11,0	105	12	6	1,0	10
l_{pq} ; 3 áreas	1,0E-05	33	3	6,0	80				
V, P, Q , 3 áreas	1,0E-03	17	3	13,0	140	14	6	0,9	9
V, P, Q , 3 áreas	1,0E-04	49	6	8,5	110	21	6	0,8	6
P_p, Q_p , 3 áreas	1,0E-03	27	6	0,5	5	17	3	0,6	5
V, P_p, Q_p , 3 áreas	1,0E-03	30	9	0,5	3,5				

(3 áreas: Sistema dividido em 3 áreas. **n menor**: Índices das n menores valores do índice;
n menor V, m menor: Índices das m linhas ligadas as n barras de menor tensão)

Parece não ser possível determinar uma configuração padrão com a qual se obtenham sempre os melhores resultados a partir dos apresentados nas tabelas 4.1, 4.2, 4.3 e 4.4. Pode-se concluir porém, que a combinação da magnitude de tensão com as perdas é uma configuração que oferece resultados razoáveis para os sistemas testados. Além disso, na maioria dos casos a divisão do sistema em áreas contribui na melhoria do processo de estimação da margem.

4.3 Situações de contingências

Usando como base os resultados obtidos para cada um dos sistemas anteriormente testados, pretende-se nesta seção avaliar a habilidade da *RNA* de estimar a margem sob condições de contingência nos sistemas IEEE de 30 e 300 barras. Para isto é definido um

cenário de aplicação da metodologia determinado pelas seguintes características:

- O procedimento de previsão de carga estima a demanda com uma precisão de $\pm 4\%$.
- É considerada uma lista de contingências simples formada somente pela saída de ramos.

Para cada um dos sistemas testados, são apresentados gráficos de barras dos erros associados à saída de ramos, onde a posição zero corresponde à topologia base. Também são mostrados gráficos comparativos do valor estimado pela rede neural e o valor calculado para os casos onde a *RNA* fornece os piores resultados de tal forma que seja possível identificar as limitações da metodologia aplicada.

4.3.1 Sistema de 30 barras

A figura 4.17 resume os resultados da configuração de variáveis de entrada com a qual foi obtido o menor erro relativo médio do conjunto completo de dados de validação. Nesse gráfico apresentam-se os erros associados a cada uma das 40 estruturas topológicas consideradas. No estudo não foram incluídas as saídas dos ramos que causam ilhamento ou onde o fluxo de carga não converge para o caso base.




Figura 4.17: Testes de validação usando V, P_p, Q_p como entradas para 3 áreas do sistema.

Para treinar a rede neural o sistema foi dividido em 3 áreas, usando como critério o nível de tensão das barras no *PMC* e como variáveis de entrada foram usadas as magnitudes de

tensão, as perdas de potência ativa e reativa. Esta estrutura de entradas, depois de aplicar o *PCA* com uma variância mínima de 1×10^{-3} , reduz o número de entradas para um total de 40.

Do gráfico do erro médio relativo para cada contingência na figura 4.17 observa-se que o maior erro médio relativo ocorre para um das faltas mais severas, isto é, a saída do ramo 2-5, que deixa o sistema operando com um terço da margem normal. Embora os valores do erro pareçam altos, observando a figura 4.18 poder-se-ia considerar como aceitável a estimativa realizada pela *RNA*. Uma apreciação similar pode-se fazer no pior de todos os casos avaliados, onde a *RNA* produz uma estimativa com um erro relativo máximo de 34%. Isto acontece na saída do ramo 3-4 no horário de 13 hrs. (Fig. 4.19) onde a *RNA* fornece uma margem de 1,68% enquanto o valor calculado é 1,25%.




Figura 4.18: Testes de validação para condições de contingência.




Figura 4.19: Testes de validação para condições de contingência.




Figura 4.20: Testes de validação para condições de contingência.

Em termos gerais, após observar a comparação entre os valores calculados e os estimados pela *RNA*, é possível dizer que a rede neural consegue captar a dinâmica do sistema de 30 barras estimando a margem de estabilidade de tensão para a lista de contingências proposta.

A tabela 4.5 apresenta os resultados conseguidos usando diferentes condições de treinamento. Essas condições são descritas pela configuração de entradas, a variância mínima aplicada no *PCA*, o número de contingências consideradas no treinamento, a quantidade de entradas da *RNA* e de neurônios usados. Os erros gerais sobre o conjunto inteiro de verificação são apresentados, e para tentar descrever a capacidade da *RNA* de estimar efetivamente a margem, são incluídas colunas que contêm a quantidade de contingências com erros médios relativos dentro de intervalos predefinidos.

Tabela 4.5: Testes no sistema IEEE de 30 barras para casos de contingência.

Var. Entrada	σ_{PCA}	Cntg. treino	Ent.	Neur.	Erro relativo		Erro absoluto		Contng. intervalo e_{med}		
					med	máx	med	máx	< 5%	5% – 10%	> 10%
V, P_p, Q_p	1e-3	Base	4	3	54.10	3190.05	0.0573	0.4390	15	5	20
V, P_p, Q_p	1e-3	10	16	1	13.73	451.08	0.0287	0.2937	21	6	13
V, P_p, Q_p	1e-3	20	16	1	6.47	96.92	0.0144	0.1570	20	15	5
V, P_p, Q_p	1e-3	30	15	6	4.34	146.44	0.0017	0.0595	30	6	4
V, P_p, Q_p	1e-3	40	14	3	2.95	115.35	0.0054	0.0628	35	4	1
V, P_p, Q_p . 3 áreas	1e-3	Base	13	1	128.41	1093.60	0.1088	1.5679	17	2	21
V, P_p, Q_p . 3 áreas	1e-3	20	42	9	11.14	317.09	0.0274	0.3170	28	5	7
V, P_p, Q_p . 3 áreas	1e-3	40	40	3	1.57	34.35	0.0029	0.0158	39	1	0
Índice lpq (l_{pq})	1e-3	Base	2	3	320.23	1673.87	0.4461	2.2157	20	2	18
Índice lpq (l_{pq})	1e-3	20	6	9	23.42	405.43	0.0542	0.8781	6	20	14
Índice lpq (l_{pq})	1e-3	40	8	9	14.31	758.17	0.0220	0.2271	16	12	12
l_{pq} . niv3V no PMC	1e-3	40	11	9	6.89	343.85	0.0136	0.1146	20	12	8
V, P, Q	1e-3	Base	5	6	29.79	1252.84	0.0361	0.2229	21	3	18
V, P, Q	1e-3	20	6	9	6.95	90.54	0.0155	0.0636	9	27	4
V, P, Q	1e-3	40	6	9	3.99	93.70	0.0080	0.0719	34	4	2
V, P, Q . 3 áreas	1e-3	Base	12	1	26.68	1988.80	0.0317	0.3186	17	7	16
V, P, Q . 3 áreas	1e-3	20	13	3	5.92	73.71	0.0125	0.0497	16	20	4
V, P, Q . 3 áreas	1e-3	40	13	9	3.46	62.54	0.0066	0.0486	31	7	2

Os resultados mostram que *RNA*'s treinadas somente com dados da topologia base conseguem estimar a margem para um número superior de contingências. Por exemplo, usando como entradas a magnitude de tensão, potência ativa e reativa é possível estimar a margem de carregamento para quase a metade das condições topológicas incluídas no treinamento com erros médios relativos que não superam o 5%. Isto se consegue já que várias contingências não afetam seriamente o estado de operação nem a margem de carregamento do sistema.

Porém, para conseguir melhoras na estimação feita pela *RNA* com uma lista maior de contingências é necessário incluir no conjunto de treinamento informações do funcionamento do sistema para configurações topológicas que mudam sensivelmente o estado de operação. É por essa razão que aos dados da configuração topológica básica foram somadas as contingências mais severas para realizar os testes resumidos na tabela 4.5.

Das configurações de entradas testadas e resumidas na tabela 4.5 observa-se que combinações de variáveis novamente melhoram os resultados, levando vantagem o arranjo de magnitude de tensão e perdas de potência, pois com ela conseguem-se menores erros quando incluídas uma maior quantidade de contingências no treinamento. Contudo treinando com dados de poucas topologias, o uso da tensão e as potências como variáveis de entrada resulta vantajoso. Dividir o sistema em áreas oferece uma melhoria adicional no comportamento da *RNA* para todas as configurações testadas.

4.3.2 Sistema de 300 barras

O processo de treinamento da *RNA* para o sistema de 300 barras converge em níveis maiores de erro se comparado com o sistema de 30 barras, porém ainda com bons níveis de aproximação para um grande número de contingências. A figura 4.21 mostra os erros obtidos para a lista de 292 topologias avaliadas. Porém, o número de contingências de treinamento é bem menor, no máximo 47, que correspondem às situações que afetam de forma mais severa o sistema. As demais não têm uma influência considerável na margem de estabilidade de

tensão e por esta razão não são levadas em consideração.




Figura 4.21: Testes de validação usando V, P_p, Q_p como entradas.

Da mesma forma que no caso do sistema de 30 barras, são apresentados gráficos comparativos dos valores da margem calculados e os estimados pela *RNA* (figuras 4.22, 4.23 e 4.24) para as contingências com os piores resultados em termos do erro relativo.




Figura 4.22: Testes de validação para condições de contingência.




Figura 4.23: Testes de validação para condições de contingência.




Figura 4.24: Testes de validação para condições de contingência.

Como dados de entrada foram escolhidas as magnitudes de tensões, as perdas de potência ativa e as reativas. A esse conjunto de dados foi aplicado o *PCA* com uma variância mínima de 1×10^{-4} que reduz o tamanho do conjunto de entrada de 1122 para 39. Esta configuração treinada com a informação das topologias disponíveis (47) foi a de menor erro

relativo médio e máximo para todo o conjunto de dados de verificação, apesar disso, não é a configuração que consegue maior número de contingências com erros baixos.

As figuras 4.22, 4.23 e 4.24 fornecem uma visão clara dos piores resultados conseguidos ($e_{med} > 10\%$) com a aplicação do método. Nelas observa-se que, embora o *RNA* consiga captar a dinâmica do problema, não é capaz de estimar a margem com bons níveis de precisão. Especialmente para a saída do ramo 193-221 (Fig. 4.24) onde apresenta erros grandes em alguns pontos específicos. As restantes topologias mostradas não têm erros tão grandes quanto o caso anterior, mas possuem um erro constante, que faz aumentar a média.

Tabela 4.6: Testes no sistema IEEE de 300 barras para casos de contingência.

Var. Entrada	σ_{PCA}	Ctng. treino	Ent.	Neur.	Erro relativo		Erro absoluto		Contng. intervalo e_{med}		
					med	máx	med	máx	< 5%	5% – 10%	> 10%
V, P_p, Q_p	1e-4	10	25	6	5.50	157.64	0.0120	0.1122	177	104	11
V, P_p, Q_p	1e-4	20	28	3	5.15	159.31	0.0108	0.1419	204	74	14
V, P_p, Q_p	1e-4	30	33	3	5.43	245.00	0.0112	0.1606	176	106	10
V, P_p, Q_p	1e-4	47	39	3	3.76	121.44	0.0080	0.1155	242	44	6
V, P_p, Q_p	1e-3	47	19	1	4.32	505.51	0.0098	0.1203	260	28	4
V, P_p, Q_p . 3 áreas	1e-3	10	45	1	14.36	22652.56	0.0215	7.4327	170	79	43
V, P_p, Q_p . 3 áreas	1e-3	20	46	1	6.12	232.88	0.0142	0.3170	193	78	21
V, P_p, Q_p . 3 áreas	1e-3	30	47	6	5.38	495.50	0.0117	0.3149	212	57	23
V, P_p, Q_p . 3 áreas	1e-3	47	52	1	4.92	273.09	0.0102	0.1477	230	48	14
V, P, Q	1e-3	10	5	3	9.96	238.54	0.0218	0.0911	10	132	150
V, P, Q	1e-3	20	5	1	7.28	397.04	0.0184	0.1014	23	257	12
V, P, Q	1e-3	30	5	6	5.63	357.99	0.0131	0.1537	102	183	7
V, P, Q	1e-3	47	5	3	4.21	449.14	0.0095	0.1209	258	30	4
V, P, Q . 3 áreas	1e-3	10	16	6	7.90	357.41	0.0222	0.3920	173	65	56
V, P, Q . 3 áreas	1e-3	20	15	6	7.60	335.06	0.0194	0.1686	22	231	39
V, P, Q . 3 áreas	1e-3	30	16	3	5.93	543.78	0.0145	0.1071	101	179	12
V, P, Q . 3 áreas	1e-3	47	15	1	5.15	537.38	0.0112	0.0779	178	105	9

Dos dados resumidos na tabela 4.6, nota-se que a melhor configuração em termos do erro médio geral é a formada pela magnitude da tensão e as perdas de potência usando uma variância mínima no *PCA* de 1×10^{-4} . Porém, aumentando esse valor para 1×10^{-3} , tanto na mesma configuração quanto na composta pela magnitude de tensão e as potências, observa-se que o número de casos de contingências que a *RNA* consegue estimar com erros baixos aumenta, mas por outra parte também aumentam os erros máximos e portanto os médios.

A divisão do sistema em áreas, que nos casos anteriores tinha-se mostrado útil, não oferece nenhum benefício pelo contrário piora o comportamento da *RNA*, aumentando os erros de estimação e a quantidade de casos com erros acima dos valores toleráveis.

Pode-se verificar que, treinando a rede neural com um número relativamente pequeno de condições topológicas, conseguem-se resultados aceitáveis para uma grande quantidade de contingências. Aliás, o aumento de contingências no conjunto de treinamento não representa uma melhoria significativa, pois a redução do número de casos com erros relativos médios acima de 10% não muda drasticamente com o incremento das informações de treinamento incluídas.

Capítulo 5

Conclusões

Neste trabalho é apresentada uma metodologia de estimação da margem de estabilidade de tensão baseada na utilização de redes neurais artificiais, que busca analisar o comportamento das mesmas e propor uma estrutura de treinamento que permita resolver o problema abordado apresentando uma alternativa de cálculo rápida e precisa que possa ser aplicada num ambiente de operação em tempo real.

Para alcançar esse objetivo, foi proposta uma estratégia de treinamento que parte das informações obtidas do processo de previsão de carga e usa grandezas mensuráveis diretamente do sistema ou de cálculo simples como entradas de uma rede neural multicamada que estimará a margem a partir desses dados. Adicionalmente foi incluído um procedimento de redução do tamanho do conjunto de entradas chamado *Principal Component Analysis (PCA)* para melhorar a performance da *RNA*.

As curvas de previsão de demanda oferecem uma opção interessante para delimitar a faixa de operação do sistema onde se espera que a *RNA* estime de forma precisa a margem, já que são ferramentas amplamente usadas em todas as empresas operadoras de sistemas elétricos de potência. Aliás, analisando estatisticamente a precisão do processo de previsão de carga é possível definir o tamanho da região provável de operação, pois erros de previsão pequenos reduzirão a amplitude da região onde deve aprender a *RNA*.

Inicialmente se esperava que os índices de proximidade ao colapso favorecessem a aprendizagem da rede neural por serem grandezas que representam o estado de operação do sistema em relação à estabilidade de tensão. Porém a *RNA* não consegue estabelecer uma relação entre eles e a margem de estabilidade, o que pode ser atribuído, no caso do vetor tangente, às grandes discontinuidades que apresenta nos pontos onde os geradores esgotam sua reserva de reativos.

A utilização de variáveis de forma independente só apresenta bons resultados em sistemas pequenos e para uma condição topológica de operação normal. Em geral as combinações

de variáveis forneceram níveis de erro menores incluso ao considerar casos de contingência simples.

Embora não seja possível determinar uma configuração de entradas que permita resolver o problema da estimação da margem de tensão para qualquer rede elétrica, pode-se dizer que para os sistemas testados o arranjo da magnitude de tensão com as perdas de potência oferece resultados com erros aceitáveis. Especialmente chama a atenção a contribuição das perdas de potência ativa no comportamento da *RNA*. Pois no caso do sistema de 300 barras é a grandeza que sendo aplicada de forma separada permite obter os melhores níveis de generalização.

A divisão do sistema em áreas demonstrou contribuições positivas no comportamento das *RNA*'s na maioria dos sistemas testados, com exceção do cenário de contingências no sistema de 300 barras, onde os resultados obtidos com esta estrutura superaram os conseguidos com o sistema inteiro.

A aplicação do *PCA* mostrou-se uma ferramenta útil no treinamento da *RNA* simplificando essa tarefa, garantindo que os dados utilizados aplicados à rede neural representem as principais características das variáveis reais do sistema, o que facilita o aprendizado da *RNA* no sentido de diminuir a quantidade de padrões de treinamento necessários para obter níveis desejáveis de generalização. Porém é necessário realizar testes para escolher o valor da variância mínima mais conveniente.

O *PCA* apresenta algumas limitações no processamento de conjuntos grandes de dados, pois é bastante exigente em termos de memória, o que poderia limitar sua aplicação com conjuntos de treinamento que incluam listas de contingências muito maiores às analisadas neste trabalho. O anterior resulta concordante com a observação feita nesse mesmo sentido na referência [6]

Com base nos resultados obtidos não é possível determinar uma arquitetura que possa se adotar como padrão para estimar a margem de carregamento. Portanto são indispensáveis testes comparativos entre diferentes estruturas de *RNA*'s para determinar aquela que oferece melhores erros de validação.

Para uma única configuração topológica as redes neurais conseguem estimar a margem de estabilidade de tensão com grande precisão para cenários possíveis de operação amplos requerendo conjuntos de treinamento relativamente pequenos. Mostrando-se aplicável para casos em que o procedimento de previsão de carga não é muito confiável.

Quando aplicadas a múltiplas condições de contingência as redes neurais captam efetivamente a dinâmica do sistema, mesmo que não tenham sido treinadas com informações de todas as topologias contempladas, mostrando uma boa capacidade de generalização o que

simplifica as etapas iniciais de simulação para a obtenção dos conjuntos de treinamento.

Embora o treinamento das *RNA*'s para diferentes casos de contingência forneça erros consideráveis quando comparados com o treinamento de uma única topologia, pode-se considerar que a estimação feita pela *RNA* oferece informações importantes aos operadores dos sistemas sobre estado do sistema elétrico de potência em relação à estabilidade de tensão que podem ajudar na operação segura da rede elétrica.

Os resultados apresentados nesta dissertação são encorajadores, sendo interessante numa etapa seguinte a aplicação desta metodologia num sistema real usando dados reais de operação como dados de treinamento da *RNA* e considerando uma lista maior de contingências que inclua saída de geradores, desligamento de capacitores, assim como também algumas das contingências múltiplas mais prováveis.

É provável que a *RNA* não consiga estimar a margem com erros suficientemente pequenos, mas poderia ser usada como um método primário de estimação e a partir dele usar outros métodos de ajuste que permitam chegar ao valor exato da margem.

Referências Bibliográficas

- [1] Vadari, S.V.; Venkata, S.S. A hybrid artificial neural network/artificial intelligence approach for voltage stability enhancement ; *Neural Networks to Power Systems, 1991., Proceedings of the First International Forum on Applications of*, 23-26 July 1991, pp:154 - 160
- [2] Hiu, K.; Short, M.J. A neural networks approach to voltage security monitoring and control; *First international forum on aplicatiopns o neural networks to power systems*, Seattle, WA, july 17-20 1991, pp:89-96
- [3] Whenkel, L., Van Custem, T., Pavella, M., Heilbornn, B; Pruvot, P.; Machine learning, neural networks and statistical pattern recognition for voltage security: a comparative study, *Proceedings of the First International Conference on Intelligent Systems Applications to Power Systems 1994*, 4-8 sept 1994, pp:521 - 528
- [4] Dingguo Chen; Mohler, R.R.; Neural-network-based load modeling and its use in voltage stability analysis *IEEE Transactions on Control Systems Technology*, Volume: 11 , Issue: 4 , July 2003 Pages:460 - 470
- [5] B. Jeyasurya, Artificial neural networks for on-line voltage stability asesment, *IEEE PES Summer Meeting*, 2000.
- [6] Repo, S.; Laaksonen, H.; Jarventausta, P.; Huhtala, O.; Mickelsson, M; General framework for neural network based real-time voltage stability assessment of electric power system . *Power Tech Conference Proceedings, 2003 IEEE Bologna* ,Volume: 4 , June 23-26, 2003, Pages:71 - 76
- [7] El-Keib, A.A.; Ma, X. Application of artificial neural networks in voltage stability assessment. *IEEE Transactions on Power Systems* ,Volume: 10 , Issue: 4, Nov. 1995, Pages:1890 - 1896
- [8] Mansour, Y. Suggested Techniques for Voltage Stability Analysis, IEEE Power Engineering Society, 93TH0620-5PWR, 1993.
- [9] Chiang, H.D.; Flueck, A.J.; Balu, N. CPFLOW: A practical tool for tracing power systems steady-state stationary behavior due to load and generation variations, *IEEE Transactions on Power Systems*, vol.10, n.2, 1995.

- [10] Kundur Prabha. Power System Stability and Control. *Ed. McGraw-Hill, Inc.*, New York, EUA, 1994.
- [11] C. W. Taylor Power System Voltage Stability. *Ed. McGraw-Hill, Inc.*, New York, EUA, 1993.
- [12] Anderson Paul, Fouad A. Power System Control and Stability. *IEEE PRESS, Inc.*, New York, EUA, 1977.
- [13] Moghavvemi, M.; Faruque, M.O. Power system security and voltage collapse: a line outage based indicator for prediction, *Electrical Power and Energy Systems*, vol.21 1997, pp 455-461.
- [14] Adriana L. Tognete, Um novo método de cálculo de margem de segurança ao colapso de tensão utilizando análise de sensibilidade, *Dissertação de Mestrado*, DSEE/FEEC, Universidade Estadual de Campinas, Ago 1997.
- [15] B.F.A. Lemos, A.A.P. Lerm, A.S. Silva, Estabilidade de tensão: uma abordagem através da teoria de bifurcações, *XI Congresso Brasileiro de Automática*, São Paulo, SP, 1996.
- [16] R.B. Prada, X. Vieira Filho, Voltage stability system critical area identification based on the existence of maximum power flow transmission, *Power Systems Computation Conference*, vol.1, 1993.
- [17] Voltage stability of power systems: concepts, analytical tools, and industrial experience, *IEEE 90TH0358-2-PWR*, 1990.
- [18] Y. Harmand, M. Trotignon, J.F. Lesigne, J.M. Tesserou, C. Lemaitre, F. Bourgin, Analysis of a voltage collapse incident and proposal for a time-based hierarchical containment scheme, *CIGR é Report 38/39-02*, 1990.
- [19] A.J. Calvaer, E. Van Geert, Quasi steady state synchronous machine linearization around an operating point and applications, *IEEE Transactions on Power Apparatus and Systems*, vol.PAS-103, n.6, 1984.
- [20] K. Walve, Modelling of power system components at severe disturbances, *CIGR é Report 38-18*, 1986.
- [21] J.F. Christensen, A.W. Grainger, G. Santagostino, M. Stube, J. Verseille, Planning against voltage collapse, *Electra*, n.111, Mar 1987.
- [22] H. Ohtsuki, A. Yokoyama, Y. Sekine, Reserve action of on-load tap changer in association with voltage collapse, *IEEE Transactions on Power Systems*, vol.6, n.1, 1991.
- [23] M.A. Pai, P.W. Sauer, Power systems steady-state stability and the load-flow Jacobian, *IEEE Transactions on Power Systems*, vol.5, n.4, 1990.
- [24] V.A. Venikov, V.A. Stroeve, V.I. Idelchick, V.I. Tarasov, Estimation of electric power system steady-state stability in load-flow calculation, *IEEE Transactions on Power Apparatus and Systems*, vol.PAS-94, n.12, 1975.

- [25] M.K. Pal, Voltage stability conditions considering load characteristics, *IEEE Transactions on Power Systems*, vol.7, n.1, 1992.
- [26] W. Xu, Y. Mansour, Voltage stability analysis using generic dynamic load models, *IEEE Transactions on Power Systems*, vol.8, n., 1993.
- [27] Y. Sekine, A. Yokoyama, K. Takenaka, T. Kumano, Mode transition of multiple load flow solution, Bulk Power System Voltage Phenomena-Voltage Stability and Security, *EPRI-EL 6183*, Project 2473-21, 1989.
- [28] F.D. Galiana, Z.C. Zeng, Analysis of the load flow behavior near a Jacobian singularity, *IEEE Transactions on Power Systems*, vol.7, n.3, 1992.
- [29] B. Gao, G.R. Morison, P. Kundur, Voltage stability evaluation using modal analysis, *IEEE Transactions on Power Systems*, vol.7, n.4, 1992.
- [30] D.J. Hill, P.-A. L'of, T. Smed, G.Andersson, Fast calculation of a voltage instability index, *IEEE Transactions on Power Systems*, vol.7, n.1, 1992.
- [31] R.A. Schlueter, I. Hu, M.W. Chang, J.C. Lo, A. Costi, Methods for determining proximity to voltage collapse, *IEEE Transactions on Power Systems*, vol.6, n.1, 1991.
- [32] F.L. Alvarado, T.H. Jung, Direct detection of voltage collapse conditions, Bulk Power System Voltage Phenomena-Voltage Stability and Security, *EPRI-EL 6183*, Project 2473-21, 1989.
- [33] I. Dobson, Observations on the geometry of saddle node bifurcations and voltage collapse in electrical power systems, *IEEE Transactions on Circuits and Systems*, vol.CAS-39, n.3, 1992.
- [34] Z.C. Zeng, F.D. Galiana, A simplified approach to estimate maximum loading conditions, *IEEE Transactions on Power Systems*, vol.8, n.2, 1993.
- [35] N. Flatabø, R. Ognedal, T. Carlsen, Voltage stability condition in a power transmission system calculated by sensitivity methods, *IEEE Transactions on Power Systems*, vol.5, n.4, 1990.
- [36] N. Flatabø, O.B. Fosso, R. Ognedal, T. Carlsen, K.R. Heggland, A method for the calculation of margins to voltage instability applied on the norwegian system for maintaining required security level, *IEEE Transactions on Power Systems*, vol.8, n.3, 1993.
- [37] J. Jarjis, F.D. Galiana, Quantitative analysis of steady state stability in power networks, *IEEE Transactions on Power Apparatus and Systems*, vol.PAS-100, n.1, 1981.
- [38] O.O. Obadina, G.J. Berg, Determination of voltage stability limit in multimachine power systems, *IEEE Transactions on Power Systems*, vol.3, n.4, 1988.
- [39] T. van Cutsem, A method to compute reactive power margins with respect to voltage collapse, *IEEE Transactions on Power Systems*, vol.6, n.1, 1991.

- [40] Edwards, C.; Lights out for UK *IEE Review* , Volume: 49 , Issue: 8 , Aug. 2003 Pages:18 - 19
- [41] *EFEI Energy news* Ano 6 N. 419 - Edição 050103 - Janeiro de 2005.
- [42] Bose, A., Concordia C., Dunlop R. D., Fouad A. A., Kundur P., Shulz R. P., Proposed Terms and Definitions for Power System Stability, *IEEE Transactions on Power Apparatus and Systems*, Vol. PAS-101, No 7, July 1982.
Gomes, P.; de Lima, A.C.S.; de Padua Guarini, A.; Guidelines for power system restoration in the Brazilian system Power Systems, *IEEE Transactions on* , Volume: 19 , Issue: 2 , May 2004 Pages:1159 - 1164
- [43] T. J. Overbye; C. L. DeMarco. Voltage security enhancement using energy based sensitivities *IEEE Transactions on Power Systems*, Vol. 6, No. 3, August 1991.
- [44] Zambroni A., Cañizares C. A., Quintana V. H.; Critical bus and point of collapse determination using tangente vectos *28th North american power symposium*, 1996, Cambridge - USA.
- [45] Niño, E. E. Estudo do fluxo de carga da continuação: parametrização automática por perdas de potência ativa em ramos. *Dissertação de Mestrado*, Universidade Estadual de Campinas, SP, setembro de 2002.
- [46] A.S. Quintela, C.A. Castro, Estudo de um índice de proximidade ao limite de estabilidade de tensão e sua aplicação na seleção de contingências, *Dissertação de Mestrado*, Unicamp, 2002.
- [47] V.L. Paucar, M.J. Rider, Artificial Neural Networks for Solving the Power Flow Problem in Electric Power Systems, *Electric Power Systems Research*, 2002.
- [48] S. Haykin, Neural Networks: a comprehensive foundation, *MacMillan College Publishing Co.*, 1994.
- [49] Aleksander, I.; H. Morton. An introduction to neural computing. Chapman and Hall, London, 1990
- [50] Koch, C.; I. Segev. Methods in neural modeling: from synapses to networks. Cambridge, MA, MIT Press, 1989.
- [51] Woods, W. A. Important issues in knowledge representation, *IEEE proceedings*, vol 74, pp. 1322-1334, 1986
- [52] Anderson, J.A. Introduction to Neural Networks, Cambridge, MA. MIT Press 1995
- [53] Funahashi, K. On the approximate realization of continuous mappings by neural networks. Neural Networks, Vol. 2, pp 183-192, 1989.
- [54] LeCun Y. Efficient Learning and second-order methods, a tutorial at NIPS 93, Denver, 1993.

- [55] Schalkoff, R.J. Artificial Neural Networks , The McGraw-Hill Companies, 1997.
- [56] Delgado J. A. Inteligencia artificial y minirobots, Material de clase, Universidad Nacional de Colombia, 1999.
- [57] Von Zuben F.J. Redes neurais, Notas de Aula, Universidade Estadual de Campinas, Material de aula 2004.
- [58] Sage, A. P. Concise encyclopedia of informatios porcessing in systems and organization, New York: Pergamon, 1990.
- [59] Churchland P.S.; T.J. Sejnowski. The computational Brain, Cambridge, MA: MIT Press, 1992.
- [60] Fischler, M.A.; Fieshein O. Intelligence: the eye, the brain and the computer, Reading, MA: Addison-Wesley, 1987.
- [61] Hebb D. O.;The organization of behavior: A neuropsychological theory, New York: Wiley, 1949.
- [62] Grossberg S.; Neural Networks ans Natural Intelligence, Cambridge, MA: MIT Press, 1988.
- [63] "Common Format for Exchange of Solved Load Flow Data". Working Group on a Common Format for Exchange of Solved Load Flow Data *IEEE Transactions on PAS*, PAS-92, no.6,Nov/Dec'1973, pp.1916-25.
- [64] <http://www.ee.washington.edu/research/pstca/>.
- [65] Moticelli, A. J. Fluxo de carga em redes de energia elétrica. Ed. Edgard Blucher. 1983. 164 p.
- [66] Sttot B, Alsaç O. Fast decoupled load flow, *IEEE Transactions on Power Apparatus and Systems*, PAS-93(3). 1749, pp 589-869.

Apêndice A

Redes Neurais Artificiais

A.1 Introdução

A computação neural representa uma alternativa aos métodos computacionais clássicos, baseada na idéia de desenvolver ferramentas que emulem características dos sistemas neurais biológicos como a robustez, flexibilidade, adaptabilidade, e estabilidade [58].

O cérebro é um processador altamente complexo, não linear e paralelo que é capaz de realizar algumas tarefas com maior eficiência e velocidade que os computadores atuais, tais como o reconhecimento de padrões, a percepção, ou o controle de movimentos [59]. Essas operações são realizadas graças à capacidade que tem o cérebro de estabelecer suas próprias regras, o que é normalmente conhecido como “*experiência*”.

O sistema nervoso consegue acumular a experiência ou “*aprender*” mediante um procedimento que lhe permite adaptar-se ao ambiente. Estes processos estão relacionados intimamente com as estruturas básicas que conformam o cérebro, chamadas *neurônios* [48]. Elas, apesar de serem elementos de processamento extremamente simples, conseguem incrementar significativamente seu poder através da formação de imensas redes. É precisamente nas interligações dos neurônios que é armazenado o conhecimento.

Em geral, uma *rede neural artificial (RNA)*, é uma máquina projetada para resolver uma tarefa particular através de um processo de aprendizado, da mesma forma que seria feita pelo cérebro, baseada na interconexão massiva de unidades de processamento simples (neurônios). Uma definição mais formal do ponto de vista da *RNA* como máquina adaptável foi proposta por Aleksander e Morton [49]:

Uma rede neural é um processador distribuído, altamente paralelo, composto por unidades de processamento simples, as quais têm a capacidade natural de armazenar conhecimento experimental e disponibilizá-lo para ser usado. A RNA tem duas semelhanças básicas com o cérebro:

1. *O conhecimento é adquirido do ambiente através de um processo de aprendizado*
2. *As ligações interneurais, assim como as ligações sinápticas são usadas para armazenar o conhecimento adquirido.*

As redes neurais reagem, aprendem, e se auto-organizam. Portanto em lugar dos algoritmos convencionais usados nos computadores comuns baseados na arquitetura de Von Neumann, elas são treinadas mediante um conjunto de regras que definem o modo de ajuste de seus parâmetros de forma a obter a resposta para a qual foram projetadas [55].

A rede neural reage em paralelo a eventos que são percebidos pelas suas entradas, e as respostas em lugar de estarem predefinidas por um modelo matemático ou um algoritmo armazenado na memória, são obtidas pela inter-relação de todos os neurônios. Portanto, o poder da rede neural encontra-se distribuído na sua topologia, o que as tornam robustas e tolerantes a falhas, já que o erro produzido por um elemento defeituoso será compensado pela atividade neural global. Uma outra característica interessante das *RNA's* é a capacidade de generalização, a qual pode ser definida como a habilidade de fornecer respostas razoáveis em casos para os quais não foram treinadas [48].

Além das características anteriormente assinaladas, existem outras propriedades que fazem as *RNA's* interessantes na solução de problemas altamente complexos:

- Aproximador de funções não-lineares
- Mapeamento entrada-saída
- Adaptabilidade
- Simplicidade de análise e projeto

Contudo, as *RNA's* não se apresentam como um substituto dos computadores convencionais, e sim como um complemento onde o desempenho destes tem apresentado limitações, como por exemplo na classificação e reconhecimento de padrões, processamento de imagens, reconhecimento de voz. Os computadores de estrutura seqüencial continuarão sendo utilizados na realização de cálculos matemáticos por sua precisão e rapidez.

A.2 Modelo Biológico

O cérebro não é uma massa uniforme, mas uma teia formada por pequenas células conhecidas como neurônios, todas elas interconectadas. Estima-se que o córtex do cérebro humano é constituído por aproximadamente 10 bilhões de neurônios e as interligações chegam a pelo menos 60 trilhões de conexões também conhecidas como *sinapses* [50]. Se comparadas

a velocidade de resposta de um neurônio (10^{-3} s) com a de um chip eletrônico (10^{-9} s), elas resultam muito mais lentas, mas a demora é compensada pelo processamento em paralelo que torna a execução da tarefa mais eficiente.

Nesta seção são apresentadas algumas características básicas das redes neurais biológicas que contribuem com a clarificação das mais importantes propriedades emuladas pelas redes neurais artificiais, ajudando na compreensão dos mecanismos de aprendizado das mesmas.

Embora existam neurônios especializados em diferentes tarefas, com algumas diferenças entre eles, é possível dizer que morfologicamente possuem a mesma conformação. A figura A.1 mostra um neurônio biológico e cada uma de suas partes.




Figura A.1: Neurônio biológico.

Um neurônio possui três componentes principais, os quais têm um papel fundamental na transmissão e processamento dos impulsos nervosos. Eles são: *dendritos*, *soma* e *axônio*, os dendritos recebem os sinais dos neurônios vizinhos ou diretamente dos receptores sensitivos [52].

O soma, ou corpo celular é o responsável por processar os sinais entrantes, e se o nível de excitação for suficiente, o neurônio é ativado e transmitirá seu próprio sinal usando o axônio para interligar-se com outros neurônios.

Os sinais são transmitidos em forma de impulsos elétricos através das *junções sinápticas* através de processos químicos denominados *sinapses*. A sinapse é influenciada pela ação dos

neuro-transmissores, que são substâncias químicas que modulam os impulsos recebidos pelo neurônio inibindo ou fortalecendo a transmissão dos sinais.

São precisamente as junções sinápticas as responsáveis pela capacidade de permanente adaptação do cérebro humano a seu ambiente, pois a cada momento estão sendo criadas junções entre neurônios diferentes ou modificadas as sinapses existentes, sendo nelas que o conhecimento é armazenado [48].

A principal teoria da forma em que o neurônio biológico aprende, foi proposta por Donald O. Hebb. [61] Segundo o cientista canadense, o aprendizado nos neurônios acontece pela atividade neural coincidente, isto é conhecido como a lei de Hebb: *“quando o axônio da célula A excita a célula B de forma repetida, ocorre algum processo de crescimento ou mudança metabólica em uma ou ambas células, tal que a eficácia de A para ativar a B aumenta.”*

Em 1963 Ladislav Tauc e Eric Kandel formularam uma segunda regra de aprendizado. Eles acharam que a junção sináptica entre dois neurônios pode se fortalecer sem necessidade de atividade da célula pós-sináptica, graças à presença de uma terceira célula chamada *moduladora* a qual aumenta a liberação dos neuro-transmissores favorecendo a ativação da célula pós-sináptica.

A.3 Modelo Matemático [48]

A partir da descrição da fisiologia neural apresentada anteriormente, foi proposto um modelo matemático (Figura A.2) que representasse as características básicas desejadas do sistema biológico. Em resumo, a rede pode ser representada por um conjunto de entradas (x_j) que são aplicadas ao neurônio artificial, cada uma delas representando uma informação externa ou a saída de um neurônio vizinho.




Figura A.2: Modelo matemático do neurônio biológico.

O modelo da figura A.2, inclui um sinal adicional *bias*, denotado por b_i que favorece ou limita a possibilidade de ativação do neurônio, de maneira semelhante ao efeito da ação da

célula moduladora descrita anteriormente.

O processo sináptico é representado pelos *pesos* (w_{ij}), que são valores que amplificam cada um dos sinais recebidos. Já a tarefa de processamento da informação, que no neurônio biológico é realizada pelo *soma*, modela-se por um somador, que pode ser resumido como uma combinação linear. A forma como o neurônio responde ao nível de excitação, é modelada pela *função de ativação* ($\varphi(\cdot)$), a qual limita e define a saída da *RNA*.

Matematicamente o neurônio pode ser representado pelas seguintes equações:

$$u_i = \sum_{n=1}^j w_{in} x_n \quad (\text{A.1})$$

$$v_i = u_i + b_i \quad (\text{A.2})$$

$$y_i = \varphi(v_i) \quad (\text{A.3})$$

A função de ativação $\varphi(\cdot)$ que define a saída do neurônio, podendo ter diferentes representações, as quais são usadas de acordo com a conveniência e como critério de projeto em cada aplicação. As funções mais comuns na literatura são: a linear (eq. A.4), o degrau (eq. A.5), a função sigmóide (eq. A.6) e a tangente hiperbólica (eq. A.7).

$$\sigma(\theta) = \theta \quad (\text{A.4})$$

$$\sigma(\theta) = \begin{cases} 1, & \theta \geq 0 \\ 0, & \theta < 0 \end{cases} \quad (\text{A.5})$$

$$\sigma(\theta) = \frac{1}{1 + e^{-\theta}} \quad (\text{A.6})$$

$$\sigma(\theta) = \text{tgh}(\theta) \quad (\text{A.7})$$

É importante salientar que este modelo ignora diversas características do neurônio biológico, tais como a desconsideração dos atrasos de tempo que afetam a dinâmica e dos efeitos do sincronismo e da modulação se frequência. Apesar destas limitações as *RNA's* formadas por neurônios simples conseguem representar atributos dos sistemas naturais, como a capacidade de aprendizagem e generalização, podendo-se dizer que a essência do mecanismo biológico foi captada [52].




Figura A.3: Funções de ativação típicas.

A.3.1 Arquiteturas típicas

Uma rede neural é uma estrutura que processa informação em forma distribuída e é formada por elementos de processamento (neurônios), interconectados por canais unidirecionais. Cada elemento de processamento tem uma conexão de saída a qual ramifica-se em múltiplas ligações. As *RNA's* podem ser organizadas de formas diferentes, permitindo ter alternativas distintas na solução de uma ampla gama de problemas.

As topologias encontradas na literatura podem ser divididas em duas classes básicas:

- Não recorrentes
- Recorrentes

As *RNA's* não recorrentes ou estáticas são aquelas que não possuem realimentação das saídas para as suas entradas e por isso são consideradas “*sem memória*”, podendo estar organizadas em uma ou múltiplas camadas. Exemplos de redes estáticas são apresentados nas figuras A.4 e A.5.




Figura A.4: Rede neural de camada única.




Figura A.5: Rede neural multicamada.

As redes de camada única (figura A.4), possuem uma camada de entrada ligada diretamente com a camada de neurônios que processa os sinais e entrega a resposta global da rede.

Nas redes neurais multicamada (figura A.5), os sinais de entrada estão formados por um conjunto de n entradas, uma ou várias camadas intermediárias ou *escondidas* contendo N neurônios e por último uma camada de saída de tamanho m ; sendo especificadas pela quantidade de neurônios em cada camada da seguinte forma: $n-N-m$. Este tipo de rede tem a capacidade de resolver problemas complicados, com processos de treinamento mais complexos que os das redes simples. Geralmente o treinamento tem maior sucesso, sendo maiores as possibilidades de resolver um problema que com uma rede de camada única, pois as camadas escondidas permitem captar características não-lineares de ordem superior [59].

As *RNA's* recorrentes são redes mais gerais que contêm realimentação das saídas de neurônios posteriores. Além disso, estas estruturas não estão organizadas necessariamente em camadas, e quando são, estas podem ter interligações entre neurônios da mesma camada e de camadas não consecutivas, gerando interconexões bem mais complexas. Na figura A.6 apresenta-se um exemplo de rede recorrente.




Figura A.6: Rede neural recorrente.

As redes neurais recorrentes também são chamadas redes com memória, já que ao serem realimentadas respondem a estímulos dinamicamente, isto quer dizer que após aplicar uma nova entrada, a saída é calculada, e realimentada até o estado de equilíbrio ser alcançado. Precisamente esta é a principal dificuldade que apresentam, pois garantir um comportamento estável não é uma tarefa simples [48].

Porém, existem trabalhos como os apresentados por Cohen e Grossberg [62] na década de 80, em que estabelecem alguns critérios para a estabilidade de redes recorrentes. Hopfield apresentou contribuições teóricas importantes, sendo conhecido por algumas configurações especiais que hoje levam seu nome.

A.4 Aprendizado em *RNA*'s

A habilidade de aprender que possuem algumas espécies animais, é uma das características mais interessantes que as *RNA*'s têm conseguido imitar dos sistemas biológicos. Isto se deve ao fato de que elas não precisam de ações detalhadas da forma em que devem responder a cada evento, tal como é feito num algoritmo convencional. Isto quer dizer que podem-se tratar problemas onde as regras não são fáceis de serem obtidas a priori [60].

A principal tarefa de uma *RNA* é aprender um modelo do ambiente no qual se encontra imersa e manter uma consistência suficiente do modelo com o mundo real para alcançar os objetivos especificados. O conhecimento do mundo envolve dois tipos de informações básicas:

- Ter um conhecimento inicial do problema a ser resolvido.
- Contar com informações do problema que se quer resolver com a *RNA*

Em aplicações reais de máquinas “inteligentes” pode-se dizer que uma boa solução

depende de uma boa representação do conhecimento [51]. Apesar do elevado grau de complexidade deste assunto, existem algumas regras gerais que é recomendável seguir [52].

1. Entradas similares de classes similares deveriam produzir representações similares na rede, e portanto deveriam ser classificadas dentro da mesma categoria.
2. Padrões correspondentes a classes diferentes, deveriam ter uma representação suficientemente diferenciada.
3. Se alguma característica é importante, devem ser envolvidos uma boa parte dos neurônios da rede na representação desse item.
4. Informações iniciais invariáveis devem ser consideradas nas etapas de projeto para simplificar a *RNA* evitando aprendê-las.

Existe uma estreita relação entre o conceito de aprendizado Hebbiano [48] apresentado neste capítulo para sistemas biológicos, e o conceito aplicado nas *RNA*'s, que está definido como uma modificação realizada na matriz de pesos da rede neural, no sentido de otimizar o mapeamento dos padrões entrada-saída. Embora para redes e problemas simples fosse possível ajustar os parâmetros manualmente, é necessária a implementação de mecanismos de ajuste automático dos pesos durante o processo de aprendizado da rede [48].

O processo de aprendizado, é o procedimento pelo qual os parâmetros da rede neural são adaptados mediante a simulação do ambiente onde a *RNA* é aplicada. O tipo de aprendizado é determinado pela forma em que as mudanças nos parâmetros são feitos.

O *algoritmo de treinamento* pode ser definido como um conjunto predefinido de regras claras para a solução do problema de aprendizado [48]. Normalmente, os algoritmos de treinamento estão associados com a estrutura de *RNA*, havendo várias alternativas para resolver este problema, cada uma delas com suas próprias vantagens. Elas apresentam diferenças basicamente na forma em que os pesos sinápticos são atualizados.

A representação do conhecimento numa *RNA* está diretamente relacionada com a arquitetura da rede. Infelizmente, ainda não é suficientemente sólida a teoria de otimização a arquitetura da rede neural requerida para interagir com o ambiente de interesse, ou para avaliar a forma na qual as mudanças na estrutura afetam a representação do conhecimento da rede. Certamente, com estudos experimentais exaustivos é possível achar algumas respostas, que são fundamentais no projeto de redes neurais.

Um outro fator a ser considerado é a maneira na qual a rede neural conforma suas interações com relação ao seu ambiente. É neste contexto que é preciso diferenciar o *paradigma de aprendizado* que não é nada mais do que o modelo do ambiente onde a rede neural operará.

A.4.1 Treinamento supervisionado

Sob este paradigma de treinamento, o modelo do ambiente é previamente conhecido e a rede neural obtém o conhecimento a partir de um conjunto de exemplos ou padrões entrada-saída previamente selecionados do problema que se quer resolver [48]. Esse conjunto deve conter uma descrição global do comportamento do sistema. Na figura A.7 apresenta-se um diagrama de blocos que descreve a idéia do treinamento supervisionado. As entradas do sistema são apresentadas à *RNA* e a resposta dela é comparada com a resposta esperada. O comportamento da *RNA* é modificado iterativamente mediante um procedimento de ajuste dos pesos sinápticos (algoritmo de treinamento) até satisfazer algum critério estatístico que garanta resultados aceitáveis. Já neste ponto pode-se considerar que a rede neural está pronta para atuar por ela mesma no ambiente para o qual foi treinada.




Figura A.7: Treinamento supervisionado.

A.4.2 Treinamento não supervisionado [48]

No caso do paradigma de aprendizado não supervisionado não existe um conhecimento prévio do ambiente de operação da rede neural, e portanto não existe uma forma de dizer à rede neural como se deve comportar. Sob este segundo paradigma existem duas subdivisões que serão descritas a seguir.

A.4.2.1 Programação Neurodinâmica

O conhecimento é adquirido mediante mapeamento entrada-saída conseguido pela contínua interação com o ambiente a fim de minimizar um índice de performance (escalar), que reflete o desempenho da rede neural na solução da tarefa especificada. Na figura A.8 mostra-se a estrutura básica que descreve esta forma de aprendizado. O bloco denominado *crítico* realiza a tarefa de avaliação da relação entre o *RNA* e o ambiente. Depois, por algum procedimento de ajuste, os parâmetros internos da rede são ajustados com base no valor do índice fornecido pelo *crítico* até otimizar o comportamento da rede neural.




Figura A.8: Programação neurodinâmica.

A.4.2.2 Aprendizado auto-organizado

Nesta forma de aprendizado não supervisionado, não há a possibilidade de conhecer exemplos de como se comportar, nem existe um mecanismo para interagir com o ambiente como acontece na programação neuro-dinâmica. Portanto a rede neural deve fazer uma auto-associação dos sinais recebidos, pois os pesos sinápticos são ajustados com relação à essa associação. Uma vez que a rede tenha feito uma classificação estatística das entradas, ela desenvolve a habilidade de codificar as características das entradas, o que permite a criação de novas classes de padrões.

A.5 Redes neurais multicamada

Este tipo de rede neural é formado por um conjunto de unidades sensoriais que constituem a camada de entrada, uma ou várias camadas escondidas de nós de processamento, e uma camada de neurônios de saída. Nelas o sinal de entrada é propagado para as camadas escondidas de forma unidirecional até alcançar os nós de saída. Este tipo de rede tem sido aplicado na solução de problemas complexos usando a estratégia de treinamento supervisionado combinada com um algoritmo de treinamento largamente usado, chamado *Back-propagation*.

As redes multicamada baseiam-se em três características fundamentais para resolver os problemas nos quais são aplicadas:

1. Utilizam uma função de ativação não-linear *suave*, sem descontinuidades, e continuamente diferenciável (ex. *tgh*, *sigmóide*).
2. A presença de neurônios escondidos entre as camadas de entrada e saída são os responsáveis do processamento da informação.
3. Alto grau de conectividade entre os neurônios de cada camada.

Estas mesmas características representam as maiores limitações na análise das redes multicamada, já que a não-linearidade espalhada nos neurônios torna o estudo teórico complexo,

e as camadas escondidas dificultam o entendimento do processo de aprendizado da *RNA*.

A.5.1 Algoritmos de treinamento

A.5.1.1 Back-propagation [56]

É um algoritmo de aprendizado supervisionado onde os pesos dos neurônios são atualizados a fim de minimizar o erro médio quadrático. Isto é feito modificando os pesos na direção oposta ao gradiente da função de erro de acordo com a seguinte expressão:

$$w^{k+1} = w^k + \alpha(-\nabla) \quad (\text{A.8})$$

Considere uma rede multicamada de estrutura n - N - m , que no caso específico da figura A.9 é formada por três entradas ($n = 3$), três neurônios escondidos ($N = 3$) e dois nós de saída ($m = 2$), onde x_i representa as entradas, d_l as saídas desejadas, h_j as saídas dos neurônios da camada escondida e y_l as saídas próprias da rede. A camada intermediária da rede é formada por neurônios com funções de ativação ($\sigma(\cdot)$) continuamente diferenciáveis como as apresentadas nas equações A.6 ou A.7. Os restantes têm funções do tipo linear (eq. A.4).

O erro de cada neurônio de saída da rede neural está definido por:

$$e_l = d_l - y_l, \quad l = 1, \dots, m \quad (\text{A.9})$$

com




Figura A.9: Rede neural 3-3-2.

A função a partir da qual é calculado o gradiente é o erro quadrático expresso por:

$$e^2 = \sum_{l=1}^m (d_l - y_l)^2 \quad (\text{A.10})$$

Levando em consideração que foi definida uma função de ativação linear para a camada de saída, têm-se:

$$\begin{aligned} y_1 &= c_{11}h_1 + c_{12}h_2 + c_{13}h_3 \\ y_2 &= c_{21}h_1 + c_{22}h_2 + c_{23}h_3 \end{aligned}$$

Calculando o gradiente da função de erro quadrático com relação aos parâmetros c_{jl} da camada de saída, tem-se:

$$\frac{\partial e^2}{\partial c_{jl}} = -2e_l h_j \quad (\text{A.11})$$

Portanto, a regra para atualizar os pesos da camada de saída é:

$$c_{jl}^{k+1} = c_{jl}^k + 2\alpha e_l h_j \quad (\text{A.12})$$

onde, $j = 1, \dots, N$ e $l = 1, \dots, m$

A saída dos neurônios escondidos está dada por:

$$\begin{aligned} h_1 &= \sigma(s_1) = \sigma(w_{11}x_1 + w_{12}x_2 + w_{13}x_3 + w_{10}) \\ h_2 &= \sigma(s_2) = \sigma(w_{21}x_1 + w_{22}x_2 + w_{23}x_3 + w_{20}) \\ h_3 &= \sigma(s_3) = \sigma(w_{31}x_1 + w_{32}x_2 + w_{33}x_3 + w_{30}) \end{aligned} \quad (\text{A.13})$$

Calculando novamente o gradiente do erro em função dos pesos da camada escondida obtém-se:

$$\frac{\partial e^2}{\partial w_{ij}} = -2\delta_j \sigma'(s_j) x_i \quad (\text{A.14})$$

sendo σ' a derivada da função de ativação dos neurônios intermediários e δ_j representação do erro dado por:

$$\delta_j = \sum_{n=1}^l c_{jn} e_n = \sum_{n=1}^l c_{jn} (d_n - y_n) \quad j = 1, \dots, N \quad (\text{A.15})$$

Então a regra para atualizar os pesos de entrada é:

$$w_{ij}^{k+1} = w_{ij}^k + 2\alpha \delta_j \sigma'(s_j) x_i \quad (\text{A.16})$$

para, $j = 1, \dots, N$ e $i = 0, \dots, n$.

Note que na equação A.12 os pesos (c_{jl}) são atualizados usando o valor do erro da resposta da RNA e na A.16 os pesos da camada escondida são modificados usando os erros δ_j , que são os erros da rede ponderados.

Este algoritmo apresentado pode-se resumir em dois passos básicos:

- Propagação positiva do sinal funcional: durante este processo todos os pesos da rede são mantidos fixos.

- Retropropagação do erro: durante este processo os pesos da rede são ajustados baseado no erro.

O algoritmo deriva seu nome da forma como os erros são propagados para atualizar os pesos, pois esta atualização ocorre em sentido oposto à forma em que os sinais são processados pela *RNA*.

No algoritmo, α representa a taxa de aprendizagem, que geralmente é mantida fixa. A escolha do passo α é fundamental, pois para valores muito baixos o tempo de treinamento pode-se tornar exageradamente alto, e para valores muito altos pode chegar a divergir. A velocidade de convergência é normalmente melhorada adicionando um termo de momento (μ), da seguinte forma:

$$w^{k+1} = w^k + \alpha(-\nabla) + \mu\Delta w^{k-1} \quad (\text{A.17})$$

Este termo adicional, geralmente evita oscilações no comportamento do erro, pois pode ser interpretado como a inclusão de uma informação de segunda ordem.

A.5.1.2 Algoritmos de treinamento baseados em técnicas de otimização [57]

Embora, o algoritmo de retro-propagação tenha provado sua utilidade no treinamento supervisionado de redes multicamadas para diversos problemas de classificação de padrões e mapeamento estático de funções não-lineares, há casos em que a velocidade de aprendizagem é um fator limitante na implementação prática deste tipo de ferramenta na solução de problemas que requerem otimalidade, robustez e rapidez na convergência do processo de ajuste dos parâmetros. Mesmo em aplicações onde o tempo computacional não é a prioridade, a complexidade temporal do algoritmo pode resultar na intratabilidade computacional.

O treinamento de *RNA*'s com várias camadas pode ser entendido como um caso especial de aproximação de funções, onde não é levado em consideração nenhum modelo explícito dos dados. Por este motivo, o problema de treinamento é equivalente a um problema de otimização não-linear irrestrito, onde a função de erro global é minimizada a partir dos parâmetros da rede (pesos).

Esta perspectiva de treinamento permite desenvolver algoritmos baseados em resultados bem fundamentados da teoria de análise numérica convencional. Dentre as aplicações mais comuns encontram-se métodos que utilizam somente o gradiente local da função de erro ou então aqueles que incluem as informações dos termos de segunda ordem. No primeiro caso, a função é aproximada pelo primeiro (constante) e segundo (linear) termos da expansão de Taylor; no segundo caso, o terceiro termo (quadrático) também é considerado. É precisamente esse último tipo de algoritmo que atualmente se considera como o mais eficiente para

treinar *RNA*'s multicamada.

Alguns destes métodos, ao mesmo tempo em que requerem poucas modificações no algoritmo de retro-propagação, resultam em elevados graus de aceleração além de não requerem a escolha de parâmetros críticos para a convergência como a taxa de aprendizagem ou coeficiente de momento.

Os métodos descritos a seguir, com exceção dos métodos de gradiente conjugado escalonado, utilizam um procedimento de busca unidimensional para encontrar um α que seja a solução ótima do problema:

$$\min_{\alpha_i \in (0,1]} e(w^i + \alpha \mathbf{d}^i) \quad (\text{A.18})$$

onde e representa a função do erro e $\mathbf{d}^i$ representa a direção de minimização.

A seguir são apresentadas as características básicas dos métodos de segunda ordem mais comuns para treinamento de redes multicamada.

- *Método de Newton Modificado*: Pode ser considerado como o método local básico que utiliza informações de segunda ordem. É pouco recomendado para aplicações práticas uma vez que o cálculo da matriz Hessiana representa um elevado custo computacional, pois exige a inversão, análise espectral e armazenagem de uma matriz quadrada da ordem do número dos parâmetros a serem ajustados.
- *Método Levenberg-Marquardt*: Este método faz uma aproximação da matriz Hessiana, o que o torna bastante eficiente quando se trata de redes que não possuem mais do que algumas centenas de conexões a serem ajustadas. Isto se deve principalmente ao fato que estes algoritmos necessitam armazenar uma matriz quadrada cuja dimensão é da ordem do número de conexões da rede.
- *Método de Davidon-Fletcher-Powell*: Classificado como método quase-Newton, onde a idéia básica é fazer uma aproximação iterativa da inversa da matriz Hessiana, o que é feito de forma simples pela soma de duas matrizes simétricas. Para problemas quadráticos, gera as direções ao mesmo tempo em que constrói a inversa da Hessiana.
- *Secantes de um passo*: Neste método as derivadas são aproximadas por secantes avaliadas em dois pontos da função. Uma vantagem deste método é que sua complexidade é linear em função ao número de parâmetros, enquanto outros métodos têm uma relação quadrática.
- *Gradiente Conjugado, Polak-Ribière e Fletcher-Reeves*: Métodos do gradiente conjugado tratam problemas de grande escala de maneira efetiva. Estes métodos baseiam-se no algoritmo padrão do gradiente, mas escolhe a direção de busca $\mathbf{d}^i$, o passo α e o coeficiente de momento μ eficientemente usando informações de segunda ordem, baseado no método das direções conjugadas proposto para tratar problemas quadráticos.

- *Gradiente Conjugado Escalonado*: Este método evita a busca unidimensional a cada iteração utilizando uma abordagem Levenberg-Marquardt cujo objetivo é fazer o escalonamento do passo de ajuste α . Já que não realiza a busca unidimensional que envolve um grande número de avaliações da função e de sua derivada, torna o processo mais eficiente do ponto de vista computacional.
- *Gradiente Conjugado Escalonado Modificado*: Permite o cálculo exato da informação de segunda ordem, através de um operador diferencial capaz de calcular exatamente o produto entre a matriz e qualquer outro vetor, sem a necessidade de armazenar e calcular a matriz Hessiana. No caso de redes multicamada o vetor corresponde à direção de busca na iteração anterior.

A.5.2 Aproximação de funções

Foi demonstrado matematicamente [53] que uma rede neural é capaz de aproximar uma função não-linear através do mapeamento entrada-saída. Este teorema só prova que a rede existe, mas não indica a estrutura nem como construí-la. Este teorema estabelece o seguinte:

Dada uma função $\varphi(\cdot)$ contínua, não constante, limitada e crescente monotonicamente. Seja K um subconjunto compacto (limitado e fechado) de $\mathbb{R}^n$, e $f(x_1, x_2, \dots, x_n)$ uma função real contida em K . Existe para $\varepsilon > 0$, um inteiro N e um conjunto de constantes reais α_i, b_i e w_{ij} , onde $i = 1, \dots, N$ e $j = 1, \dots, n$, tal que:

$$F(x_1, x_2, \dots, x_n) = \sum_{i=1}^N \alpha_i \varphi \left(\sum_{j=1}^n w_{ij} x_j + b_i \right) \quad (\text{A.19})$$

que satisfaz:

$$|F(x_1, x_2, \dots, x_n) - f(x_1, x_2, \dots, x_n)| < \varepsilon \quad (\text{A.20})$$

para todo x que pertence a K .

Em outras palavras isto quer dizer que existe uma rede neural multicamada com estrutura n-N-1 que consegue aproximar qualquer função não-linear.

A.5.3 Processamento de dados

Com o fim de melhorar o processo de aprendizagem das *RNA's*, é conveniente realizar um pré-processamento dos dados fazendo que a média estatística do conjunto de dados seja próxima a zero ou pelo menos pequena quando comparada com o desvio padrão [54]. Além disso, é recomendável levar em consideração na etapa de pré-processamento outras condições que melhoram o aprendizado em redes multicamada [54]:

- As variáveis de entrada do conjunto de treinamento não devem ser correlacionadas.

- As variáveis de entrada não-correlacionadas escalonadas de tal forma que as suas covariâncias sejam aproximadamente iguais, assegurando desse modo que os pesos sinápticos da rede aprendam aproximadamente à mesma velocidade.

No capítulo 3 é tratada uma técnica que permite realizar as tarefas anteriormente mencionadas, além de extrair as principais características do conjunto de dados, chamada *Principal Component Analysis (PCA)* a qual é aplicada neste trabalho. A figura A.10 ilustra o pré-processamento a ser realizado com os dados de entrada da rede neural.




Figura A.10: Pré-processamento de dados.

As funções como a sigmóide ou tangente hiperbólica usadas freqüentemente nas *RNA's* multicamada, apresentam saturação, ou seja, para valores muito grandes de seu argumento elas operarão na região saturada da curva. Portanto é conveniente fazer com que os valores dos atributos dos dados de entrada estejam limitados a um intervalo pré-definido, por exemplo $[0,1]$ ou $[-1,1]$. Isto é feito usando expressões como as apresentadas em A.21 e A.22. Nelas p_n corresponde ao vetor de entrada normalizado, μ representa a média do vetor de dados de entrada original (p) e σ seu desvio padrão.

$$p_n = \frac{(p - \mu(p))}{\sigma(p)} \quad (\text{A.21})$$

$$p_n = 2 * \frac{(p - \min(p))}{(\max(p) - \min(p))} - 1 \quad (\text{A.22})$$

A equação A.21 é geralmente preferida, pois inclui as considerações feitas por LeCun em [54] as quais foram enunciadas acima, enquanto a expressão A.22 só limita as variáveis de entrada num intervalo pequeno.

Apêndice B

Divulgação da pesquisa

Jiménez A.C.; Castro C.A.; Voltage satability security margin assessment via artificial neural networks, *IEEE Power Engineering Society, PowerTech Conference 2005*, St. Petersburg, Rusia, 2005.