



APLICAÇÃO DE INTELIGÊNCIA COMPUTACIONAL PARA AUXÍLIO À
RECOMPOSIÇÃO DE SISTEMAS ELÉTRICOS DE POTÊNCIA

Cassia Maria Souza Chaves

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Elétrica.

Orientador(es): Djalma Mosqueira Falcão

Alexandre Alves Pinto da Silva

Rio de Janeiro

Setembro de 2008

APLICAÇÃO DE INTELIGÊNCIA COMPUTACIONAL PARA AUXÍLIO À
RECOMPOSIÇÃO DE SISTEMAS ELÉTRICOS DE POTÊNCIA

Cassia Maria Souza Chaves

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ
COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA DA
UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS
NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR EM CIÊNCIAS EM
ENGENHARIA ELÉTRICA.

Aprovada por:

Prof. Djalma Mosqueira Falcão, Ph.D.

Prof. Alexandre Pinto Alves da Silva, Ph.D.

Prof. Antonio Carlos Siqueira de Lima, D.Sc.

Prof. Glauco Nery Taranto, Ph.D.

Prof. Arturo Suman Bretas, Ph.D.

Prof. Benemar Alencar de Souza, D.Sc.

RIO DE JANEIRO, RJ – BRASIL

SETEMBRO DE 2008

Chaves , Cassia Maria Souza

Aplicação de Inteligência Computacional para Auxílio à
Recomposição de Sistemas Elétricos de Potência/ Cassia
Maria Souza Chaves. -Rio de Janeiro: UFRJ/COPPE, 2008.

XVI, 167 p.: il.;29,7 cm.

Orientadores: Djalma Mosqueira Falcão

Alexandre Pinto Alves da Silva

Tese (doutorado) – UFRJ/ COPPE/ Programa de
Engenharia Elétrica, 2008.

Referências Bibliográficas: p. 162-167

1.Recomposição. 2. Redes Neurais. I.Falcão, Djalma
Mosqueira et al. II. Universidade Federal do Rio de
Janeiro, COPPE, Programa de Engenharia Elétrica.
III.Título

Aos meus pais
Geraldo e
Dalcilia

Ao meu esposo
Aloisio

Aos meus filhos
Rafael e
Lívia

Ao meu irmão
Geraldo

AGRADECIMENTOS

Aos meus pais, esposo e filhos pela compreensão, apoio, carinho e principalmente pelo estímulo para a finalização deste trabalho.

Aos Professores Djalma Mosqueira Falcão e Alexandre Pinto Alves da Silva pela orientação segura e apoio durante toda a realização do trabalho.

À FURNAS onde tive o privilégio de passar grande parte da minha vida profissional e conviver com tantos amigos.

Aos meus amigos Alexandre e Arthur que muito me ajudaram nos momentos em que os obstáculos pareciam intransponíveis.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

APLICAÇÃO DE INTELIGÊNCIA COMPUTACIONAL PARA AUXÍLIO À
RECOMPOSIÇÃO DE SISTEMAS ELÉTRICOS DE POTÊNCIA

Cassia Maria Souza Chaves

Setembro / 2008

Orientadores: Djalma Mosqueira Falcão

Alexandre Pinto Alves da Silva

Programa: Engenharia Elétrica

Este trabalho descreve uma metodologia para construção de uma ferramenta para avaliação rápida da viabilidade de energização de linhas de transmissão que incorpora os resultados de estudos de fluxo de potência e transitórios eletromagnéticos. A classificação da energização é feita por uma rede neural treinada e regras são extraídas por uma árvore de decisão para explicar a classificação. O sistema híbrido pode ser utilizado para apoiar a decisão em tempo real ou validar caminhos de restabelecimento do sistema.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

APPLYING ARTIFICIAL INTELLIGENCE TO HELP
ELECTRIC POWER SYSTEM RESTORATION

Cassia Maria Souza Chaves

September / 2008

Advisor : Djalma Mosqueira Falcão

Alexandre Pinto Alves da Silva

Department : Engenharia Elétrica

This work describes a methodology to create a tool for fast evaluation of transmission lines energization viability that incorporate power flow and electromagnetic transients studies results. The classification of the energization is made by a trained neural network and rules are extracted by a decision tree to explain the classification. The hybrid system can be used to support the decision in real time or to validate paths of restoration system.

ÍNDICE

Capítulo I Introdução.....	1
I.1 Considerações Iniciais.....	1
I.2 Definição e Justificativas do Problema.....	2
I.3 Principais Objetivos do Trabalho.....	4
I.4 Principais Contribuições do Trabalho.....	5
I.5 Organização do Trabalho.....	6
I.6 Sumário do Capítulo.....	8
Capítulo II Restabelecimento de Sistema de Potência.....	9
II 1 Considerações Iniciais.....	9
II.2 Introdução.....	9
II.3 Visão geral do processo de Restabelecimento de Sistema de Potência.....	10
II.4 Filosofias de Restabelecimento.....	11
II.5 Estratégias de Chaveamento.....	12
II.6 Estudos de energização.....	14
II.7 O Restabelecimento do Sistema Elétrico Brasileiro.....	16
II.8 Sobretensões Resultantes da Energização de uma Linha de Transmissão.....	20
II.8.1 Introdução.....	20
II.8.2 Análise de Regime Permanente.....	21
II.8.3 Análise Transitória de Manobra.....	24
II.9 Técnicas de Inteligência Computacional no Restabelecimento do Sistema Elétrico.....	28
II.10 Sumário do Capítulo.....	31

CAPÍTULO III Sistema Híbrido para Restabelecimento de Sistema de Potência	32
III.1 Considerações Iniciais.....	32
III.2 Formulação do problema.....	32
III.3 A Metodologia Proposta para Solução do Problema.....	33
III.4 Arquitetura Proposta.....	34
III.5 Etapas de desenvolvimento do projeto.....	37
III.6 A Metodologia Proposta para Solução do Problema.....	39
III.7 Arquitetura Proposta.....	40
III.8 Etapas de desenvolvimento do projeto	41
III.8.1 Estudos de regime permanente e transitórios eletromagnéticos.....	41
III.8.2 Seleção de variáveis de entrada para a rede neural.....	46
III.8.3 Projeto da rede neural classificadora.....	47
III.8.4 Extração de regras utilizando árvore de decisão.....	50
III.9 Sumário do Capítulo.....	52
CAPÍTULO IV Resultados Obtidos.....	53
IV.1 Considerações Iniciais.....	53
IV.2 Sistema Teste 1.....	53
IV.3 Sistema Teste 2.....	69
IV.4 SistemaTronco.....	84
IV.5 Análise dos Resultados.....	99
IV.6 Simulador.....	100
IV.7 Sumário do Capítulo.....	103
CAPÍTULO V Conclusões.....	104
V.1 Considerações Iniciais.....	104

V.2 Desenvolvimentos Futuros.....	106
APÊNDICE A Transitórios Eletromagnéticos.....	108
A.1 Considerações Iniciais.....	108
A.2 Sistema Teste 1.....	108
A.2.1 Energização da LT Usina A - Usina B com 2 máquinas na Usina A.....	108
A.2.2 Energização da LT Usina B- Usina C com 1 máquina na Usina A e 1 máquina na Usina B.....	109
A.2.3 Energização da LT Usina B- Usina C com 1 máquina na Usina A e 2 máquina na Usina B.....	110
A.3 Sistema Teste 2.....	111
A.3.1 Energização da LT Usina A - Usina B com 2 máquinas na Usina A.....	111
A.3.2 Energização da LT Usina B – SE1 com 2 máquinas na Usina A.....	112
A.3.3 Energização da LT Usina A- SE2 com 2 máquinas na Usina A.....	114
A.3.4 Energização da LT SE2-SE1 com 2 máquinas na Usina A.....	115
A.3.5 Energização da LT Usina B – SE2 com 2 máquinas na Usina A.....	117
A.3.6 Energização da LT SE2 – SE1 com 2 máquinas na Usina A.....	118
A.3.7 Energização da LT UsinaB–SE1 com 2 máquinas na Usina A e 1 na UsinaB..	120
A.3.8 Energização da LT Usina B-SE2 com 2 maq na Usina A e 1 maq na UsinaB..	122
A.3.9 Energização da LT SE2-SE1 com 2 máquinas na Usina A e 1 na Usina B.....	124
A.4 Sistema Tronco.....	125
A.4.1 Energização da primeira LT AD-MH.....	125
A.4.2 Energização da segunda LT AD-MH sem reator em VT.....	126
A.4.3 Energização da segunda LT AD-MH com reator em VT.....	127
APÊNDICE B Redes Neurais.....	129
B.1 Considerações Iniciais.....	129

B.2	Introdução.....	129
B.3	Processo de Aprendizagem.....	134
B.4	Algoritmo Backpropagation.....	138
APÊNDICE C Classificadores.....		139
.C1	Considerações Iniciais.....	139
C.2	Introdução.....	139
C.3	Classificador Bayesiano.....	140
C.4	Árvores de Decisão.....	142
C.5	Redes Neurais.....	146
C.5.1	Perceptron.....	146
C.5.1	Redes Neurais. MLP.....	149
C.7	Sumário do Capítulo.....	152
APÊNDICE D Extração de Regras e Sistemas Híbridos Inteligentes.....		153
D.1	Considerações Iniciais.....	153
D.2	Extração de Regras de Redes Neurais.....	153
D.3	Sistemas Híbridos Inteligentes.....	156
D.4	Sumário do Capítulo.....	158
APÊNDICE E Dados do Sistema Elétrico.....		159
D.1	Considerações Iniciais.....	159
D.2	Dados de Linhas de Transmissão.....	159
D.1	Dados de Transformadores.....	160
D.2	Dados das Usinas.....	161
REFERÊNCIAS BIBLIOGRÁFICAS.....		156

LISTA DE FIGURAS

Figura 1 – Energização da linha SE A – SE B.....	21
Figura 2 – Quadripolo.....	21
Figura 3 – Sobretensões de manobra típica.....	25
Figura 4 – Sobretensões de impulso atmosférico típica.....	25
Figura 5 – Manobra típica de energização.....	27
Figura 6 – Abordagem do Problema	34
Figura 7 – Representação gráfica dos dados de entrada.....	37
Figura 8 – Arquitetura do Sistema Híbrido.....	41
Figura 9 – Tensão máxima no extremo da linha.....	43
Figura 10 – Diagrama de blocos da primeira etapa de projeto.....	45
Figura 11 – Arquitetura da rede neural.....	48
Figura 12 – Diagrama de blocos das etapas finais.....	51
Figura 13 – Configuração do sistema teste 1.....	53
Figura 14 – Tensão máxima de pré-energização.....	54
Figura 15 – Arquitetura da rede neural proposta para a LT UsinaB-UsinaC.....	60
Figura 16 – Rede neural MLP.....	62
Figura 17 – Árvore de decisão extraída do banco de dados para classificação da energização da linha que interliga a Usina A a Usina B.....	65
Figura 18 – Configuração do sistema teste 2.....	69
Figura 19 – Arquitetura da rede neural proposta LT UsinaA-UsinaB.....	78
Figura 20 – Árvore de decisão extraída do banco de dados para classificação da energização da linha que interliga a Usina A a Usina B.....	81
Figura 21 – Tronco do Sistema de Transmissão.....	84
Figura 22 – Configuração do Sistema.....	88
Figura 23 – Arquitetura da rede neural proposta LT AD-MH.....	92
Figura 24 – Árvore de decisão extraída do banco de dados para classificação da energização da linha AD-MH.....	94

Figura 25 – Diagrama de blocos do Simulador.....	101
Figura 26 – Energização da LT UsinaA – Usina B – Tensão no extremo da linha....	108
Figura 27 – Energização da LT UsinaB – UsinaC com 1 máquina na Usina A e 1 máquina na Usina B.....	109
Figura 28 – Energização da LT UsinaB – UsinaC com 2 máquinas na Usina B – Tensão no extremo da linha.....	110
Figura 29 – Energização da LT Usina A - Usina B com 2 máquinas na Usina A – Tensão no gerador Usina A.....	111
Figura 30 – Energização da LT Usina A - Usina B com 2 máquinas na Usina A – Tensão na Usina A.....	111
Figura 31 – Energização da LT Usina A - Usina B com 2 máquinas na Usina A – Tensão no extremo da LT.....	112
Figura 32 – Energização da LT Usina B – SE1 com 2 máquinas na Usina A – Tensão no extremo da LT.....	112
Figura 33 – Energização da LT Usina B – SE1 com 2 máquinas na Usina A – Tensão na Usina B.....	112
Figura 34 – Energização da LT Usina B – SE1 com 2 máquinas na Usina A – Tensão no extremo da LT.....	113
Figura 35 – Energização da LT Usina B – SE2 com 2 máquinas na Usina A – Tensão de geração Usina A.....	114
Figura 36 – Energização da LT Usina B – SE2 com 2 máquinas na Usina A – Tensão na Usina B.....	114
Figura 37 – Energização da LT Usina A- SE2 com 2 máquinas na Usina A – Tensão no extremo da LT.....	115
Figura 38 – Energização da LT SE2-SE1 com 2 máquinas na Usina A – Tensão no gerador da Usina A.....	115

Figura 39 – Energização da LT SE2-SE1 com 2 máquinas na Usina A – Tensão na SE2.....	116
Figura 40 – Energização da LT SE2-SE1 com 2 máquinas na Usina A – Tensão no extremo da LT.....	116
Figura 41 – Energização da LT Usina B – SE2 com 2 máquinas na Usina A – Tensão no gerador da Usina A.....	117
Figura 42 – Energização da LT Usina B – SE2 com 2 máquinas na Usina A – Tensão na Usina B.....	117
Figura 43 – Energização da LT Usina B – SE2 com 2 máquinas na Usina A- Tensão no extremo da LT.....	118
Figura 44 – Energização da LT SE2 – SE1 com 2 máquinas na Usina A – Tensão de geração.....	119
Figura 45 – Energização da LT SE2 – SE1 com 2 máquinas na Usina A – Tensão na SE2.....	119
Figura 46 – Energização da LT SE2 – SE1 com 2 máquinas na Usina A – Tensão no extremo da LT.....	120
Figura 47 – Energização da LT UsinaB – SE1 com 2 máquinas na Usina A e 1 na UsinaB – Tensão no gerador.....	121
Figura 48– Energização da LT UsinaB – SE1 com 2 máquinas na Usina A e 1 na UsinaB – Tensão na Usina B.....	121
Figura 49 – Energização da LT UsinaB – SE1 com 2 máquinas na Usina A e 1 na UsinaB – Tensão no extremo da LT.....	122

Figura 50 – Energização da LT Usina B-SE2 com 2 maq na Usina A e 1 maq na Usina B – Tensão no gerador.....	122
Figura 51 – Energização da LT Usina B-SE2 com 2 maq na Usina A e 1 maq na Usina B – Tensão na Usina B.....	123
Figura 52 – Energização da LT Usina B-SE2 com 2 maq na Usina A e 1 maq na Usina B – Tensão no extremo da LT.....	123
Figura 53 – Energização da LT SE2-SE1 com 2 máquinas na Usina A e 1 na Usina B – Tensão de geração.....	124
Figura 54 – Energização da LT SE2-SE1 com 2 máquinas na Usina A e 1 na Usina B – Tensão na SE2.....	124
Figura 55 – Energização da LT SE2-SE1 com 2 máquinas na Usina A e 1 na Usina B – Tensão no extremo da LT.....	125
Figura 56 – Energização da primeira LT - Tensão no extremo da LT.....	126
Figura 57 – Energização da segunda LT - Tensão no extremo da LT.....	127
Figura 58 – Energização da segunda LT - Tensão no extremo da LT.....	128
Figura 59 – Neurônio Artificial.....	130
Figura 60 – Estrutura de uma Rede Neural.....	132
Figura 61 – Exemplo de árvore de decisão.....	145
Figura 62 – Perceptron.....	147.
Figura 63 – Fronteira de decisão.....	147
Figura 64 – Representação gráfica dos dados de entrada.....	148
Figura 65 – Abordagem clássica para classificação de padrões.....	150

LISTA DE TABELAS

Tabela 1 – Níveis de tensão aceitáveis em regime permanente para estudos de recomposição das regiões Sul, Sudeste e Centro-Oeste.....	42
Tabela 2 – Resultados dos estudos de regime permanente para as energizações de linhas de transmissão no sistema teste 1.....	55
Tabela 3 – Erro de classificação da rede neural UsB – UsC.....	63
Tabela 4 – Configuração de máquinas nas Usinas A e B consideradas.....	63
Tabela 5 – Resultados dos estudos de regime permanente para as energizações de linhas de transmissão no sistema teste 2	70
Tabela 6 – Erro de classificação da rede neural UsinaA-UsinaB.....	80
Tabela 7 – Resultados dos estudos de regime permanente para as energizações de linhas de transmissão no sistema tronco.....	85
Tabela 8 – Erro de classificação da rede neural da Linha AD-MH.....	93
Tabela 9 – Dados de linhas de transmissão.....	159
Tabela 10 – Dados de transformadores.....	160
Tabela 11 – Dados de usinas.....	161

CAPÍTULO I

INTRODUÇÃO

I.1 Considerações Iniciais

Interrupções de suprimento do fornecimento de energia aos consumidores são inevitáveis e podem causar sérios prejuízos econômicos e sociais. Fenômenos atmosféricos, desgaste de equipamentos, falhas humanas e diversas outras causas fazem com que perturbações no sistema elétrico ocorram. Embora o sistema elétrico esteja dimensionado para suportar contingências simples, fatores imprevistos tais como algumas contingências múltiplas e operações indevidas de proteção podem vir a ocasionar até mesmo seu desligamento total. A manutenção preventiva adequada, a implantação de esquemas de emergência para contingências simples e múltiplas e diversas outras providências têm sido empregadas para diminuir o número e abrangência destas interrupções.

Embora a probabilidade de que blecautes generalizados ocorram seja reduzida, eles têm acontecido algumas vezes, seja no Sistema Interligado Brasileiro ou em outros países, trazendo graves conseqüências à sociedade, hoje em dia tão dependente da eletricidade. Todas as empresas de energia elétrica correm este risco, por mais bem planejado, construído e operado que seja o seu sistema elétrico [1]. Uma vez que não se pode impedir que as perturbações ocorram, esforços têm sido feitos para diminuir o tempo em que os consumidores ficam sem suprimento de energia minimizando os seus efeitos.

Além disso, é crescente a demanda pela melhoria da qualidade dos serviços de energia elétrica, com os consumidores exigindo cada vez mais um melhor

atendimento. No Brasil, o desempenho das concessionárias quanto à continuidade do serviço prestado de energia elétrica é medido pela Agência Nacional de Energia Elétrica - ANEEL com base em indicadores específicos tais como os denominados de DEC e FEC. O DEC (Duração Equivalente de Interrupção por Unidade Consumidora) indica o número de horas em média que um consumidor fica sem energia elétrica durante um período, geralmente mensal. Já o FEC (Frequência Equivalente de Interrupção por Unidade Consumidora) indica quantas vezes, em média, houve interrupção na unidade consumidora (residência, comércio, indústria etc).

Quando ocorrem perturbações no sistema elétrico os operadores têm que fazer um diagnóstico rápido da situação e tomar providências para restabelecer este sistema com rapidez e precisão. O fato destes operadores se defrontarem cada vez menos com situações de perda total do sistema torna a tarefa de restabelecimento após distúrbio ainda mais difícil e estressante. Atualmente, com o intuito de orientar os operadores após o blecaute a maioria das empresas de eletricidade tem procedimentos pré-estabelecidos e diretrizes para restabelecimento do sistema de potência. Estas diretrizes se baseiam em alguns cenários e contemplam os passos a serem seguidos pelos operadores do sistema elétrico, para recompor o sistema após perturbações. No Brasil, o Operador Nacional do Sistema - ONS elabora os planos de recomposição e define Instruções de Operação que descrevem as ações e restrições para a reenergização das diversas áreas geo-elétricas do sistema elétrico, de acordo com alguns cenários estudados na fase de planejamento.

I.2 Definição do Problema

O restabelecimento de sistemas elétricos é uma tarefa bastante complexa envolvendo desde o entendimento da severidade e extensão do distúrbio até o restabelecimento

total das cargas e retorno do sistema à condição normal. Processamento de alarmes, escolha de caminhos de restabelecimento, análise da viabilidade de energização, execução de manobras, controle de tensão e carregamento, tomada de carga e fechamento de anéis e paralelos são alguns dos principais aspectos envolvidos. A complexidade do problema torna difícil o desenvolvimento de uma solução única que abranja todos os diversos aspectos por ele envolvidos.

Os procedimentos e diretrizes pré-estabelecidas para Restabelecimento do Sistema de Potência se baseiam em alguns cenários, contemplando os passos a serem seguidos pelos Operadores do Sistema Elétrico para recompor o sistema após perturbações. Entretanto o stress a que os Operadores ficam submetidos associado a fatos imprevistos podem retardar ou mesmo impedir o restabelecimento completo deste sistema [2].

As técnicas tradicionalmente utilizadas para definição dos planos de recomposição envolvem estudos de regime permanente e transitórios eletromagnéticos que são realizados previamente na fase de planejamento da operação (pré-operação). A complexidade na modelagem dos componentes da rede e análise de resultados, além do tempo necessário para simulação inviabiliza a sua execução em tempo real, em especial no que se refere aos estudos de transitórios eletromagnéticos.

É importante lembrar que ações inadequadas tomadas pelos operadores para a energização de equipamentos durante o restabelecimento podem causar novos desligamentos no sistema, ocasionar sobretensões que podem provocar operações de proteção ou até mesmo causar sérios danos aos equipamentos. Um desafio consiste no desenvolvimento de técnicas para treinamento e apoio aos operadores no processo de restabelecimento do sistema que facilitem a tomada de decisão, o trabalho de consulta e implementação das ações e limites durante o restabelecimento do sistema.

I.3 Principais Objetivos do Trabalho

O objetivo do trabalho é contribuir para o desenvolvimento de uma ferramenta que possa ser utilizada para apoio a decisão dos operadores, durante o Restabelecimento do Sistema na fase de tempo real, e que seja capaz de indicar se um determinado elemento do sistema elétrico pode ou não ser energizado sem violação dos valores admissíveis de sobretensão transitórias e sustentadas. Neste trabalho o problema é abordado como um problema de classificação com duas classes possíveis: energização viável ou não.

A rapidez de resposta é uma característica imprescindível a ferramentas de apoio a decisão em tempo real. As simulações tradicionais necessárias a análise da energização de circuitos, em especial os estudos de transitórios eletromagnéticos, necessitam de uma representação trifásica detalhada do sistema cuja topologia depende do tipo da perturbação que ocorreu (parcial ou total), das conexões entre seus componentes e de estudos estatísticos da energização preliminares, para representação de diferentes instantes de fechamento de disjuntor. São estudos exaustivos e complexos que demandam bastante tempo o que impede a sua formulação e execução em tempo real. Deveria ser encontrada uma alternativa rápida, mas que levasse em consideração todos estes aspectos envolvidos de forma a evitar ações inadequadas que pudessem ocasionar problemas ao restabelecimento.

Além disso, a análise dos resultados das simulações tradicionais necessárias a avaliação da energização de circuitos, em especial dos estudos de transitórios eletromagnéticos, necessitam ser executadas por um especialista que necessariamente pode não estar disponível prontamente. Portanto a ferramenta de apoio a decisão deve ser o mais simples possível de forma a poder ser facilmente utilizada.

Outra preocupação foi a de comparar os resultados obtidos com os métodos atualmente utilizados. Daí surgiu a necessidade de se extrair regras dos exemplos utilizados para treinamento da rede neural utilizada para classificação da energização que pudessem ser comparadas com as Instruções de Operação atualmente empregadas. A extração de regras também contribuiu para uma melhor aceitação por parte do usuário, em especial nestes tipos de aplicações onde a segurança é fator primordial.

Para se atingir estes objetivos foi necessário associar duas técnicas de Inteligência Computacional. O sistema híbrido proposto é constituído de um módulo neural (rede neural MLP) associado a um módulo simbólico (árvore de decisão). A associação destas duas técnicas permite utilizar a capacidade de interpretação e classificação de padrões complexos com rapidez das redes neurais e possibilita a explicação do processo que levou a uma determinada resposta através de extração de regras dos dados utilizados no treinamento utilizando árvore de decisão.

I.4 Principais Contribuições do Trabalho

Os diversos trabalhos publicados apontam para a necessidade de programas de apoio ao restabelecimento de sistemas especialmente nas fases de tempo real e para treinamento de operadores. Em sua grande maioria estes trabalhos propõem a utilização de sistemas especialistas, onde se procura embutir nas regras de produção alguma experiência do pessoal de operação neste processo.

Os trabalhos que se concentram na busca de melhores rotas de restabelecimento de sistemas normalmente validam estes caminhos através de estudos de fluxo de potência.

Existem apenas alguns trabalhos com aplicações de redes neurais em restabelecimento de sistemas nas seguintes áreas:

- estimar a carga após o distúrbio [2, 3]
- escolher caminhos de restabelecimento [2, 3]
- estimar o valor da sobretensão transitória máxima [4]

Neste trabalho se propõe a utilização de redes neurais para classificar rapidamente a energização de linhas de transmissão, considerando não somente resultados de estudos de fluxo de potência como também de transitórios eletromagnéticos, possibilitando a sua futura utilização em tempo real para validar caminhos de restabelecimento. Desta forma pretende-se eliminar o obstáculo da complexidade e tempo de execução dos estudos de transitórios eletromagnéticos necessários para classificar a energização. Além disso, propõe a utilização de uma árvore de decisão como forma de extrair regras compreensíveis para o usuário de como a classificação foi efetuada. Estas regras se assemelham as atuais diretrizes contidas nas Instruções de Operação, proporcionando maior transparência ao processo para melhor aceitação pelo usuário e confiança no resultado obtido.

Embora não resolva todos os aspectos relacionados ao complexo processo de Restabelecimento do Sistema Elétrico, o sistema híbrido proposto poderá ser utilizado como uma ferramenta de apoio à decisão a este processo, contribuindo para a escolha de caminhos de restabelecimento. Na fase de planejamento da operação possibilita extrair regras dos resultados de estudos de regime permanente e transitórios eletromagnéticos para servir de base para confecção de Instruções de Operação.

I.5 Organização do Trabalho

O presente trabalho está estruturado em 5 capítulos, referências bibliográficas e anexos .

No Capítulo II é feita uma revisão bibliográfica do restabelecimento de Sistemas Elétricos de Potência, nos métodos convencionais atualmente utilizados e em algumas técnicas que têm sido propostas para auxiliar nesta tarefa. Apresenta também um resumo dos critérios e diretrizes adotadas no Sistema Elétrico Brasileiro.

O Capítulo III além de formular o problema apresenta a metodologia utilizada para construção da ferramenta de apoio a decisão. É apresentada ainda a arquitetura da ferramenta proposta para auxiliar no restabelecimento de sistemas de potência.

No Capítulo IV são apresentados resultados obtidos pela aplicação da metodologia em dois sistemas teste e em um tronco de sistema de transmissão de uma configuração antiga de estudo e são comparados ainda os resultados de extração de regras com as Instruções de Operação.

O Capítulo V apresenta as conclusões e propostas para desenvolvimentos futuros.

O Apêndice A apresenta resultados das simulações

O Apêndice B apresenta alguns conceitos básicos de redes neurais.

No Apêndice C são apresentados alguns tipos de classificadores e suas características.

O Apêndice D descreve a importância dos métodos de extração de regras de redes neurais para melhor aceitação pelos usuários dos resultados de classificação em alguns tipos de aplicação. São também apresentados sistemas híbridos com esta mesma finalidade.

O Apêndice E apresenta os dados dos sistemas teste utilizados.

Finalmente é apresentada a bibliografia citada e usada ao longo do trabalho.

I.6 Sumário do Capítulo

Neste capítulo foi apresentada a importância da rapidez no restabelecimento de sistema para diminuir os impactos das perturbações no sistema elétrico. Foram ainda ressaltadas as características necessárias e a importância de desenvolvimento de uma ferramenta de apoio aos operadores no desempenho desta tarefa.

CAPÍTULO II

RESTABELECIMENTO DE SISTEMA DE POTÊNCIA

II.1 Considerações Iniciais

No capítulo I foi descrita a importância de desenvolvimento de uma ferramenta de apoio aos operadores no restabelecimento de sistemas de potência. Neste capítulo é apresentada uma visão geral do processo de restabelecimento de sistema, os estudos necessários a sua análise, as diversas estratégias existentes bem como a filosofia utilizada no sistema elétrico brasileiro para solução do problema.

II.2 Introdução

O problema de restabelecimento é extremamente complexo, um problema de otimização combinatória, não linear, sujeito a restrições, com múltiplos estágios e objetivos [5, 6, 7]. Os objetivos são o restabelecimento rápido de todos os consumidores, minimizando o tempo de restabelecimento e maximizando a carga restabelecida a cada estágio. Durante todo o processo devem ser observadas as restrições de fluxo de potência (balanço da carga e geração, limites de fluxos e tensões), de estabilidade (resposta do sistema dinâmica e transitória e considerações de frequência e sincronização), de religamento de geradores, de capacidade de tomada de carga de geradores e de seqüência de chaveamento de linhas.

A complexidade de tal problema, que envolve desde o entendimento da severidade e extensão do distúrbio até o restabelecimento total das cargas e retorno do sistema à condição normal, torna difícil o desenvolvimento de um método geral que possa determinar séries de ações de controle restaurativas para uma faixa de circunstâncias

operativas suficientemente ampla. Técnicas de Inteligência Computacional tais como sistemas especialistas [5,8,9,11,12] , redes neurais [2,3,4] , lógica difusa [9] e algoritmos genéticos [10] têm sido propostos para auxiliar em algumas etapas do restabelecimento de sistema.

II.3 – Visão geral do processo de Restabelecimento de Sistemas de Potência

De maneira genérica o processo de restabelecimento compreende três estágios. No primeiro estágio é feita uma avaliação do estado do sistema, identificação das fontes disponíveis e cargas críticas. No segundo estágio é feita a identificação dos caminhos, energização dos subsistemas e posterior interligação dos mesmos. No terceiro estágio é feito o restabelecimento total das cargas [13].

Podem ser citadas as seguintes principais tarefas que envolvem o processo de restabelecimento do sistema [5]:

- Análise crítica dos dados de tempo real (alarmes, displays) para verificar extensão e severidade do blecaute. É importante verificar se houve operação de alguma proteção que seja impeditiva a reenergização imediata do equipamento sem que tenha havido uma avaliação da equipe de manutenção, como por exemplo atuação de proteção diferencial de transformadores;
- Abertura de disjuntores para preparar o sistema para o restabelecimento. Essa manobra visa evitar, por exemplo, que linhas de transmissão sejam energizadas simultaneamente;
- Partida de geradores na área atingida;
- Deve ser dada atenção especial ao suprimento de emergência para usinas nucleares e cargas críticas;

- Energização de um caminho da unidade de auto-restabelecimento para uma unidade vizinha para parti-la;
- Aumento de geração e tomada de carga gradual garantindo controle de frequência, tensão e fluxos dentro dos limites;
- Gradualmente energizar outros caminhos de transmissão, efetuar tomadas de carga e geração;
- Monitorar continuamente tensões, frequência, balanço de potência ativa e reativa e fluxos;
- Interligar a área com o resto do sistema quando for apropriado;
- Repetir os passos até todos os consumidores serem restabelecidos e o sistema totalmente normalizado.

II.4 Filosofias de Restabelecimento

A escolha do tipo de restabelecimento a ser usado em um sistema depende de vários aspectos, tais como: tamanho do sistema, a capacidade e localização das usinas de autorestabelecimento, quantidade e localização das fontes emergenciais de suprimento de potência [14]. Sistemas pequenos com capacidade de autorestabelecimento centralizada provavelmente usam um método de restabelecimento seqüencial. Para sistemas grandes este método iria demandar muito tempo, sendo mais utilizado o restabelecimento paralelo, com diversos subsistemas sendo normalizados simultaneamente.

O seguinte critério geralmente é utilizado para seccionamento de subsistemas [14]:

- Cada subsistema deve ter capacidade de autorestabelecimento suficiente para restabelecer suprimento para equipamentos críticos;
- Cada subsistema deve ter capacidade de manter a frequência dentro de limites (equilíbrio carga e geração);
- Cada subsistema deve ter recursos para manter o controle da tensão durante a tomada de carga;
- Cada subsistema deve ser monitorado por um centro de controle para manter a segurança e um chaveamento coordenado;
- Alguns subsistemas podem ser formados por unidades térmicas e carga, separados por relés de subfrequência;
- A sincronização dos subsistemas adjacentes deve ser feita nos pontos de interligação com capacidade para isso.

Na referencia [5] são discutidas as diversas possibilidades de restabelecimento: automático e auxiliado por computador. O restabelecimento automático é de difícil implantação, demandaria um tempo elevado de buscas para tomada de decisão e não se deve prescindir do operador, de sua experiência e habilidade para decidir. Desta forma, operador e computador devem desempenhar as funções nas quais são mais eficientes e o restabelecimento ser cooperativo.

II.5- Estratégias de Chaveamento

Logo após a perturbação, tendo sido verificada a falta de tensão, normalmente são abertos todos os disjuntores ou disjuntores selecionados (“Operação Controlada”) nas diversas subestações do sistema. Essa manobra visa evitar que linhas de transmissão e demais equipamentos sejam energizados simultaneamente. A energização simultânea de circuitos pode ocasionar sobretensões capazes de danificar os

equipamentos. Na referência [15] são discutidas as vantagens e desvantagens das estratégias de chaveamento.

Um aspecto bastante importante no restabelecimento do sistema são as usinas com capacidade de autorestabelecimento. A recomposição do sistema após um grande distúrbio se inicia nestas usinas e qualquer retardo pode significar um expressivo atraso no processo de recomposição do sistema.

Um dos primeiros passos do restabelecimento envolve a energização de circuitos para restabelecer os troncos principais do sistema. Essas energizações resultam em um aumento de tensão, principalmente no extremo da linha energizada que ainda se encontra sem carga ativa. Para minimizar as sobretensões reatores shunt podem ser energizados simultaneamente a estes circuitos [14]. Da mesma forma se evita a energização de circuitos paralelos antes da tomada de carga no primeiro para se evitar excesso de reativo, gerado por estes circuitos, no sistema.

Outro aspecto importante é que a tomada de carga deve ser gradual e em montantes previamente definidos por estudos, de forma a não provocar desvios excessivos na frequência. Durante todo o processo especial atenção deve ser dada ao controle de tensão, sendo necessário ligar capacitores para suprir a carga reativa adicionada ao sistema com o aumento de consumidores ligados. Da mesma forma circuitos paralelos também são ligados para diminuir a impedância série e melhorar o perfil de tensão.

Na referência [14] são descritos alguns problemas para balanço da potência reativa durante o processo de restabelecimento e ressaltada a importância do pessoal de operação rapidamente saber a magnitude e localização da capacidade de reserva de reativo para determinar a ação apropriada durante o restabelecimento.

A estratégia de uma empresa se baseia em simulações, análise e experiência de todo o pessoal envolvido no restabelecimento. Normalmente o seccionamento do sistema em ilhas, restabelecimento de cada ilha e sincronização das ilhas proporciona maior rapidez ao processo.

II.6 – Estudos de energização

A análise do restabelecimento de um sistema elétrico envolve uma série de estudos de forma a garantir o sucesso e segurança do processo. Estudos de regime permanente devem ser feitos para analisar as condições do sistema nas diversas etapas e configurações de recomposição. Devem ser verificados os perfis de tensão, carregamentos e capacidade das unidades geradoras de forma que nenhum limite seja ultrapassado.

Estudos de estabilidade eletromecânica devem ser realizados para analisar o comportamento das oscilações de frequência e tensão durante as manobras de energização de linhas de transmissão, transformadores e nas tomadas e rejeições de carga.

Estudos de transitórios eletromagnéticos são necessários para definir as tensões máximas de energização de equipamentos avaliando os surtos de manobra decorrentes da energização de linhas, configuração mínima de reatores no sistema e avaliar rejeições de carga. São realizados estudos estatísticos para representar as características probabilísticas dos equipamentos de manobra, por exemplo, a aleatoriedade dos instantes de fechamento do disjuntor. Para a condição mais crítica de fechamento devem ser simuladas manobras com e sem aplicação de curto-circuito fase-terra no terminal remoto da linha.

Devem ser analisadas as sobretensões sustentadas à frequência fundamental, transitórias de chaveamentos e resultantes de ressonância harmônica. Estas sobretensões podem levar a operações de proteção ou a falhas em equipamentos (transformadores, disjuntores, pára-raios, etc). É importante a preparação da rede para energização, podendo ser estabelecidas medidas tais como a utilização de reatores shunt para controle de sobretensões conforme discutida em [14].

A referência [16] apresenta uma visão geral das ferramentas analíticas necessárias para descrever o comportamento estático, transitório e dinâmico do sistema durante o restabelecimento. Para cada ferramenta os autores resumem o que precisa ser estudado, as características específicas necessárias à análise do restabelecimento, os procedimentos e porque os estudos são necessários.

A carga se modifica durante o processo e depende de condições de tempo, hora do dia, estilo de vida de consumidor, tipo de carga e características dinâmicas específicas de carga. Os modelos dinâmicos podem não ser adequados para avaliar o fenômeno contemplando todos os aspectos (relés de subfrequência, taxa de elevação de carga em geradores, etc). Em substituição são usados manuais contendo regras operativas com informações várias, entre elas qual é o maior montante de carga que pode ser tomado por vez.

O restabelecimento hoje é executado passo a passo, de forma manual e é baseado em instruções e procedimentos operativos. Estes procedimentos são oriundos dos estudos de regime permanente, de estabilidade eletromecânica e de transitórios eletromagnéticos prévios e análise de especialistas.

II.7- O Restabelecimento do Sistema Elétrico Brasileiro

No Brasil o Operador Nacional do Sistema Elétrico é a entidade responsável pela coordenação e controle da operação das instalações de geração e transmissão de energia elétrica no Sistema Interligado Nacional (SIN), sob a fiscalização e regulação da Agência Nacional de Energia Elétrica .

O ONS elabora, com a participação dos agentes, os Procedimentos de Rede que são documentos de caráter normativo, aprovados pela ANEEL, que definem os procedimentos e os requisitos necessários à realização das atividades de planejamento da operação eletro-energética, administração da transmissão, programação e operação em tempo real no âmbito do SIN. Entre os Procedimentos de Rede está o Manual de Procedimentos da Operação (MPO) em cujo submódulo 10.11, Norma de Operação – Recomposição da Rede de Operação após Perturbação, estão estabelecidas premissas, diretrizes, responsabilidades e critérios para Recomposição da Rede de Operação após perturbações gerais ou parciais, visando o restabelecimento das condições normais de operação [47]. Um desligamento geral é caracterizado quando não houver tensão em todos os terminais de linhas de transmissão e geradores de uma instalação.

A recomposição do sistema após um blecaute se inicia a partir das usinas de auto-restabelecimento, tendo sido assim definidas as usinas que não necessitam de alimentação externa para seus serviços auxiliares para que possam ter suas unidades geradoras recompostas após um desligamento geral na mesma. A capacidade de auto-restabelecimento pode ser integral ou parcial, sendo que nesta última classificação, se enquadram as usinas onde os serviços auxiliares são alimentados a partir da tensão terminal dos próprios geradores. As unidades geradoras nestas usinas permanecem girando mecanicamente e excitadas, após a ocorrência da perturbação.

A estratégia de recomposição do sistema considera a pior hipótese de uma área ou região totalmente desenergizada, com exceção de ilhamentos programados, após a ocorrência de um blecaute em condições extremas de carga (cargas pesada e leve) de forma a garantir a viabilidade e eficácia do processo em qualquer horário.

As Instruções de Operação são os documentos em que são detalhadas as ações a serem seguidas por todo o pessoal que participa da operação em tempo real, as responsabilidades dos mesmos e as condições mínimas para recomposição de cada elemento do sistema. Nelas estão definidos os procedimentos preferenciais de recomposição do sistema e alguns procedimentos alternativos, visando cobrir eventuais situações de indisponibilidades de equipamentos que inviabilizem a adoção do procedimento preferencial no processo de recomposição.

A Recomposição do Sistema Elétrico Brasileiro após um blecaute compreende duas fases: a fase fluente e a fase coordenada. Para isto o sistema foi dividido em áreas geoeletricas que possuem pelo menos uma usina de auto-restabelecimento, onde são partidas e sincronizadas um número mínimo de unidades geradoras, instalações de onde são energizadas linhas de transmissão e transformadores necessários à alimentação de cargas prioritárias.

Na fase fluente o restabelecimento se inicia nas usinas de autorestabelecimento e são recompostas áreas geoeletricas previamente definidas de forma isolada com recomposição de cargas prioritárias e tomadas de carga máximas pré-definidas por exaustivos estudos na fase de pré-operação. Nesta fase os procedimentos de recomposição são descentralizados e efetuados pelos operadores das instalações com um mínimo de troca de informações entre instalações e Centro de Operação com a qual se relaciona. A parcela de carga prioritária atendida nesta fase é previamente estabelecida nos estudos, compatível com a geração, transmissão e transformação disponíveis e definidas nas Instruções de Operação. Para religamento dos

equipamentos devem ser obedecidas as configurações mínimas e as condições de pré-energização estabelecidas nas Instruções de Operação.

É importante ressaltar o fato de na fase fluente todas as ações necessárias são executadas pelos operadores das usinas e subestações de acordo com os procedimentos constantes nas Instruções de Operação sem a necessidade de intervenção dos Centros de Operação, com isso se consegue rapidez no processo de recomposição do sistema. Caso ocorram problemas que impeçam a execução da fase fluente há uma imediata intervenção dos centros de controle e o restabelecimento passa a ser feito de forma coordenada.

Na fase coordenada os Centros de Operação coordenam a interligação das áreas e a restauração do sistema às condições normais de operação, liberando a tomada de carga adicional, fechamento de paralelo ou anéis, sincronização de áreas isoladas ou ilhas programadas e religamento do Controle Automático de Geração (CAG).

Similarmente aos procedimentos adotados nos demais países, as principais ações envolvidas no restabelecimento do sistema elétrico brasileiro podem ser resumidas em:

- Sincronização de unidades geradoras;
- Preparação das instalações para o recebimento de tensão, efetuando manobras de acordo com as instruções específicas;
- Desligamento de bancos de capacitores e comutação de tapes de transformadores para uma posição que não implique em sobretensões no sistema durante a etapa da recomposição;
- Energização de linhas de transmissão, transformadores e demais ações de recomposição fluente das instalações conforme Instruções de Operação;
- Execução das ações de recomposição na fase coordenada;

- Monitoramento da evolução das principais grandezas (tensão, carregamento, potência sincronizada e carga restabelecida) intervindo e alterando o processo quando necessário;
- Controle da operação de CAG durante a recomposição do sistema;
- Restabelecimento da carga prioritária em cada fase da recomposição até o limite pré-estabelecido nas Instruções de Operação;
- Fechamento de paralelo ou anéis;
- Sincronização de ilhas isoladas ou ilhas programadas;
- Restabelecimento das cargas lembrando que a retomada de carga deve ser processada gradativamente a fim de evitar eventuais oscilações de potência ou tensão que possam acarretar perturbações ou desligamentos durante o processo de recomposição.

As responsabilidades dos Centros de Operação do ONS, das empresas e instalações no que se refere a coordenação, supervisão, controle e execução das ações envolvidas no processo de recomposição do sistema elétrico brasileiro estão definidas no Manual de Procedimentos da Operação [47].

A referência [1] aborda a filosofia básica atual e critérios para recomposição do Sistema Interligado Brasileiro, faz um breve histórico da evolução do processo de recomposição deste sistema e relata as principais perturbações ocorridas no novo modelo do setor elétrico brasileiro.

A referência [17] apresenta os principais aspectos e critérios adotados pelo ONS no Restabelecimento do Sistema Elétrico Brasileiro após perturbações parciais ou totais. A área Rio de Janeiro foi utilizada para exemplificar os procedimentos adotados.

II.8 Sobretensões Resultantes da Energização de uma Linha de Transmissão

II.8.1 Introdução

Energização e religamento de linhas de transmissão são manobras típicas que ocorrem em um sistema e cuja análise pode ser feita considerando-se três períodos distintos: [18]

- O período transitório, no qual prevalecem os efeitos das ondas trafegantes associadas a estes fenômenos e cuja duração é da ordem de alguns milissegundos, dependendo do comprimento da linha manobrada. As sobretensões resultantes podem ser caracterizadas por um valor de pico e uma taxa de crescimento, assumindo uma forma exponencial;
- O período dinâmico, que representa uma transição entre os períodos transitórios e o regime permanente, sendo de natureza repetitiva, caracterizado por pequenas variações na forma de onda que é aproximadamente periódica e composta pela tensão à frequência fundamental e harmônicos de baixa ordem, predominantemente segundo e terceiro, os quais poderão distorcer bastante a forma de onda, podendo ter uma duração de até um segundo;
- O regime permanente, no qual a tensão é periódica, porém podendo ser bastante distorcida. Geralmente, para uma linha de transmissão, as sobretensões neste período ocorrem quando o terminal receptor está aberto, como no caso de energizações e religamentos, podendo persistir por vários minutos.

II.8.2 Análise de Regime Permanente

Normalmente a energização de uma linha de transmissão é efetuada a partir do fechamento do disjuntor de uma de suas estações terminais, respeitando o sentido de energização previsto nas Instruções de Operação. Considerando a energização de uma linha a partir da Subestação A, a tensão nesta barra V_1 , antes de efetuar a energização, é denominada tensão de pré-energização ou simplesmente tensão de energização.



Figura 1: Energização da linha SE A – SE B

Em [19] é feita a seguinte análise da energização de uma linha de transmissão utilizando o quadripolo para representá-la na solução em regime permanente:

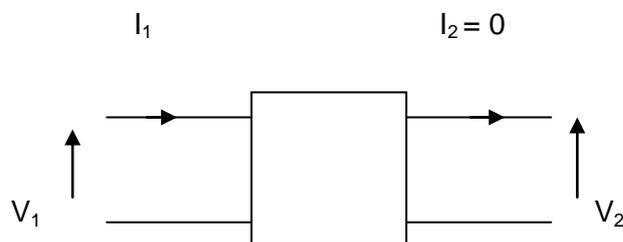


Figura 2 : Quadripolo

Escrevendo a partir das constantes do quadripolo, tomadas no ponto $s = j\omega$, para frequência nominal da rede:

$$\begin{bmatrix} V_1 \\ I_1 \end{bmatrix} = \begin{bmatrix} A & B \\ C & D \end{bmatrix} \times \begin{bmatrix} V_2 \\ I_2 \end{bmatrix} \quad (II.1)$$

Como $I_2 = 0$ então:

$$V_1 = AV_2 \quad (II.2)$$

A tensão no final da linha em vazio (V_2) é maior que a tensão no início da linha (V_1), pois a constante A tem módulo menor que 1. A determinação do valor V_2 é importante para analisar não somente a sobretensão nos equipamentos terminais da linha como analisar as condições de paralelismo com o restante do sistema ou de tomada de carga. [19].

Essa variação entre as tensões no início e fim de linha em vazio é conhecida como efeito Ferranti [19]. Esse comportamento da linha é corrigido quando necessário utilizando-se reatores em derivação para controle das sobretensões sustentadas. Normalmente as linhas operam com níveis de compensação de 40 a 60% da capacitância da linha de transmissão [19]. Portanto, a indisponibilidade do reator em uma linha de transmissão compensada afeta substancialmente os valores de tensão máxima de pré-energização da linha de forma a que os limites de sobretensão no final da linha não sejam ultrapassados.

Outro fator que afeta os valores das sobretensões sustentadas é o fato da rede elétrica ser forte ou fraca em termos de sua potência de curto-circuito. Em [19] é feita uma análise aproximada desta influência. A tensão sustentada no início da linha pode ser calculada por:

$$V_1 = \frac{E}{1 - \frac{Q_C}{P_{CC}}} \quad (II.3)$$

Desta expressão se conclui que a sobretensão sustentada no início da linha depende da relação:

$$\frac{Q_c}{P_{cc}} \quad (11.4)$$

P_{cc} é a potência de curto-circuito trifásica da rede para uma tensão nominal de linha, calculada através da expressão:

$$P_{cc} = \frac{V^2}{Z_t} \quad (11.5)$$

Z_t e E representam a impedância e tensão equivalente de Thèvenin da rede vista da barra energizadora.

Q_c é a potência capacitiva trifásica da linha para a tensão nominal V que pode ser calculada por

$$Q_c = V^2 \omega C \quad (11.6)$$

C é a capacitância total da linha.

A tensão no fim da linha é calculada através do parâmetro A do quadripolo.

Os piores casos ocorrem para linhas longas (Q_c grande) com redes fracas (P_{cc} pequeno). A fórmula ainda tem validade para linhas compensadas com reatores desde que se considere Q_c como saldo de potência indutiva ou capacitiva após a compensação da linha. [19]

Podemos concluir, portanto, que a potência de curto-circuito da rede é fator determinante do valor das sobretensões sustentadas. Alterações da configuração da rede e conseqüente alteração do equivalente de Thèvenin influenciam nos valores das sobretensões sustentadas, visto que o valor da capacitância é uma constante para

uma determinada linha. Portanto alterações de número de máquinas em usinas e circuitos em operação influenciam nos valores destas sobretensões.

II.8.3 Análise Transitória de Manobra

Sobretensões de manobra são devidas à operação de um equipamento de manobra, defeito ou outra causa, cuja forma de onda é similar à onda de impulso de manobra. Tal sobretensão é em geral fortemente amortecida e de curta duração (entre 100 e 500 microsegundos) [18]. A amplitude e duração das sobretensões de manobra dependem dos parâmetros do sistema, de sua configuração, e das condições em que ele se encontra no momento da manobra. Desta forma, para um mesmo sistema, a mesma operação pode resultar em valores diferentes para a sobretensão. Como exemplo de sobretensões de manobras mais comuns temos a energização e religamento de linhas e aplicação e abertura de faltas.

A forma de onda de uma sobretensão de manobra tem um período de frente de onda mais lento do que uma sobretensão de impulso atmosférico, conforme mostram as figuras 3 e 4 .

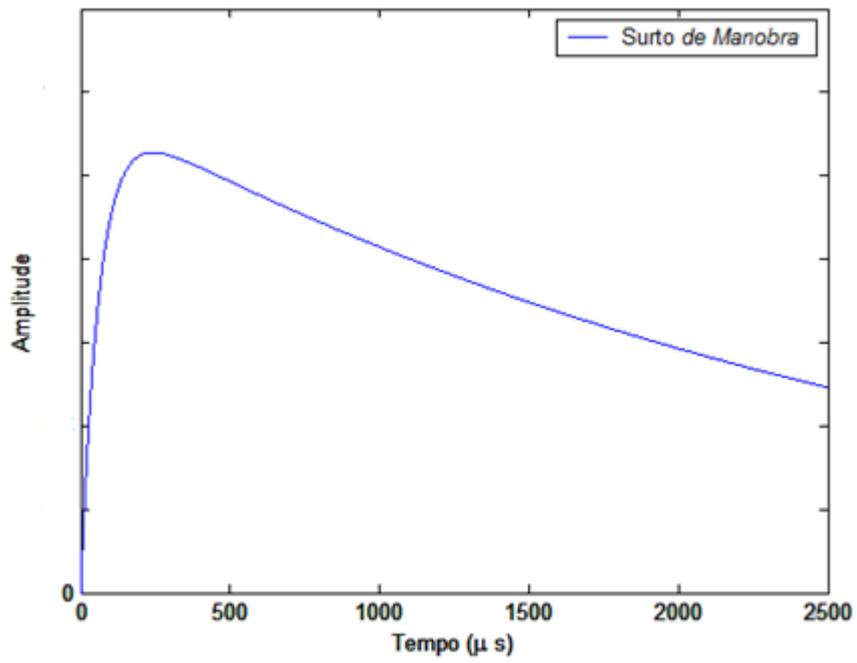


Figura 3 – Sobretensão de manobra típica

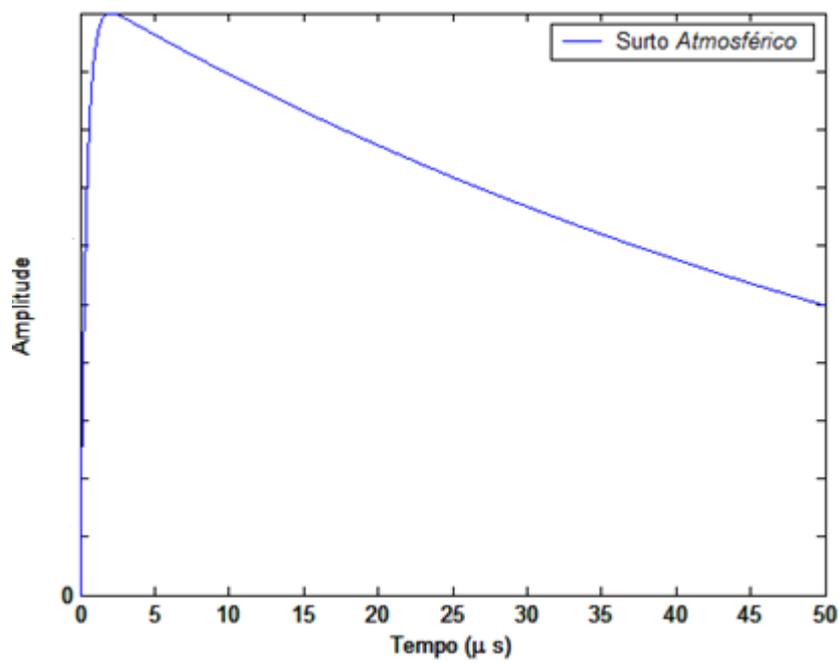


Figura 4 – Sobretensão de impulso atmosférico típica

As frequências presentes em transitórios de sobretensões de manobra, que se enquadram no caso de sobretensões com frentes de onda lentas, são da ordem de centenas de Hz até poucas dezenas de kHz, com exceção do caso de manobras de chaves em subestações SF₆, que apresentam frentes de onda rápidas. [19]

Uma característica importante das sobretensões de manobra é o aspecto probabilístico, ou seja, para uma determinada manobra pode-se obter diferentes valores de sobretensão, uma vez que dependerão não só da dispersão dos instantes de fechamento do disjuntor, como também do instante na onda de tensão onde ocorreu o fechamento. Devido à aleatoriedade desses eventos, torna-se extremamente difícil prever a máxima sobretensão que irá ocorrer para uma manobra específica, sendo necessário recorrer a métodos estatísticos para descrever o comportamento da sobretensão.

As sobretensões de manobra são fenômenos transitórios eletromagnéticos cuja probabilidade de ocorrência depende do número de faltas e operações de manobra no sistema e suas magnitudes são influenciadas pela configuração do sistema, pela potência de curto-circuito, bem como pelas características dos equipamentos [18]. Podem ser reduzidas de várias formas entre elas pela compensação paralela, e utilização de resistores de fechamento.

A determinação das sobretensões de manobra é normalmente realizada em analisador de transitório de redes (TNA), em programas de transitórios eletromagnéticos, como os programas EMTP [26] e Real Time Digital Simulator (RTDS). É feita uma representação trifásica da rede com as linhas de transmissão sendo normalmente representadas com parâmetros distribuídos e idealmente transpostas.

As sobretensões resultantes de manobras de energização e religamento dependem de diversas condições de sistema, sendo as mais importantes relacionadas a seguir: [18]

- Potência de curto-circuito do sistema alimentador;

- Ponto na onda de tensão em que o disjuntor é fechado;
- Grau de compensação da linha de transmissão;
- Comprimento da linha de transmissão;
- Perdas no condutor;
- Presença de equipamento de proteção;
- Grau de aterramento do sistema;
- Tensão de pré-manobra;
- Valor do resistor de pré-inserção;
- Tempo de inserção do resistor;
- Dispersão entre os contatos do disjuntor.

Na figura 5 é apresentada uma manobra típica de energização.

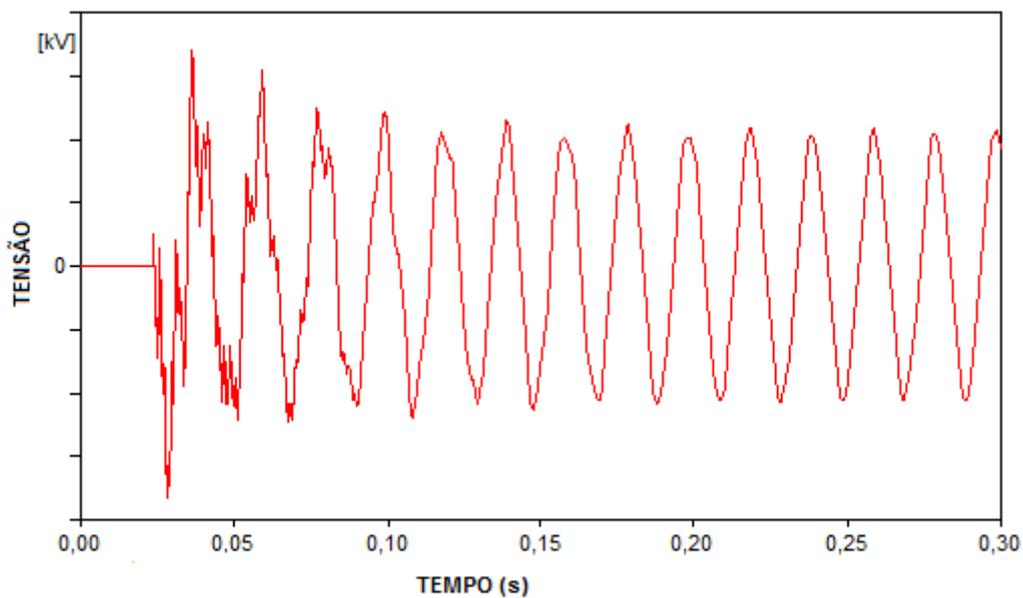


Figura 5 – Manobra típica de energização

II.9 Técnicas de Inteligência Computacional no Restabelecimento do Sistema

Elétrico

Técnicas de Inteligência Computacional tais como sistemas especialistas, redes neurais, lógica difusa e algoritmos genéticos têm sido propostos para auxiliar na operação do sistema elétrico, em especial na tarefa de restabelecimento de sistema.

Sistemas especialistas têm sido propostos para auxiliar no treinamento em recomposição de sistemas de transmissão de energia elétrica. A referência [11] apresenta um sistema especialista para treinamento em recomposição de um tronco do sistema elétrico, desenvolvido na linguagem PROLOG, associado a um programa de fluxo de potência que tem a função de calcular as tensões e fluxos nas linhas energizadas a cada mudança de configuração da rede.

A referência [12] enfoca o desenvolvimento de um sistema especialista para um tronco de transmissão, cujo objetivo principal é sugerir ao operador as providências cabíveis para a recomposição a partir de dados adquiridos em tempo real pelo COS. O conhecimento representado tem como base as Instruções de Operação e incorpora a experiência da equipe do COS.

Algumas pesquisas se concentram no desenvolvimento de sistemas especialistas para restabelecer o tronco principal da rede. Muitas empresas possuem procedimentos escritos que descrevem um ou mais caminhos para a recomposição da rede. Esses procedimentos podem ser implementados em versões on-line, entretanto, se imprevistos ocorrerem durante o restabelecimento, nenhuma ação pode ser sugerida [5].

As pesquisas mais recentes associam sistemas especialistas a ferramentas analíticas que irão verificar, por exemplo, se um dado caminho de restabelecimento pode causar sobrecargas ou sobretensões.

Em [20] é proposta uma ferramenta para auxílio à decisão capaz de levar em consideração a evolução dinâmica do estado da rede devido às ações de controle ou eventos imprevistos, acoplada a um simulador dinâmico que valida sugestões do usuário.

A lógica difusa, com base na teoria dos conjuntos nebulosos, entre outras coisas tem se mostrado bastante adequada para modelar incertezas para as quais não são disponíveis dados estatísticos. Entre as áreas de aplicação mais importantes, em sistemas elétricos, estão sistemas de inferência e sistemas de tomadas de decisões [21]. Em [9] grandezas como montantes de carga restabelecida, taxa de sobrecarga, insuficiência de suporte de reativo são avaliados por regras FUZZY e auxiliam na avaliação da adequação do procedimento operativo para restabelecimento de sistema de potência.

Os Algoritmos Genéticos são algoritmos de otimização e busca baseados nos mecanismos de seleção natural e genética. Em [10] é apresentada uma abordagem onde um algoritmo genético associado a um simulador de sistema de potência e uma árvore de decisão são usados para gerar uma seqüência de operação de restabelecimento de cargas.

As redes neurais artificiais (RNA) constituem uma forma de aproximação universal de funções, que apresenta um desempenho satisfatório durante a interpretação e classificação de padrões complexos. Estas são também bastante versáteis, apresentam grande rapidez na solução do problema, além de apresentarem

capacidade de generalização e alto desempenho computacional, devido ao seu forte paralelismo. Elas não dependem do conhecimento prévio das regras que governam o fenômeno, pois são adaptáveis e inferem soluções a partir dos exemplos utilizados durante o treinamento. O fato de elas serem não lineares permite que capturem interações complexas entre as variáveis, como ocorre normalmente no mundo real. Todas estas características se mostram bastante adequadas para utilização de redes neurais ao problema de restabelecimento do sistema.

Em [3] é proposta uma nova técnica para elaboração de planos de restauração de Sistemas Elétricos de Potência fazendo uso de Redes Neurais Artificiais e são feitos testes comparativos com técnicas de restauração baseados em busca heurística. O esquema é composto de 3 módulos básicos: módulo de carga fria, módulo de seleção e módulo de seqüência de energização. Para alimentar os módulos são necessárias informações pré-blecaute do sistema via SCADA-EMS, além do tempo de restabelecimento estimado e dos valores coletados pós-distúrbio que indicam a localização da falta. As RNA que compõe os diversos módulos informam o percentual de carga fria, os equipamentos que podem ser usados no restabelecimento e a seqüência de energização (fechamento dos disjuntores).

Técnicas de Inteligência Computacional também tem sido usadas na determinação de caminhos de restabelecimento [9, 10, 5, 20]. Estes caminhos podem ser validados com relação ao regime permanente e domínio do tempo por simulações.

A referência [22] estudou a aplicação de buscas heurísticas tais como o algoritmo A* e a Busca Tabu, ao problema de determinação de rotas alternativas para recomposição fluente de sistemas elétricos de potência. A estratégia adotada é capaz de sugerir corredores de recomposição preferenciais e alternativos e avaliá-los do ponto de vista de regime permanente com bons resultados.

Conforme discutido no item anterior a energização de linhas de transmissão resulta em sobretensões transitórias e sustentadas. A análise destas sobretensões tem sido feita através de programas de transitórios eletromagnéticos, como o ATP (Alternative Transients Program). Em [4] é apresentado um método para estimar o valor de pico da sobretensão transitória na energização de uma linha de transmissão. Inicialmente foi feita uma análise paramétrica de cada um dos diversos fatores que influenciam no valor de pico desta sobretensão. Estes fatores foram agrupados em três categorias: influência forte, média e fraca. Quatro fatores de influência forte foram selecionados: tamanho do sistema, comprimento da linha, ângulo de chaveamento e presença do reator. Estes fatores foram utilizados pelos autores como variáveis de entrada para uma rede neural estimar os valores de pico de sobretensão associados. Os resultados das simulações mostram que a técnica proposta pode estimar o valor de pico das sobretensões de chaveamento com boa precisão.

Esta recente publicação reforça o conceito da necessidade de se buscar uma alternativa a execução de estudos de transitórios eletromagnéticos em tempo real, utiliza uma rede neural como aproximador, estimando o valor de pico da sobretensão e não prescinde de uma análise final do resultado para tomada de decisão.

II.10 Sumário do Capítulo

Neste capítulo é apresentada uma visão geral do processo de restabelecimento, sumarizados alguns aspectos relevantes que envolvem a filosofia, estratégias de chaveamento e estudos necessários para avaliação das sobretensões resultantes destes chaveamentos. Um método simplificado de cálculo de sobretensões sustentadas decorrentes da energização de uma linha de transmissão é descrito e os principais fatores que influenciam nos valores das sobretensões decorrentes destas energizações são indicados. Finalmente são apresentadas algumas pesquisas na área de Inteligência Computacional em Restabelecimento de Sistemas de Potência

CAPÍTULO III

SISTEMA HÍBRIDO PARA RESTABELECIMENTO DE SISTEMAS DE POTÊNCIA

III.1 Considerações Iniciais

Conforme descrito no capítulo I o objetivo do trabalho é desenvolver uma ferramenta, que pudesse ser utilizada para apoio à decisão dos operadores durante o Restabelecimento do Sistema na fase de tempo real, para classificar a energização de um circuito como viável ou não. Neste capítulo é justificada a escolha de redes neurais para efetuar esta classificação e a utilização de sistemas híbridos como forma de obter um maior entendimento do resultado da mesma. Além disso, formula o problema e apresenta a metodologia utilizada para construção da ferramenta de apoio à decisão.

III.2 Formulação do problema

O problema consiste em determinar se um elemento do sistema elétrico pode ser ou não energizado, sem violação dos valores admissíveis de sobretensão transitória e sustentada e sem causar danos aos equipamentos. A análise deste tipo de problema normalmente é feita através da realização de estudos de transitórios eletromagnéticos e de regime permanente. Estes estudos são baseados em alguns cenários de blecaute total ou parcial e seus resultados são transcritos em Instruções de Operação que serão utilizadas pelo pessoal de operação em tempo real, quando de desligamentos no sistema elétrico. São considerados apenas alguns cenários mais prováveis e algumas indisponibilidades de equipamentos tendo em vista o número elevado de combinações de configurações possíveis e a forma de apresentação dos resultados.

A alternativa de execução em tempo real de estudos de regime permanente e de transitórios eletromagnéticos, para análise da energização, se mostra inviável dada a complexidade de formulação e análise de resultados, em especial no que se refere a estes últimos estudos. Além disso, o tempo de processamento e análise inviabiliza esta alternativa. Não obstante todos estes aspectos devem ser considerados de forma a evitar ações inadequadas, operação de proteções e danos aos equipamentos nas energizações.

O problema consiste, portanto, em desenvolver uma ferramenta que facilite a tomada de decisão, o trabalho de consulta e implementação de ações durante o restabelecimento do sistema. É necessário que esta ferramenta seja rápida, precisa e é desejável que tenha capacidade de explanação para aumentar a confiança do usuário na sua utilização.

III.3 A Abordagem do Problema

Este problema foi abordado como um problema de classificação com duas classes possíveis: energização viável ou não. O apêndice C descreve alguns tipos de classificadores.

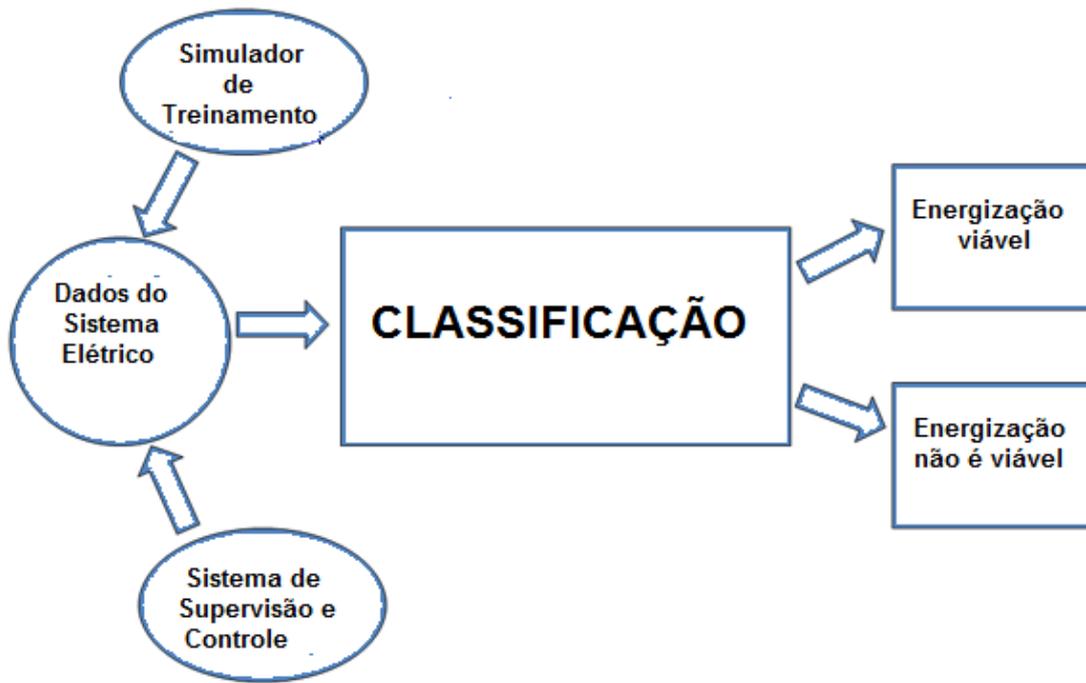


Figura 6 - Abordagem do Problema

III.4 A Escolha de Redes Neurais para Efetuar a Classificação

Para efetuar a classificação da energização foram utilizadas redes neurais. No apêndice B são apresentados os conceitos básicos de redes neurais, o neurônio artificial, as principais funções de ativação utilizadas e os diversos tipos e algoritmos de aprendizagem. As principais razões que levaram a escolha das redes neurais para classificar a viabilidade de restabelecimento são:

- A existência de uma interação complexa dos parâmetros de entrada entre si e com a saída;
- O bom desempenho para classificação destes padrões complexos e que não sejam necessariamente linearmente separáveis;

- Independem do conhecimento do tipo de distribuição de probabilidade das variáveis de entrada;
- Rapidez de resposta em formato simples;
- Robustez para ruídos nos dados de entrada;
- Capacidade de generalização.

Alguns destes aspectos têm motivado a escolha desta técnica para solução de problemas de tempo real [23].

O perceptron é a forma mais simples de uma rede neural usada para classificação de padrões linearmente separáveis (padrões que se encontram em lados opostos de um hiperplano) [24]. Este tipo de classificador foi utilizado no início do trabalho em alguns testes para restabelecimento de circuitos em sistemas mais simples, apresentando um desempenho bastante satisfatório. Nestes circuitos cada padrão de entrada é composto de três atributos: tensão, número de máquinas na usina e configuração do sistema (sistema completo ou não). A representação gráfica dos dados de entrada evidenciou a existência de um hiperplano de separação entre exemplares de cada classe (energização possível ou não), justificando este bom desempenho. A figura 7 mostra esta separação entre os exemplares.

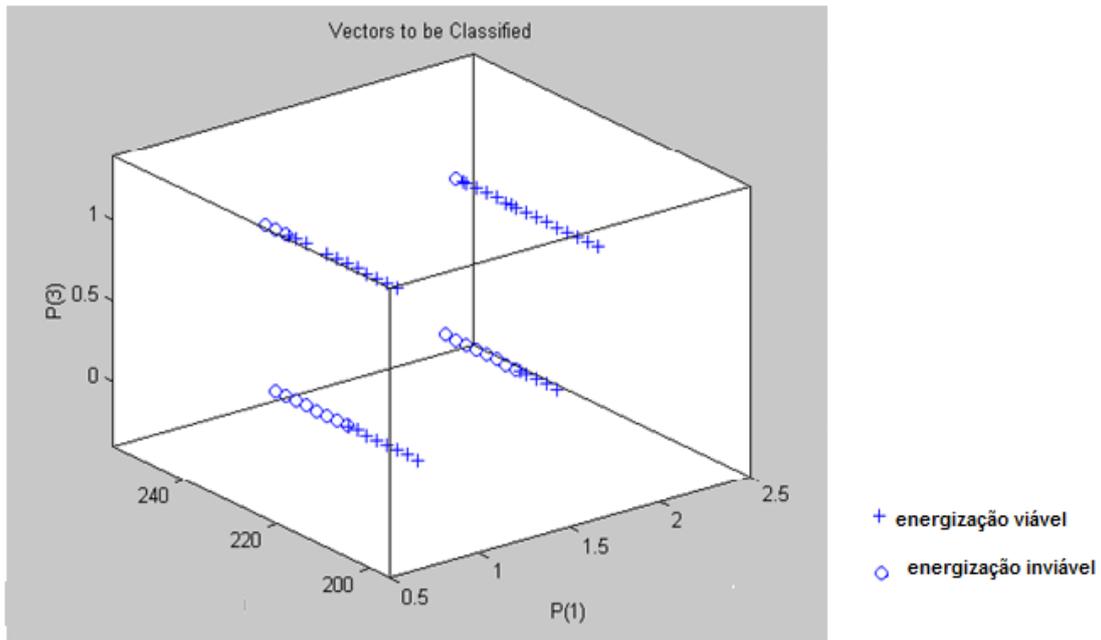


Figura 7 - Representação gráfica dos dados de entrada

Posteriormente, testes realizados utilizando o perceptron para classificação em restabelecimento de sistemas mais complexos, com diferentes atributos de entrada não apresentaram bons resultados. Diversas combinações de número de máquinas nas usinas, tensões, configuração do sistema, presença de reator no circuito a ser energizado e outros atributos compõem padrões que não são linearmente separáveis. Para estes sistemas foi necessário utilizar redes neurais MLP.

Redes neurais MLP têm excelente desempenho para tarefas de classificação. Em contrapartida existe uma reação natural à utilização de técnicas, comumente chamadas caixas pretas, em que apenas um resultado é apresentado sem que se conheça a forma com que se chegou a esta conclusão, em especial em alguns tipos

de aplicação onde a segurança é fator primordial. Diversas pesquisas têm sido feitas em extração de regras de redes neurais como uma forma de resolver esta limitação.

III.5 A Extração de Regras

A falta de compreensibilidade se constitui um dos principais obstáculos à utilização de redes neurais em aplicações onde segurança é uma preocupação primordial. Para se obter uma melhor aceitação pelos usuários é importante que se tenha um melhor entendimento de como a rede solucionou um dado problema. Além disso, a explicitação em forma de regras do conhecimento adquirido pela rede neural, após o processo de treinamento, permite sua análise por um especialista numa tentativa de descobrir se o conjunto de dados utilizados é limitado e não representativo do problema, numa tentativa de melhorar a generalização da rede.

A tarefa de expressar em poucas regras o complexo mapeamento entre as entradas e saídas feito pela rede neural num compromisso entre precisão e simplicidade é uma tarefa bastante difícil. Obter regras simples, bons resultados para variáveis de entrada discretas e contínuas e que independam da arquitetura da rede tem motivado diversas pesquisas, mas ainda requerendo mais investigação. O apêndice D descreve alguns dos métodos propostos [29, 31, 32, 33, 34, 35, 36].

Uma alternativa bastante interessante é a utilização de sistemas híbridos onde uma rede neural classificadora é associada a uma árvore de decisão para extrair as regras utilizadas na classificação, onde cada uma das técnicas inteligentes resolve uma das subtarefas do problema principal. Desta forma consegue-se superar limitações ou

deficiências ou melhorar o desempenho reunindo as potencialidades de cada uma das técnicas na solução de um dado problema.

Árvore de decisão é um dos métodos de aprendizado simbólico mais amplamente utilizados para inferência indutiva, podendo também ser utilizado como método de preparação de dados para servir de entrada para outros algoritmos de mineração de dados como, por exemplo, uma rede neural. Apesar das árvores de decisão produzirem justificativas para as inferências, a qualidade da classificação é, em geral, inferior a produzida por uma rede neural.

Um conjunto de regras pode ser extraído diretamente de uma árvore de decisão. Uma regra é gerada por cada folha. O antecedente da regra inclui uma condição para todo nó ou caminho da raiz até a folha e o conseqüente da regra é a classe atribuída à folha. Este procedimento produz regras que não são ambíguas em que a ordem em que são executadas é irrelevante. Entretanto, em geral, regras que são lidas diretamente de uma árvore de decisão são mais complexas que o necessário e são usualmente podadas para remover cláusulas desnecessárias.

A simplicidade da forma com que regras podem ser extraídas de árvores de decisão utilizando o algoritmo C4.5 e o formato com que as mesmas se apresentam, que se assemelha bastante as Instruções de Operação utilizadas atualmente para apoio ao pessoal de operação durante o restabelecimento de sistema elétrico de potência, motivaram a escolha deste método para extração de regras dos dados utilizados no processo de classificação.

III.6 A Metodologia Proposta para Solução do Problema

A metodologia proposta para solução do problema consiste das seguintes etapas:

- Realização de estudos de regime permanente, de forma a determinar a tensão máxima de energização do circuito que não viola os limites admissíveis de sobretensão sustentada;
- Realização de estudos de transitórios eletromagnéticos de forma a analisar as sobretensões transitórias decorrentes da energização do circuito com estes valores máximos de tensão de pré- energização. Deve ser verificado se estas sobretensões podem ocasionar atuação de alguma proteção de sobretensão, violação dos limites de energia dissipada em pára-raios da linha ou de tensão de disparo de pára-raios convencionais;
- Seleção de características de forma a considerar apenas os atributos que tem influência na classificação (seleção de atributos);
- Construção de banco de dados com os valores dos atributos correspondentes aos exemplos de energizações viáveis ou não para treinamento da rede neural;
- Projeto e treinamento da rede neural para classificar a energização;
- Extração de regras utilizando árvore de decisão.

Utilizando esta metodologia é desenvolvido um sistema inteligente híbrido que permite classificar as alternativas viáveis de Restabelecimento do Sistema, baseado nos estudos de regime permanente e transitórios eletromagnéticos realizados na fase de planejamento do restabelecimento. Este sistema se utiliza da rapidez de resposta e capacidade de generalização das redes neurais, características bastante úteis para a operação em tempo real. A rede neural pode ser alimentada por valores de algumas

grandezas presentes na operação do sistema elétrico, obtidas de um estimador de estado ou de um simulador de sistema elétrico, e classificar a energização como viável ou não.

Além disso, esta ferramenta possibilita a extração de regras utilizadas na solução do problema, possibilitando um maior entendimento e aceitação pelos usuários. Na fase de planejamento da operação possibilita extrair regras dos resultados de estudos de regime permanente e transitórios eletromagnéticos para servir de base para confecção de Instruções de Operação.

III.7 Arquitetura Proposta

O sistema híbrido é composto de um módulo de classificação (rede neural) associada à um módulo de extração de regras (árvore de decisão). Alguns dados, tais como tensões, fluxos, estado de disjuntores e chaves que indicam indisponibilidades de circuitos e reatores, podem ser adquiridos diretamente do sistema elétrico ou de resultados de simulações de fluxo de potência. Estes dados, após passarem por um pré-processamento, formam o arquivo de entrada para a rede neural que faz a análise da viabilidade de energização de circuitos. A árvore de decisão extrai regras do mesmo conjunto de dados, apresentando ao operador a linha de raciocínio utilizada na solução do problema. Além disso, na fase de projeto, a árvore é capaz de auxiliar na seleção dos atributos de entrada para a rede neural. A figura 7 apresenta a arquitetura proposta.

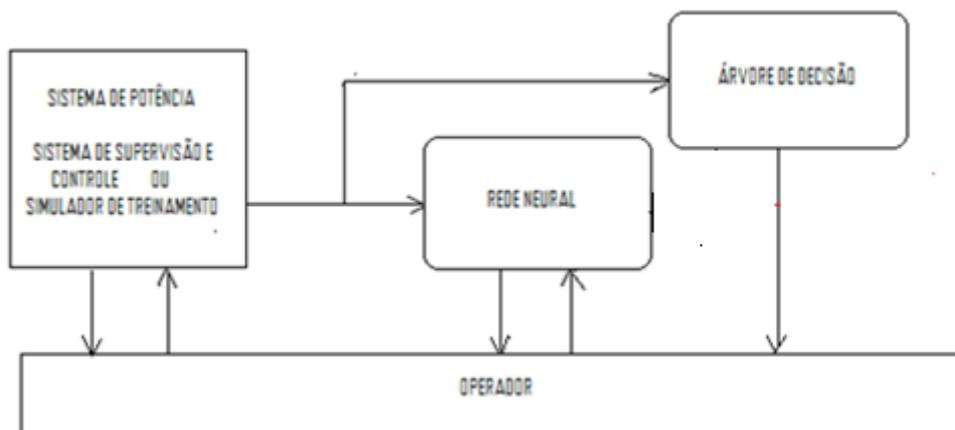


Figura 8 – Arquitetura do Sistema Híbrido

III.8 Etapas de desenvolvimento do projeto

Baseado na metodologia apresentada no item III.6 o desenvolvimento da ferramenta de apoio compreendeu as seguintes etapas

III.8.1 – Estudos de regime permanente e transitórios eletromagnéticos

Inicialmente estudos de regime permanente são executados para o sistema teste, utilizando o programa ANAREDE. Através destas simulações de fluxo de potência são determinadas as tensões máximas de energização de todos os circuitos, de forma que os limites de tensão no final da linha após a energização não sejam violados. Foi utilizado o valor de 110% como o valor máximo admissível de tensão no final da linha após a energização. Este valor foi baseado nos atuais critérios normalmente adotados no sistema elétrico brasileiro, conforme Procedimentos de Rede (Tabela 1).

Tabela 1 – Níveis de tensão aceitáveis em regime permanente para estudos de recomposição das regiões Sul, Sudeste e Centro-Oeste

Tensão Nominal de Operação (kV)	Fase Fluente (%)		Fase Coordenada (%)	
	Mínimo	Máximo	Mínimo	Máximo
≤ 138	90	110	90	105
230	90	110	90	110
345	90	110	90	110
440	90	110	90	110
500	90	110	90	110
765	90	104,6	90	104,6

É importante observar que para a simulação de energização de cada circuito são analisadas diversas configurações do sistema elétrico, combinando diversos números de máquinas em operação em cada usina, diversas configurações de rede e indisponibilidades de reatores. O fato de estes estudos serem realizados na fase de planejamento da operação permite que um grande número de combinações de configurações sejam analisadas e os resultados das simulações armazenados.

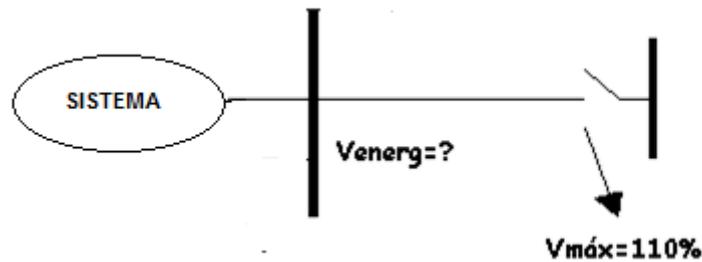


Figura 9 - Tensão máxima no extremo da linha

Numa segunda etapa, para as condições que são definidas na análise de regime permanente, representando a energização com sucesso, são realizados estudos de TRANSITÓRIOS ELETROMAGNÉTICOS utilizando o programa ATP (Alternative Transient Program) [26], com a análise estatística de 100 casos e detalhamento daqueles que apresentaram as maiores sobretensões, sendo utilizado um tempo mínimo de análise de 300ms e um Time step de 50 μ s. Os estudos estatísticos preliminares são realizados para representar as características probabilísticas dos equipamentos de manobra tais como a aleatoriedade dos instantes de fechamento do disjuntor.

Nestes estudos foram utilizadas as seguintes representações para os equipamentos:

- Fonte senoidal constante atrás de reatância subtransitória (modelo 14 do ATP);
- Linhas por parâmetros distribuídos, invariantes com a frequência e idealmente transpostas (modelo -1,-2,-3 do ATP);
- Pára-raios da linha ZnO (modelo 92 do ATP) ou com gap;
- Transformadores com a sua curva de saturação.

São analisadas as sobretensões na linha e em barramentos mais próximos para verificar a possibilidade de ocorrer atuação de alguma proteção de sobretensão e verificada a energia dissipada em pára-raios da linha e/ou tensão de disparo de pára-raios convencionais. No caso de alguma violação foram reduzidos os valores da tensão de pré-energização para aquela condição de sistema e efetuadas novas simulações.

Os resultados destes estudos realizados na fase de planejamento da operação contemplando um grande número de combinações de configuração do sistema são armazenados para posteriormente compor o conjunto de dados de entrada para treinamento da rede neural. Esta etapa de desenvolvimento pode ser resumida no diagrama de blocos da figura 10:

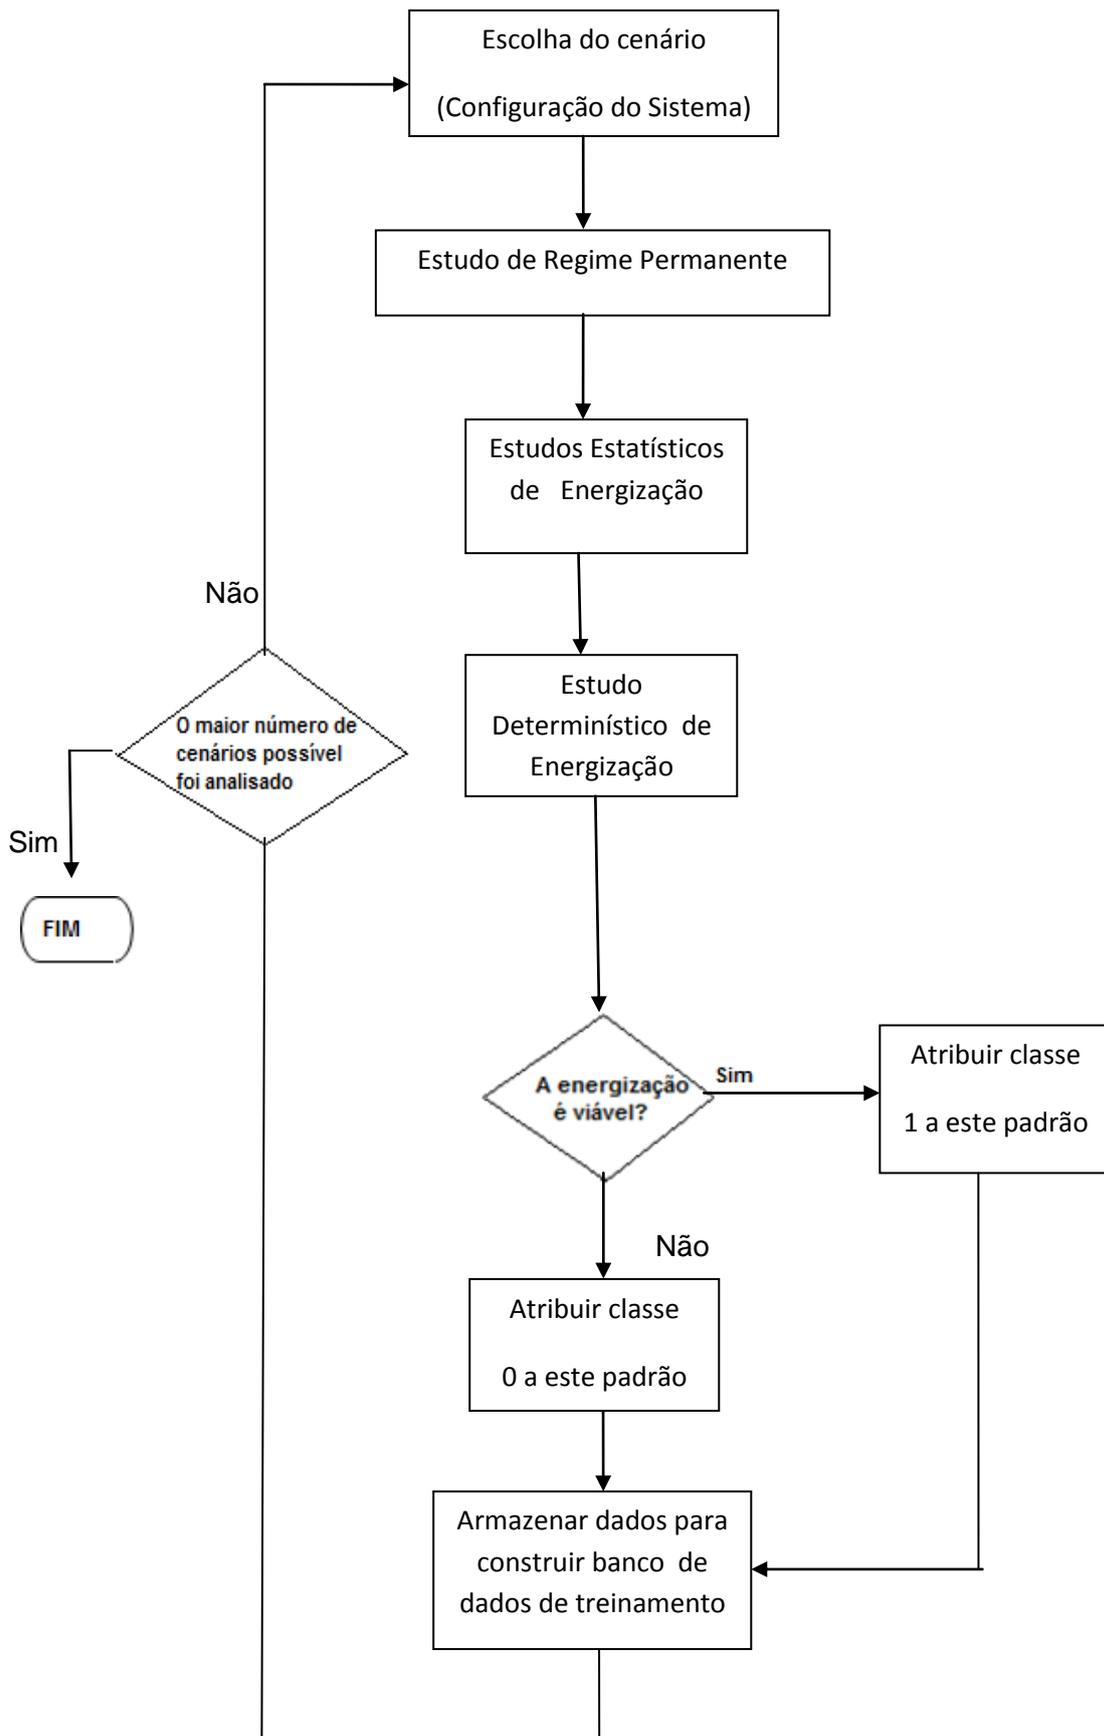


Figura 10 – Diagrama de blocos da primeira etapa de projeto

III.8.2 – Seleção de variáveis de entrada para a rede neural

É de grande importância a seleção adequada de características que irão compor os padrões de treinamento do classificador de forma a se obter um subespaço de menor dimensão possível, mas que preserve o poder de discriminação das classes. Esta redução de dimensionalidade é justificada por ela simplificar a tarefa de classificação.

Diferentemente de outros problemas de reconhecimento de padrões o conhecimento do domínio do problema permitiu, conforme abordado no capítulo II, que fosse elencado um conjunto de atributos que interferem no resultado da classificação. Foi necessário realizar a seleção de variáveis que irão compor o vetor padrão de entrada e então construir o arquivo de entrada para treinar a rede neural.

Dentre os atributos selecionados, que influenciam nos valores das sobretensões transitórias resultantes da energização de linhas de transmissão, alguns deles tais como as características construtivas da linha (condutor, comprimento, transposição, etc...), características de disjuntores e pára-raios não são variáveis para um mesmo circuito. A aleatoriedade do instante de fechamento do disjuntor é tratada através da análise estatística da energização na fase de estudo. Outros fatores tais como valor da tensão de pré-energização, configuração do sistema, carregamento do circuito paralelo e a presença ou não de reatores manobráveis no extremo da linha variam de acordo com a ocasião e o tipo de distúrbio sendo consideradas como variáveis de entrada para a rede neural classificar a energização.

Os elementos dos vetores padrões de entrada são então definidos como os valores das grandezas elétricas presentes na operação do sistema, as tensões em barramentos e a configuração do sistema. Na análise da configuração do sistema deve-se considerar o número de máquinas em usinas, se o sistema está completo ou não, ou seja, se a perturbação foi isolada, parcial ou total. Algumas vezes a avaliação

desta configuração pode ser feita indiretamente através da medição e combinação de grandezas como fluxo de potência ativa em pontos específicos, ao invés de combinação de estado de disjuntores e chaves. No item IV.4 será dado um exemplo desta abordagem onde uma árvore de decisão foi utilizada, como forma de selecionar os atributos necessários a identificação da configuração do sistema, com resultados bastante aceitáveis.

Em situações onde não se tenha nenhum conhecimento do domínio do problema a árvore de decisão pode ser utilizada para fazer a seleção inicial de atributos.

III.8.3 – Projeto da rede neural classificadora

O objetivo da rede neural é informar se o elemento do sistema (linha de transmissão) pode ser ou não restabelecido a partir de um dado padrão do mesmo. Conforme citado neste capítulo as redes neurais têm excelente desempenho para classificação de padrões complexos, capacidade de generalização e principalmente rapidez de resposta em formato simples o que justifica a sua aplicação ao problema de restabelecimento de sistemas elétricos de potência.

A rede neural utilizada apresenta a seguinte estrutura:

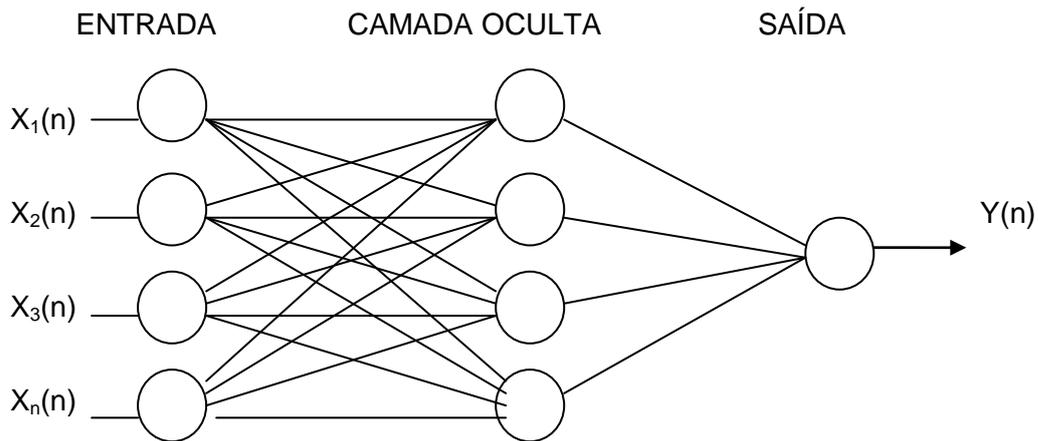


Figura 11 - Arquitetura da rede neural

Onde:

$X(n)$ = vetor padrão de entrada

$Y(n)$ = saída da rede neural, ou seja, a classe 1 (energização viável) ou classe 0 (energização não permitida)

O vetor padrão de entrada é composto dos atributos selecionados que representam os valores das grandezas elétricas presentes na operação do sistema, as tensões em barramentos e a configuração do sistema. Os valores destes atributos para os diferentes exemplares de treinamento da rede neural são obtidos a partir dos dados armazenados resultantes dos estudos de regime permanente e transitórios eletromagnéticos.

Algumas destas variáveis de entrada tais como número de máquinas em operação em cada usina são discretas, outras como tensão máxima de energização são contínuas e foram discretizadas para compor o vetor padrão de entrada. Considerou-se que a tensão no barramento varia de 0,9 a 1,1 pu que representam os níveis de tensão aceitáveis em regime permanente para estudos de recomposição conforme tabela 1.

Os valores abaixo da tensão máxima de energização foram discretizados com um intervalo de 0,01 pu e passam a compor exemplos de padrão de treinamento da classe 1 (energização viável) enquanto que acima deste valor discretizados da mesma maneira constituem exemplos de padrão de treinamento da classe 0 (energização não viável).

Além da eliminação de variáveis redundantes já realizada é importante que os dados de entrada para a rede neural sejam normalizados de forma a melhorar o desempenho do classificador. Os dados de entrada foram normalizados no intervalo de -1 a 1.

O conjunto de dados de entrada disposto de maneira aleatória foi subdividido em um conjunto de treinamento, validação e teste. Com esta escolha se evita o supertreinamento e memorização dos dados durante o treinamento e possibilita a rede neural ser capaz de classificar os dados corretamente, provando assim sua capacidade de generalização. Além disso, o conjunto de dados de treinamento da rede neural deve ser suficientemente grande de forma a ser representativo do problema e o erro de classificação minimizado.

Foram simuladas diversas arquiteturas com diversos números de neurônios na camada escondida sendo escolhida a que maximizou o percentual de acerto no conjunto de teste.

Após o treinamento a rede é capaz de confirmar ou não a possibilidade de energização do circuito sem a necessidade de execução de estudos de regime permanente e de transitórios eletromagnéticos no instante da consulta, uma vez que diversas combinações de configuração de rede e tensão de energização já foram estudadas e analisadas previamente. Além disso, a rede tem capacidade de generalização, ou seja, é capaz de inferir resultados para casos não analisados previamente, para os quais não foi treinada, desde que não sejam condições limites, com índice de acertos superior a 97%.

III.8.4 – Extração de regras utilizando árvore de decisão

Em algumas aplicações onde a segurança é fator primordial, em especial aplicações de apoio à tomada de decisão em tempo real, é imprescindível que se forneça alguma informação que possibilite o entendimento da solução encontrada, para aumentar a confiança do usuário neste resultado obtido.

Com esta finalidade foi utilizado um módulo composto de uma árvore de decisão para se extrair as regras de decisão. Este módulo é alimentado pelo mesmo conjunto de dados de entrada da rede neural passando por um pré-processamento para torná-lo compatível com a ferramenta utilizada (formato ARFF). Este pré-processamento basicamente consiste de duas partes. A primeira contém a lista de todos os atributos onde devemos definir o tipo do atributo ou os valores que ele pode representar e a segunda parte compreende os registros com os valores dos atributos. O arquivo ARFF tem a seguinte estrutura:

@relation nome_do_conjunto_de_dados

@attribute x1 {valor1,valor2,valor3}

@attribute x2 real

@attribute x3 {verdadeiro,falso}

@attribute x4 {sim,não}

@data e nas próximas linhas colocamos os registros onde cada linha representa um registro.

Foi utilizado o programa WEKA que consiste de uma coleção de algoritmos para mineração de dados e extração de informações a partir dos dados de entrada. Para gerar a árvore de decisão foi utilizado o algoritmo C4.5, implementado em sua versão para linguagem Java no WEKA com o nome J4.8.

As etapas de desenvolvimento descritas nos itens III.8.2 a III.8.4 podem ser resumidas no seguinte diagrama de blocos:

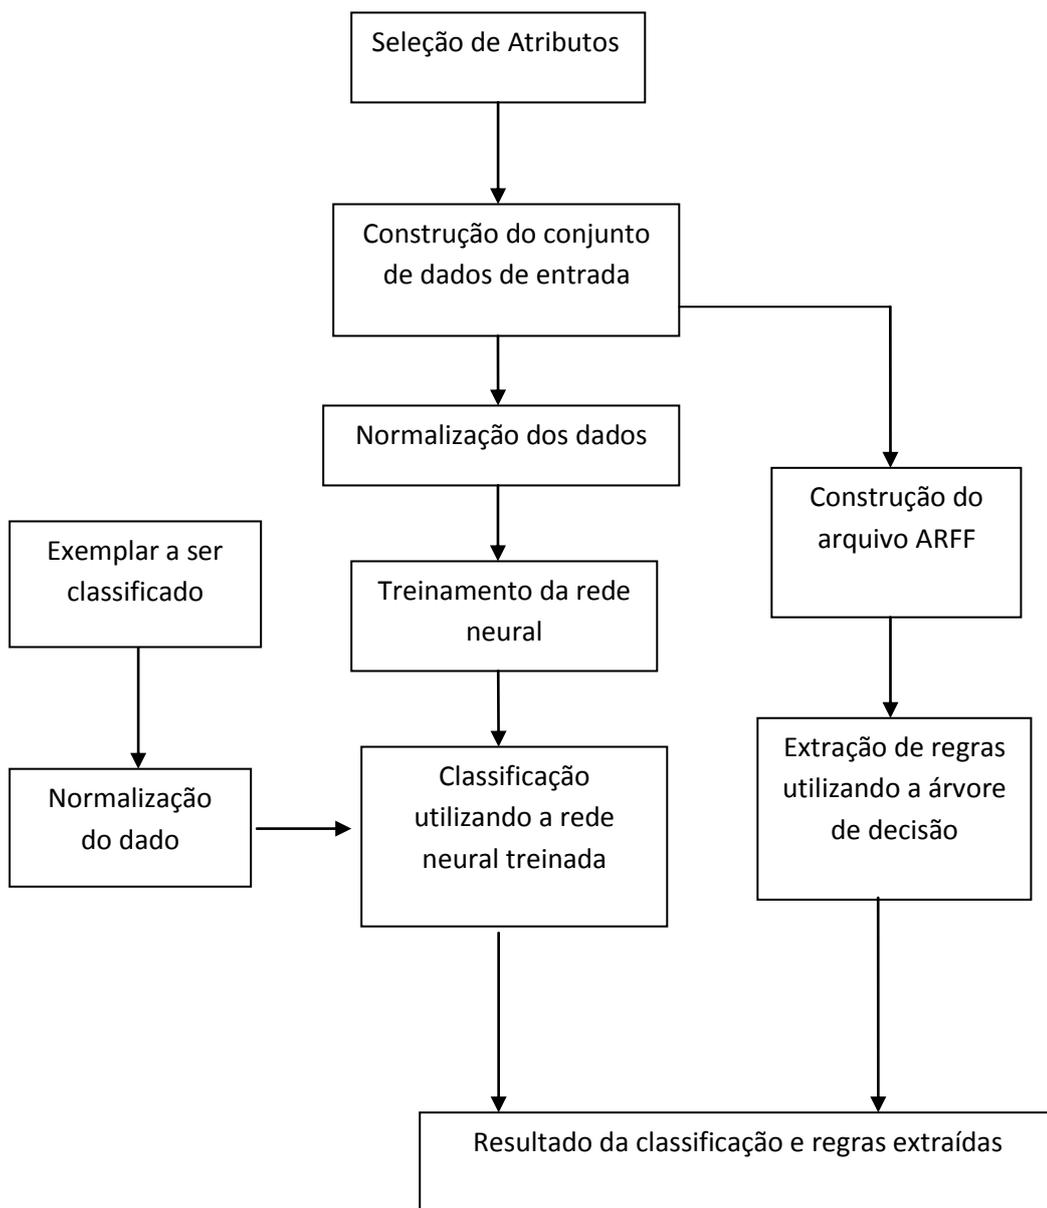


Figura 12 – Diagrama de blocos das etapas finais

III.9 Sumário do Capítulo

Neste capítulo foi apresentado o Sistema Híbrido proposto para apoio a decisão no processo de Restabelecimento de Sistemas Elétricos de Potência composto de uma rede neural e uma árvore de decisão. A metodologia de projeto envolve estudos de regime permanente, transitórios eletromagnéticos, construção e treinamento da rede neural e utilização de uma árvore de decisão.

CAPÍTULO IV

RESULTADOS OBTIDOS

IV.1 Considerações Iniciais

Neste capítulo são apresentados resultados obtidos pela aplicação da metodologia. Com este propósito inicialmente foi utilizado o sistema teste 1, entretanto houve necessidade de comprovar a eficácia da metodologia para sistemas mais complexos. Para isso foram realizadas algumas modificações no sistema 1 que resultaram no sistema teste 2. Finalmente com o propósito de observar o comportamento da metodologia e comparar resultados de extração de regras foi utilizado um tronco de sistema de transmissão numa configuração antiga de estudo.

IV.2 Sistema Teste 1

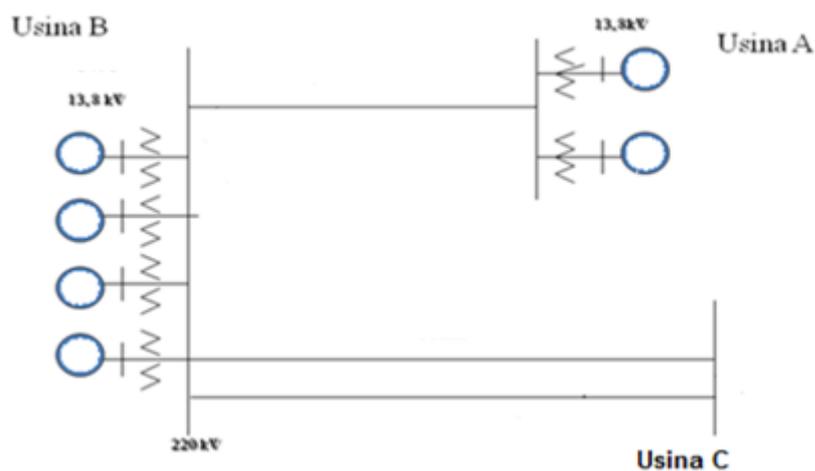


Figura 13 – Configuração do sistema teste 1

A configuração do sistema teste 1 é mostrada na figura 12. A análise deste sistema iniciou-se com a realização de estudos de regime permanente utilizando-se o programa ANAREDE. A recomposição fluente deste sistema inicia-se na usina A e o objetivo é alimentar cargas na Usina C. Os estudos foram realizados para determinar as tensões máximas de energização de cada circuito de forma a não ultrapassar o limite de 110% no extremo da linha após a energização conforme critérios vigentes. É importante observar que para cada circuito foram analisadas diversas configurações do sistema elétrico, combinando diversos números de máquinas em operação em cada usina e diversas configurações de rede.

Além disso, houve uma preocupação de também verificar as tensões máximas de energização que em caso de perturbação geral permitam a energização fluente de circuitos, ou seja, o valor máximo de tensão na usina A que permita a energização fluente até a usina C sem que após as energizações a tensão no extremo da linha que interliga as Usinas B e C ultrapasse o valor máximo admissível.

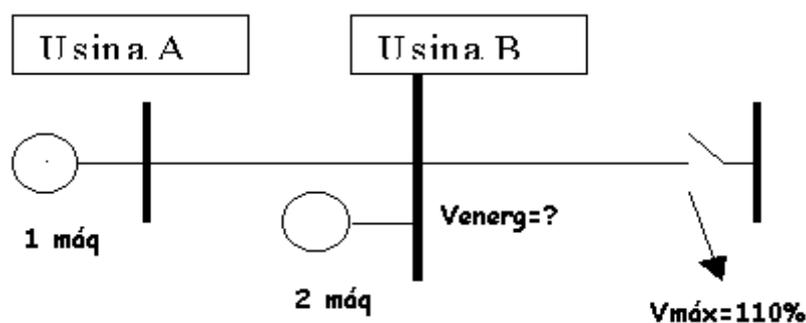


Figura 14 – Tensão máxima de energização

Um resumo destas simulações está transcrito na tabela 2:

Tabela 2 – Resultados dos estudos de regime permanente para as energizações de linhas de transmissão no sistema teste 1

Condição inicial		Tensão na ponta da linha em vazio após a energização	Observações	Configuração
Usina A	Usina B			
1,018	-	1,041	$V_{13,8}=0,95$	
1,032	1,041	1,106	$V_{13,8}=0,95$	
1,077	-	1,10	$V_{13,8}=1,00$	
1,083	-	1,099	$V_{13,8}=1,01$	

Condição inicial		Tensão na ponta da linha em vazio após a energização	Observações	Configuração
Usina A	Usina B			
1,035	-	1,050	$V_{13,8} = 0,965$	
1,041	1,050	1,105	$V_{13,8} = 0,965$	
1,042	1,055	1,10	$V_{13,8} = 0,95$	
1,042	1,063	1,10	$V_{13,8} = 0,95$	
1,045	1,069	1,10	$V_{13,8} = 0,95$	

Condição inicial		Tensão na ponta da linha em vazio após a energização	Observações	Configuração
Usina A	Usina B			
1,046	1,072	1,10	$V_{13,8}=0,95$	
1,041	1,057	1,10	$V_{13,8}=0,98$	
1,048	1,066	1,10	$V_{13,8}=0,98$	
1,051	1,071	1,10	$V_{13,8}=0,98$	
1,053	1,074	1,10	$V_{13,8}=0,98$	

Condição inicial		Tensão na ponta da linha em vazio após a energização	Observações	Configuração
Usina A	Usina B			
1,01	1,05	1,10	$V_{13,8} = 0,9$	
1,012	1,061	1,10	$V_{13,8} = 0,9$	
1,014	1,066	1,10	$V_{13,8} = 0,9$	
1,015	1,07	1,10	$V_{13,8} = 0,9$	
1,014	1,056	1,10	$V_{13,8} = 0,94$	

Condição inicial		Tensão na ponta da linha em vazio após a energização	Observações	Configuração
Usina A	Usina B			
1,017	1,064	1,10	$V_{13,8} = 0,94$	
1,018	1,068	1,10	$V_{13,8} = 0,94$	
1,019	1,071	1,10	$V_{13,8} = 0,94$	

Após a determinação das tensões máximas de energização foi necessário verificar a existência de sobretensões transitórias que pudessem ocasionar operações de proteções de sobretensão. Foi considerado o valor de 125% para ajuste da proteção de sobretensão da linha. Além disso, foi verificada a energia dissipada em pára-raios da linha e/ou tensão de disparo de pára-raios convencionais. No caso de alguma

violação foram reduzidos os valores da tensão de energização para a configuração do sistema em análise e efetuadas novas simulações.

Os estudos de transitórios eletromagnéticos foram realizados utilizando o programa ATP (Alternative Transient Program), com a análise estatística de 100 casos e detalhamento daqueles que apresentaram as maiores sobretensões, sendo utilizado um tempo mínimo de análise de 300ms e um Time step de 50 μ s. Os estudos estatísticos preliminares foram realizados para representar as características probabilísticas dos equipamentos de manobra como por exemplo, a aleatoriedade dos instantes de fechamento do disjuntor.

Os resultados destas simulações encontram-se no anexo A.2.

Tendo sido realizados os estudos contemplando o maior número possível de cenários e armazenados os valores dos diversos atributos que influenciam na classificação conforme item III.8.2. Os valores destes atributos formam os vetores - padrões de entrada que compõem os conjuntos de treinamento e teste da rede neural. É importante ressaltar que todos os dados de entrada foram normalizados para um melhor resultado.

Para o sistema teste 1 a rede neural apresenta a seguinte estrutura:

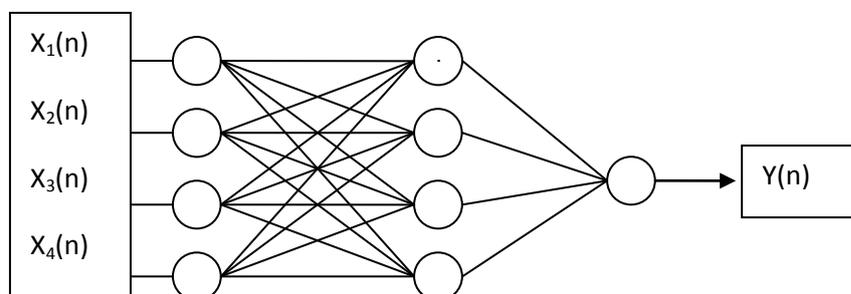


Figura 15 - Arquitetura da rede neural proposta para a LT UsinaB-UsinaC

Onde :

$X(n)$ representa o vetor padrão da entrada n ;

$X_1(n)$ representa o número de máquinas na Usina A;

$X_2(n)$ representa o número de máquinas na Usina B;

$X_3(n)$ o módulo da tensão no barramento onde vai ser fechado o disjuntor;

$X_4(n)$ a configuração do sistema em operação e

$Y(n)$ a saída da rede ou seja se o circuito pode (classe=1) ou não (classe=0) ser energizado

É interessante observar que X_1 , X_2 e X_4 são variáveis discretas e X_3 é obtida de uma variável contínua. A variável X_1 pode assumir os valores 1 ou 2, a variável X_2 pode assumir os valores 0,1,2,3 ou 4 e a variável X_4 será 1 se o restante do sistema estiver completo 0 caso contrário.

Já a variável X_3 é obtida a partir do valor máximo de tensão de energização. Considerou-se que a tensão no barramento varia na faixa de 0,9 pu a 1,10 pu. Os valores abaixo da tensão máxima de energização foram discretizados com um intervalo de 0,01pu e passam a compor exemplos de padrões de treinamento da classe 1.

Os valores acima da tensão máxima de energização foram discretizados com um intervalo de 0,005pu e passam a compor exemplos de padrões de treinamento da classe 0. Esse intervalo menor foi utilizado para melhor balancear os exemplos de treinamento.

A metodologia é repetida para cada configuração da rede sendo obtidos 464 padrões de treinamento. Esse conjunto de dados foi disposto de maneira aleatória sendo

utilizados 80 % destes padrões para treinamento da rede neural e os 20 % restantes para teste.

Utilizou-se uma rede neural feedforward, com algoritmo de treinamento backpropagation, no qual os pesos são ajustados baseados na regra de aprendizagem por correção de erro. A rede foi modelada e executada no software Matlab, estruturada em três camadas, ou seja, apenas uma camada oculta foi utilizada. A camada de entrada é formada por quatro neurônios, um para cada variável de entrada da rede. O número de neurônios da camada oculta foi determinado pela configuração que apresentou o menor erro no conjunto de teste. A rede foi treinada utilizando o método TRAINLM (Levenberg-Marquardt backpropagation) e o critério de parada foi MSE (erro quadrático médio).

A função tangente hiperbólica foi utilizada como a função de ativação para os neurônios da camada oculta e de saída. Na camada de saída há apenas um neurônio. Além disso, na saída foi utilizado um comparador e seu limiar ajustado da seguinte forma:

Se Saída ≥ 0 a classe é 1 ou seja energização viável

Se saída < 0 , então a energização não é viável

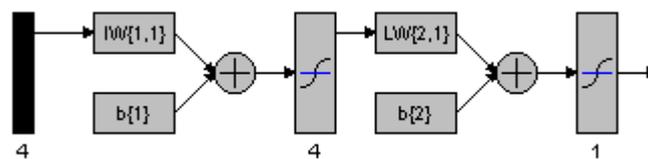


Figura 16 - Rede neural MLP

Essa rede é capaz de rapidamente permitir ou não a energização do circuito baseada na configuração do sistema e tensão de energização. Os resultados obtidos foram:

Tabela 3 – Erro de classificação da rede neural UsinaB - UsinaC

Neurônios na camada escondida	MSE	Erro Absoluto	Erro %
3	0,0213	3	3,3%
4	0,00099	1	1%
5	0,00094	2	2,2%
6	0,00027	3	3,3%
7	0,0420	4	4,4%

Finalmente, para verificar como uma rede se comporta para casos em que ela não foi treinada (capacidade de generalização) a rede foi treinada utilizando a seguinte combinação de configuração de máquinas na Usina A e B.

Tabela 4 – Configuração de máquinas nas Usinas A e B consideradas

<i>Nº de máquinas na Usina A</i>	<i>Nº de máquinas na Usina B</i>
<i>1</i>	<i>0</i>
<i>1</i>	<i>1</i>
<i>1</i>	<i>2</i>
<i>1</i>	<i>4</i>

Para testar a generalização da rede, no conjunto de teste foram incluídos 26 casos para os quais a rede não foi treinada (3 máquinas na Usina B e 1 máquina na Usina A). O conjunto de teste assim construído foi composto de 46 exemplares no total, não utilizados no treinamento da rede. O resultado mostrou a boa capacidade de generalização da rede tendo sido obtido 100% de acertos nos exemplares com combinação de número de máquinas treinadas e 3,8% de erro (1 caso) nos exemplares com combinação de número de máquinas não treinadas.

A seguir utilizando o WEKA foram extraídas as regras do banco de dados utilizado para treinamento da rede neural:

A árvore extraída do banco de dados para classificação da energização da linha que interliga a Usina A a Usina B pode ser representada da seguinte forma:

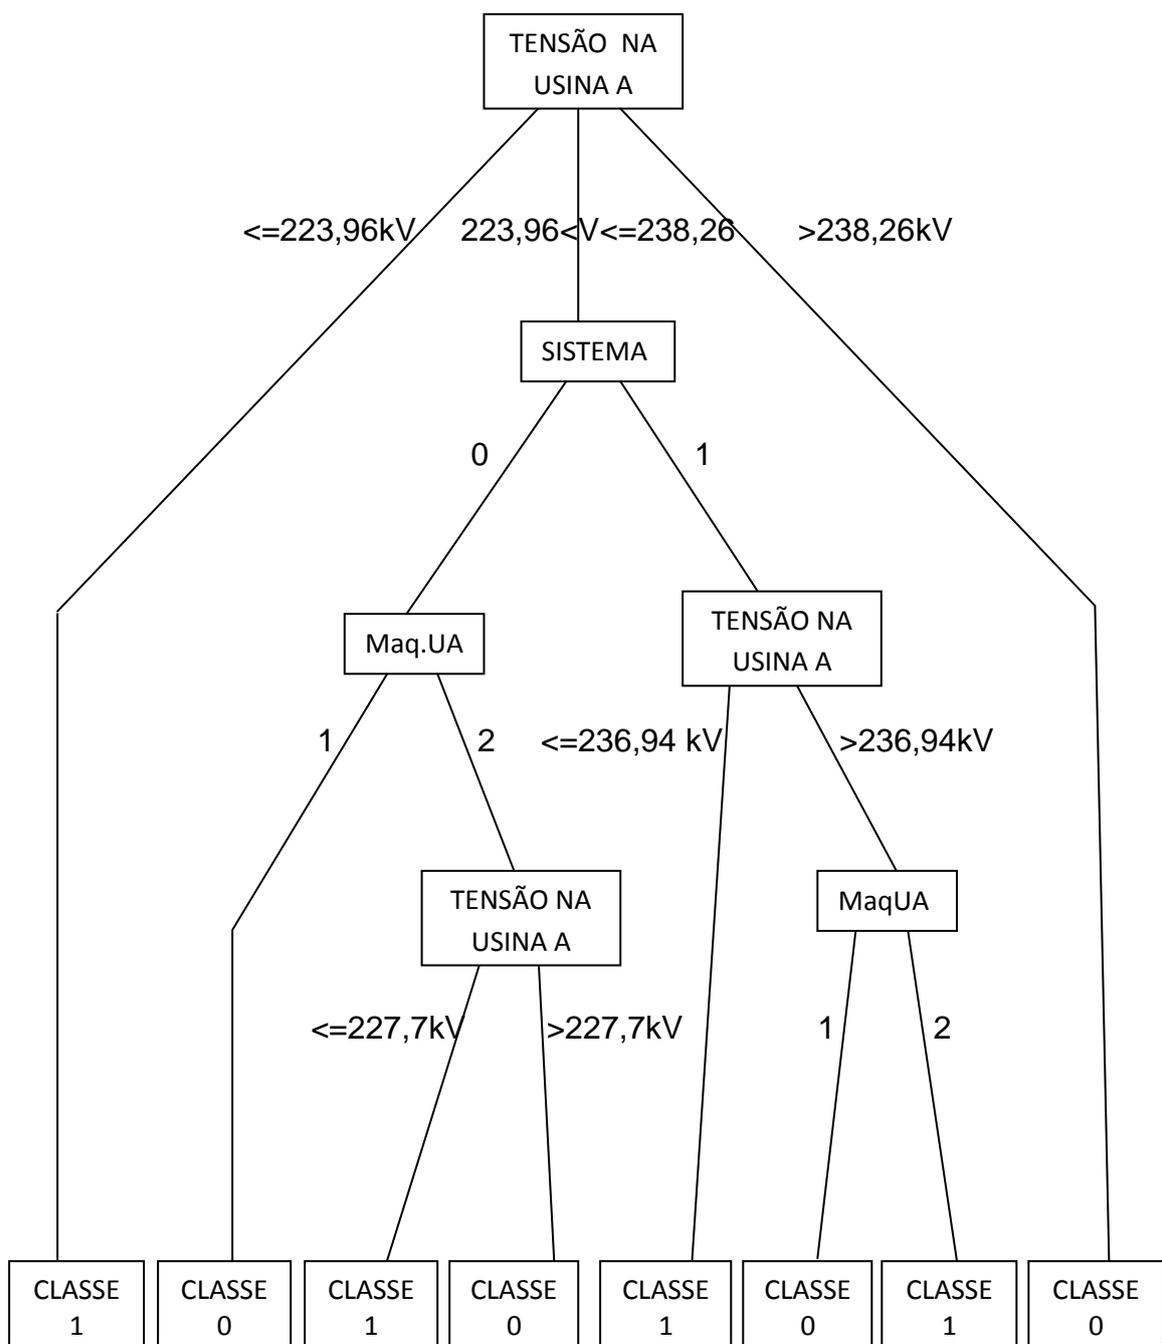


Figura 17 - Árvore de decisão extraída do banco de dados para classificação da energização da linha que interliga a Usina A a Usina B

Dessa árvore podem ser extraídas as seguintes regras:

Regra 1: Se a tensão for menor ou igual a 223,96kV então

a energização é possível

Regra 2: Se a tensão for maior que 238,26kV então

a energização é inviável

Regra 3: Se a tensão for maior que 223,96kV e menor ou igual a 238,26kV e

o sistema não estiver completo e

apenas 1 máquina estiver em operação na Usina A então

a energização é inviável

Regra 4: Se a tensão for maior que 223,96kV e menor ou igual a 238,26kV e

o sistema não estiver completo e

2 máquinas estiverem em operação na Usina A e

a tensão for menor ou igual a 227,7kV então

a energização é viável

Regra 5: Se a tensão for maior que 223,96kV e

menor ou igual a 238,26kV e

o sistema não estiver completo e

2 máquinas estiverem em operação na Usina A e

a tensão for maior que 227,7kV então

a energização é inviável

Regra 6: Se a tensão for maior que 223,96kV e

menor ou igual a 238,26kV e

o sistema estiver completo e

a tensão menor ou igual a 236,94kV então

a energização é viável

*Regra 7: Se a tensão for maior que 223,96kV e
menor ou igual a 238,26kV e
o sistema estiver completo e
a tensão maior que 236,94kV e
apenas 1 máquina estiver em operação na Usina A
a energização é inviável*

*Regra 8: Se a tensão for maior que 223,96kV e menor ou igual a 238,26kV e
o sistema estiver completo e
a tensão maior que 236,94kV e
2 máquinas estiverem em operação na Usina A então
a energização é viável*

Naturalmente algumas destas regras lidas diretamente da árvore podem ser simplificadas da seguinte forma:

*Regra 4: Se a tensão for maior que 223,96kV e menor ou igual a 227,7kV e
o sistema não estiver completo e
2 máquinas estiverem em operação na Usina A
a energização é viável*

*Regra 5: Se a tensão for maior que 227,7kV e menor ou igual a 238,26kV e
o sistema não estiver completo e
2 máquinas estiverem em em operação na Usina A então
a energização é inviável*

*Regra 6: Se a tensão for maior que 223,96kV e menor ou igual a 236,94kV e
o sistema estiver completo então*

a energização é viável

*Regra 7: Se a tensão for maior que 236,94kV e menor ou igual a 238,26kV e
o sistema estiver completo e
apenas 1 máquina estiver em operação na Usina A então
a energização é inviável*

*Regra 8: Se a tensão for maior que 236,94kV e menor ou igual a 238,26kV e
o sistema estiver completo e
2 máquinas estiverem em operação na Usina A então
a energização é viável*

As regras 1, 4, 6 e 8 expressam as condições que permitem a energização do circuito que interliga a Usina A a Usina B:

A ENERGIZAÇÃO É VIÁVEL SE

A tensão for menor ou igual a 223,96kV OU

A tensão for maior que 223,96kV e menor ou igual a 227,7kV E

o sistema não estiver completo E

2 máquinas estiverem em operação na Usina A OU

A tensão for maior que 223,96kV e menor ou igual a 236,94kV E

o sistema estiver completo OU

Se a tensão for maior que 236,94kV e menor ou igual a 238,26kV E

o sistema estiver completo E

2 máquinas estiverem em operação na Usina A

IV.3 Sistema Teste 2

A configuração do sistema teste 2 é mostrada na figura 17 .Foi incluído um reator na LT que interliga as Usinas A e B e criada a SE-2 seccionando a linha que interliga a Usina B a SE-1 . Os estudos foram realizados com os mesmos critérios utilizados para o sistema teste 1. O objetivo foi avaliar o desempenho da ferramenta proposta para um sistema de maior complexidade.

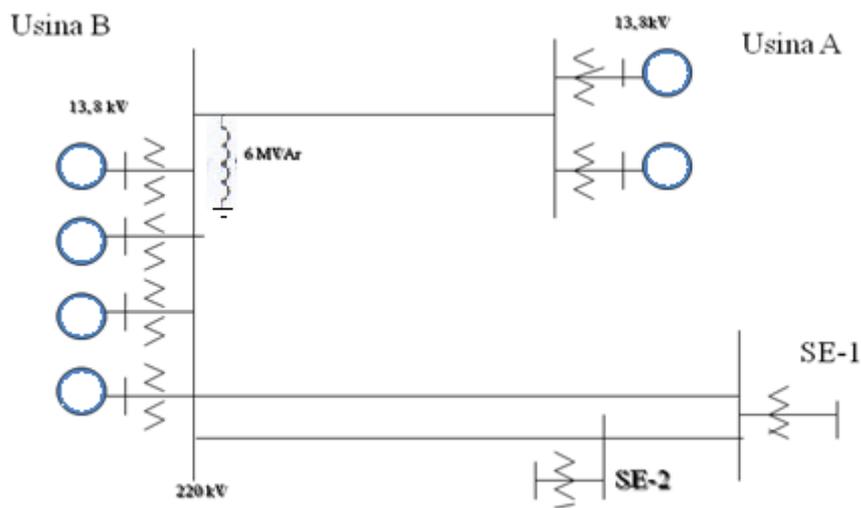


Figura 18 – Configuração do sistema teste 2

O resultado das simulações para o sistema teste 2 utilizando o programa ANAREDE seguindo os mesmos critérios utilizados para o sistema 1 descritos no item IV.2 estão resumidos na tabela a seguir:

Tabela 5 – Resultados dos estudos de regime permanente para as energizações de linhas de transmissão no sistema teste 2

Condição inicial				Tensão na ponta da linha em vazio após energização	Observações	Configuração
Usina A	Usina B	SE-1	SE-2			
1,097	-	-	-	1,104	$V_{13,8} = 1,05$	
1,045	-	-	-	1,051	$V_{13,8} = 1,0$	
1,049	1,051	-	-	1,107	$V_{13,8} = 1,0$	
1,049	1,051	-	-	1,099	$V_{13,8} = 1,0$	

Condição inicial				Tensão na ponta da linha em vazio após energização	Observações	Configuração
Usina A	Usina B	SE-1	SE-2			
1,058	1,084	-	1,099	1,107	$V_{13,8} = 1,0$	
1,022	1,049	1,068	-	1,099	$V_{13,8} = 0,965$	
1,023	1,053	1,106	-	1,107	$V_{13,8} = 0,965$	
1,087	-	-	-	1,097	$V_{13,8} = 1,04$	

Condição inicial				Tensão na ponta da linha em vazio após energização	Observações	Configuração
Usina A	Usina B	SE-1	SE-2			
1,024				1,034	$V_{13,8} = 0,98$	
1,032	1,034	-	-	1,099	$V_{13,8} = 0,98$	
1,047	1,052	-		1,096	$V_{13,8} = 1,0$	
1,047	1,052	-	-	1,09	$V_{13,8} = 1,0$	

Condição inicial				Tensão na ponta da linha em vazio após energização	Observações	Configuração
Usina A	Usina B	SE-1	SE-2			
1,053	1,074	-	1,090	1,096	$V_{13,8} = 1,0$	
1,035	1,062	-	-	1,101	$V_{13,8} = 0,98$	
1,041	1,085	-	1,101	1,108	$V_{13,8} = 0,98$	
1,053	1,064	--	--	1,103	$V_{13,8} = 1,0$	

Condição inicial				Tensão na ponta da linha em vazio após energização	Observações	Configuração
Usina A	Usina B	SE-1	SE-2			
1,053	1,064	--	--	1,103	$V_{13,8} = 1,0$	
1,058	1,081	--	1,097	1,103	$V_{13,8} = 1,0$	
1,049	1,07	1,09	--	1,104	$V_{13,8} = 1,0$	
1,045	1,082		1,10	1,104	$V_{13,8} = 0,99$	

Condição inicial				Tensão na ponta da linha em vazio após energização	Observações	Configuração
Usina A	Usina B	SE-1	SE-2			
1,047	1,071			1,107	$V_{13,8} = 1,0$	
1,047	1,071			1,106	$V_{13,8} = 1,0$	
1,05	1,084		1,099	1,105	$V_{13,8} = 1,0$	
1,047	1,072	1,091		1,102	$V_{13,8} = 1,0$	

Condição inicial				Tensão na ponta da linha em vazio após energização	Observações	Configuração
Usina A	Usina B	SE-1	SE-2			
1,049	1,080		1,099	1,10	$V_{13,8} = 1,0$	
1,044	1,076			1,108	$V_{13,8} = 1,0$	
1,044	1,076			1,108	$V_{13,8} = 1,0$	
1,046	1,082		1,098	1,103	$V_{13,8} = 1,0$	

Condição inicial				Tensão na ponta da linha em vazio após energização	Observações	Configuração
Usina A	Usina B	SE-1	SE-2			
1,042	1,068	1,087	1,096	$V_{13,8} = 1,0$		
1,046	1,080	1,096	1,101	$V_{13,8} = 1,0$		

Após a determinação das tensões máximas de energização foi necessário verificar a existência de sobretensões transitórias que pudessem ocasionar operações de proteções de sobretensão. Foi considerado o valor de 125% para ajuste da proteção de sobretensão da linha. Além disso, foi verificada a energia dissipada em pára-raios da linha e/ou tensão de disparo de pára-raios convencionais. No caso de alguma violação foram alterados os valores da tensão de pré-energização para aquela condição de sistema e efetuadas novas simulações.

Os estudos de transitórios eletromagnéticos foram realizados utilizando o programa ATP (Alternative Transient Program), com a análise estatística de 100 casos e detalhamento daqueles que apresentaram as maiores sobretensões, sendo utilizado um tempo mínimo de análise de 300ms e um Time step de 50 μ s. Os estudos estatísticos preliminares foram realizados para representar as características probabilísticas dos equipamentos de manobra como, por exemplo, a aleatoriedade dos instantes de fechamento do disjuntor.

Os resultados das simulações de transitórios eletromagnéticos utilizando o programa ATP encontram-se no anexo A.3.

Dos resultados dos estudos são extraídos os valores dos diversos atributos que influenciam na classificação para compor os vetores - padrões de entrada dos conjuntos de treinamento e teste da rede neural. É importante ressaltar que todos os dados de entrada foram normalizados para um melhor resultado.

A rede neural para apoio a decisão da energização da LT UsinaA - UsinaB apresenta a seguinte estrutura:

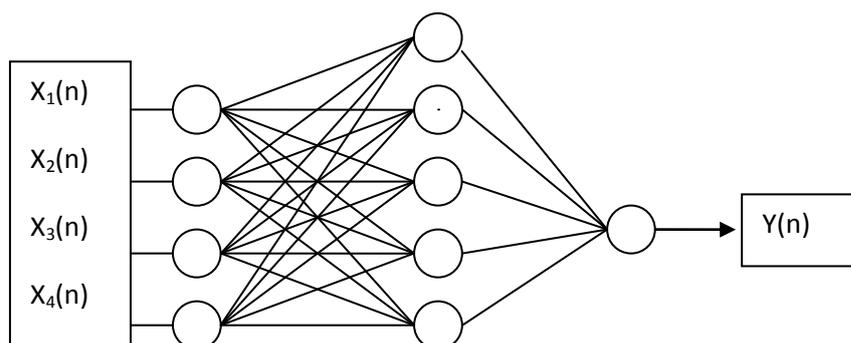


Figura 19 - Arquitetura da rede neural proposta LT UsinaA-UsinaB

Onde :

$X(n)$ representa o vetor padrão da entrada n ;

$X_1(n)$ representa o número de máquinas na Usina A;

$X_2(n)$ representa o módulo da tensão no barramento onde vai ser fechado o disjuntor;

$X_3(n)$ representa a presença ou não do reator da linha ;

$X_4(n)$ a configuração do sistema em operação e

$Y(n)$ a saída da rede ou seja se o circuito pode (classe=1) ou não (classe=0) ser energizado

A variável X_1 pode assumir os valores 1 ou 2, a variável X_3 pode assumir o valor 1 caso o reator esteja presente e 0 caso contrário . A variável X_4 será 1 se o restante do sistema estiver completo, ou seja, a tensão enviada para a usina B servirá para fechamento de paralelo e será 0 caso contrário, ou seja será necessário restabelecer de forma fluente o restante do sistema.

Já a variável X_2 é obtida a partir do valor máximo de tensão de energização. Considerou-se que a tensão no barramento varia na faixa de 0,9 pu a 1,10 pu. Os valores abaixo da tensão máxima de energização foram discretizados com um intervalo de 0,01pu e passam a compor exemplos de padrões de treinamento da classe 1. Os valores acima da tensão máxima de energização foram discretizados com um intervalo de 0,01pu e passam a compor exemplos de padrões de treinamento da classe 0. Próximo a fronteira de decisão foi utilizado um intervalo menor para um melhor resultado de classificação.

.

A metodologia é repetida para cada configuração da rede sendo obtidos 192 padrões de treinamento. Esse conjunto de dados foi disposto de maneira aleatória sendo utilizados 80 % destes padrões para treinamento da rede neural e os 20 % restantes

para validação e teste. Com esta escolha se evita o supertreinamento e memorização de dados durante o treinamento da rede neural.

Essa rede é capaz de rapidamente permitir ou não a energização do circuito baseada na configuração do sistema e tensão de energização. Os resultados obtidos foram:

Tabela 6 – Erro de classificação da rede neural UsinaA-UsinaB

Neuronios na camada escondida	MSE	Erro Absoluto	Erro %
4	0,0000475	5	15%
5	0,0000165	1	3,1%
6	0,0000417	2	6,25%

A seguir utilizando o WEKA foram extraídas as regras do banco de dados utilizado para treinamento das redes neurais:

A árvore extraída do banco de dados para classificação da energização da linha que interliga a Usina A a Usina B pode ser representada da seguinte forma:

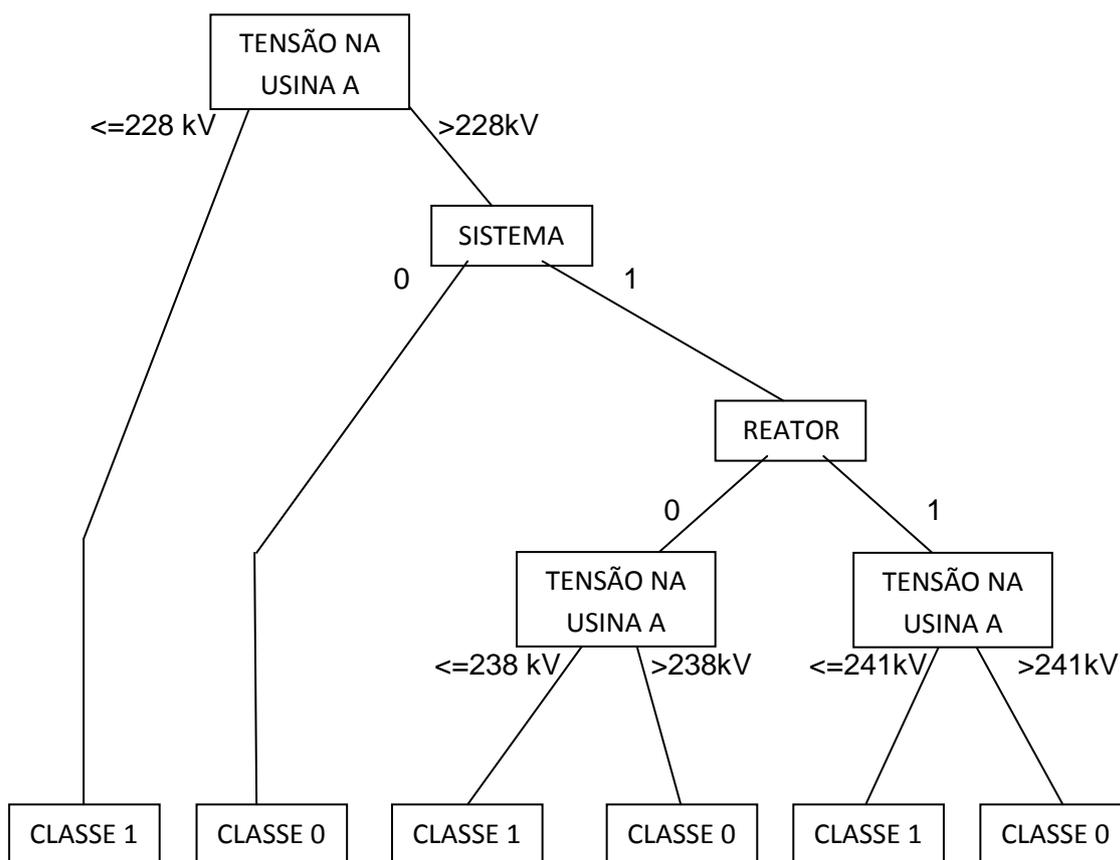


Figura 20 – Árvore de decisão extraída do banco de dados para classificação da energização da linha que interliga a Usina A a Usina B

Dessa árvore podem ser extraídas as seguintes regras:

*Regra 1: Se a tensão for menor ou igual a 228kV então
a energização é possível*

*Regra2: Se a tensão for maior que 228kV e
o sistema não estiver completo então
a energização não é viável*

*Regra3 : Se a tensão for maior que 228kV e
o sistema estiver completo e
o reator não estiver presente e
a tensão for menor ou igual a 238kV então
a energização é viável*

*Regra4 : Se a tensão for maior que 228kV e
o sistema estiver completo e
o reator não estiver presente e
a tensão maior que 238kV então
a energização não é viável*

*Regra 5: Se a tensão for maior que 228kV e
e o sistema estiver completo e
o reator estiver presente e
a tensão for menor ou igual a 241kV então
a energização é viável*

*Regra 6: Se a tensão for maior que 228kV e
o sistema estiver completo e
o reator estiver presente e
a tensão for maior que 241kV então
a energização não é viável*

As regras 4 e 6 podem ser simplificadas e reescritas da seguinte forma:

*Regra 4 : Se a tensão for maior que 238kV e
o sistema estiver completo e*

*o reator não estiver presente então
a energização não é viável*

*Regra 6: Se a tensão for maior que 241kV e
o sistema estiver completo e
o reator estiver presente então
a energização não é viável*

As regras 1, 3 e 5 expressam portanto as condições que permitem a energização do circuito:

A energização é viável SE:

A tensão for menor ou igual a 228kV OU

*A tensão for maior que 228kV E
o sistema estiver completo E
o reator não estiver presente E
a tensão for menor ou igual a 238kV OU*

*A tensão for maior que 228kV E
o sistema estiver completo E
o reator estiver presente E
a tensão for menor ou igual a 241kV .*

IV.4 Sistema Tronco

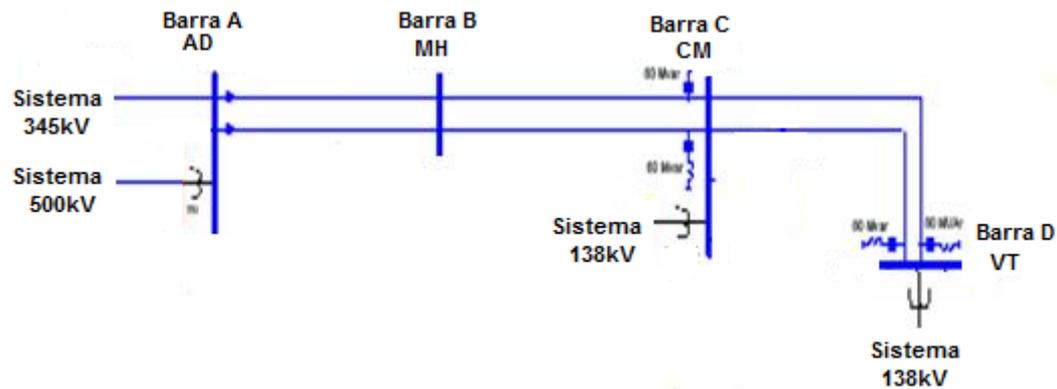


Figura 21 – Tronco do Sistema de Transmissão

A necessidade de comparar resultados obtidos de classificação e extração de regras motivaram a escolha de pequeno trecho de um tronco de transmissão para aplicação da metodologia. Foi utilizado um trecho do sistema representado na figura 21 numa configuração antiga de estudo.

Os estudos foram realizados utilizando o programa ANAREDE para determinar as tensões máximas de energização de cada circuito de forma a não ultrapassar o limite máximo admissível no extremo da linha após a energização (105%). Os resultados das simulações para o sistema tronco estão resumidos na tabela a seguir:

Tabela 7 - Resultados dos estudos de regime permanente para as energizações de linhas de transmissão no sistema tronco

Condição inicial Tensão antes da energização		Tensão na ponta da linha	Observação	Carga no circuito paralelo	Configuração do tronco
BarraA	BarraB				
1.006	-----	1.047	----	--	
1.012	1.052	1.054	Segundo circuito a ser energizado Reator da Barra D ligado $V=1.045$ na Barra D	125 MW	
1.023	1.095	1.067	Segundo circuito a ser energizado Reator da Barra D desligado $V=1,15$ na Barra D	125 MW	

Condição inicial Tensão antes da energização		Tensão na ponta da linha	Observação	Carga no circuito paralelo	Configuração do tronco
BarraA	BarraB				
1.02	1.094	1.066	Segundo circuito a ser energizado Reator da Barra C desligado V=1,10 na Barra D	125 MW	
1.030 Após energi- zação	1.057	1.056	Segundo circuito a ser energizado Reator da Barra D ligado V=1.052 na Barra D	113 MW	
1.031 Após energi- zação	1.062	1.057	Segundo circuito a ser energizado Reator da Barra D ligado V=1.058 na Barra D	100 MW	
1.013	1.048	1.055	Segundo circuito a ser energizado Reator da Barra D ligado, V=1.048 na Barra D	120 MW	

Após a determinação das tensões máximas de energização foi necessário verificar a existência de sobretensões transitórias que pudessem ocasionar operações de proteções de sobretensão. Foi considerado o valor de 125% para ajuste da proteção de sobretensão da linha. Além disso, foi verificada a energia dissipada em pára-raios da linha e/ou tensão de disparo de pára-raios convencionais. No caso de alguma violação foram alterados os valores da tensão de pré-energização para aquela condição de sistema e efetuadas novas simulações.

Os estudos de transitórios eletromagnéticos foram realizados utilizando o programa ATP (Alternative Transient Program), com a análise estatística de 100 casos e detalhamento daqueles que apresentaram as maiores sobretensões, sendo utilizado um tempo mínimo de análise de 300ms e um Time step de 50 μ s. Os estudos estatísticos preliminares foram realizados para representar as características probabilísticas dos equipamentos de manobra como, por exemplo, a aleatoriedade dos instantes de fechamento do disjuntor.

Os resultados das simulações de transitórios eletromagnéticos utilizando o programa ATP encontram-se no anexo A.4.

Dos resultados dos estudos são extraídos os valores dos diversos atributos que influenciam na classificação para compor os vetores - padrões de entrada dos conjuntos de treinamento e teste da rede neural. É importante ressaltar que todos os dados de entrada foram normalizados para um melhor resultado.

Uma dificuldade adicional encontrada neste sistema foi a de como identificar se o restante do sistema está completo ou seja se a perturbação se restringiu ao tronco em análise ou envolveu outros circuitos não necessariamente ligados diretamente a ele.

Nos sistemas teste anteriores por se tratar apenas de 3 linhas esta tarefa foi mais evidente, por exemplo a presença de qualquer circuito entre as Usinas B e C caracteriza o restante do sistema completo para esta energização. Desta forma a

energização da LT Usina A-Usina B com o restante do sistema completo pode ser executada com uma tensão mais elevada uma vez que não será necessário a energização de nenhum outro circuito a partir da Usina B , apenas háverá o fechamento de paralelo nesta usina. Caso contrário, se a perturbação for geral a tensão de partida na Usina A deverá ser menor para garantir a fluência da energização até a Usina C.

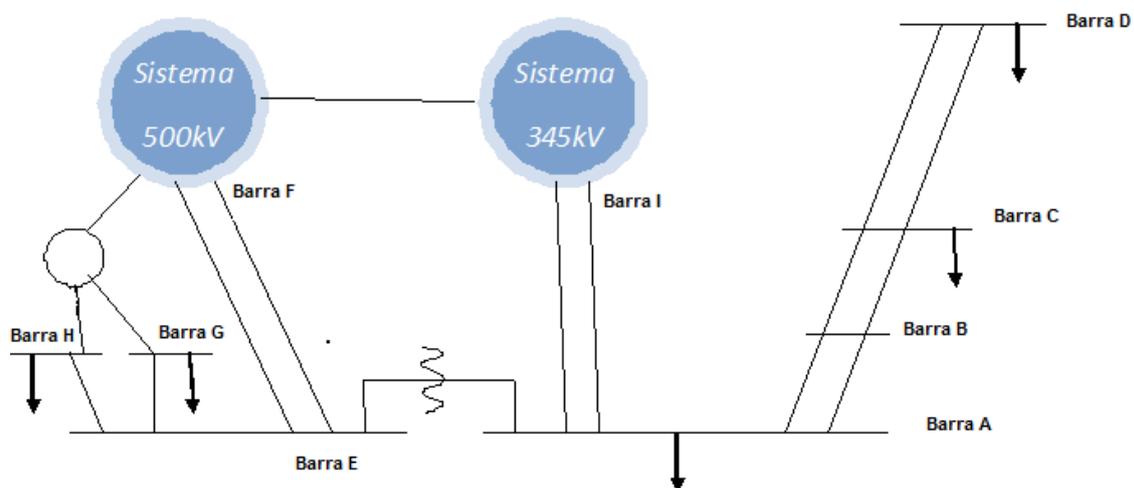


Figura 22 - Configuração do Sistema

Com relação ao sistema tronco em análise, representado na figura 21, foram feitos alguns testes para tentar identificar através de medidas de grandezas elétricas presentes na operação do sistema se um circuito de 500kV, por exemplo uma LT 500kV AD-CH encontra-se desligada caracterizando que o sistema não está completo. Com base no conhecimento do domínio do problema foram escolhidas 17 grandezas, que pudessem caracterizar esta situação, como variáveis de entrada:

- Fluxo na própria linha
- Fluxo na LT paralela
- Fluxo na LT Barra E – Barra G
- Fluxo na LT Barra E – Barra H
- Fluxo na LT Barra A – Barra I circuito 1
- Fluxo na LT Barra A – Barra I circuito 2
- Reativo no síncrono da Barra G
- Tensão na Barra E 500kV
- Tensão na Barra A 345kV
- Fluxo total no 500kV da Barra A
- Fluxo total no 345kV da Barra A
- Fluxo total 500+345kV da Barra A
- Percentual de fluxo pelo 500kV
- Percentual de fluxo pelo 345kV
- Fluxo que vai para Barra G+ Barra H
- Percentual de fluxo que vai para Barra G+ Barra H
- Percentual de fluxo no circuito paralelo

A análise de diversos casos base de carga pesada, média, leve, mínima e de sábados e domingos compuseram os 32 exemplares de treinamento sendo 16 casos com a LT 500kV AD-CH circuito1 presente e 16 casos com esta linha de transmissão ausente. Outro aspecto a ser considerado é quais as variáveis representativas do problema em análise. Para fazer a seleção de atributos inicialmente foi feita uma verificação de correlação de cada variável com a saída, sendo obtido o seguinte resultado em ordem decrescente:

- 1- Fluxo no próprio circuito
- 2- Percentual de fluxo no circuito paralelo em relação ao total
- 3- Percentual de fluxo que vai para Barra G+ Barra H
- 4- Fluxo que vai para Barra H
- 5- Fluxo que vai para Barra G+ Barra H
- 6- Fluxo no circuito paralelo
- 7- Fluxo total no 500kV da Barra A
- 8- Fluxo que vai para Barra G
- 9- Tensão no 500kV
- 10- Tensão no 345kV
- 11- Fluxo total 500+345kV da Barra A
- 12- Percentual de fluxo pelo 500kV
- 13- Percentual de fluxo pelo 345kV
- 14- Fluxo na Barra A – Barra I circuito 1ou 2
- 15- Fluxo total no 345kV da Barra A
- 16- Reativo no síncrono da Barra G

Foi também feita a seleção de atributos relevantes para a classificação utilizando-se a árvore de decisão do WEKA. Os resultados não só comprovaram os obtidos anteriormente como indicaram através da árvore podada (J48 pruned tree) que apenas o fluxo no próprio circuito seria suficiente para identificar a presença do mesmo. A possibilidade de perda de telemedição e outros fatores nos conduzem a pensar na fragilidade desta escolha. Foi feita então nova simulação com a árvore de decisão retirando-se esta variável da entrada. Os novos resultados indicaram que apenas o percentual de fluxo na LT paralela em relação ao total seria suficiente para indicar a ausência da linha.

Embora este possa ser um caminho para identificar se o sistema está completo, muita pesquisa ainda precisa ser feita. Associar o sistema a um nível de curto circuito embora mais preciso é de difícil construção prática.

Os resultados obtidos com a utilização do WEKA indicaram que um fluxo maior que 428,2 MW na LT 500kV AD-CH circuito 2 seria suficiente para indicar a ausência do circuito paralelo. A retirada desta variável do conjunto de dados de entrada foi realizada para identificar a próxima variável mais significativa. O resultado obtido indicou que o percentual de fluxo no circuito paralelo em relação ao total acima de 65,68% também seria suficiente para indicar a ausência do circuito paralelo.

Embora estes testes preliminares indiquem que a árvore é capaz de selecionar os atributos relevantes, seria necessário um maior número de exemplares de treinamento em uma maior faixa de operação para se ter resultados mais conclusivos. Conforme já mencionado associar o sistema a um nível de curto circuito embora mais preciso é de difícil construção prática. Foi então considerada perturbação envolvendo apenas o tronco em análise, permanecendo o restante do sistema em operação.

Dos resultados dos estudos de regime permanente e transitórios eletromagnéticos foram extraídos os valores dos diversos atributos que influenciam na classificação para compor os vetores - padrões de entrada dos conjuntos de treinamento e teste da rede neural. É importante ressaltar que todos os dados de entrada foram normalizados para um melhor resultado.

A rede neural para apoio a decisão da energização da LT BarraA - BarraB apresenta a seguinte estrutura:

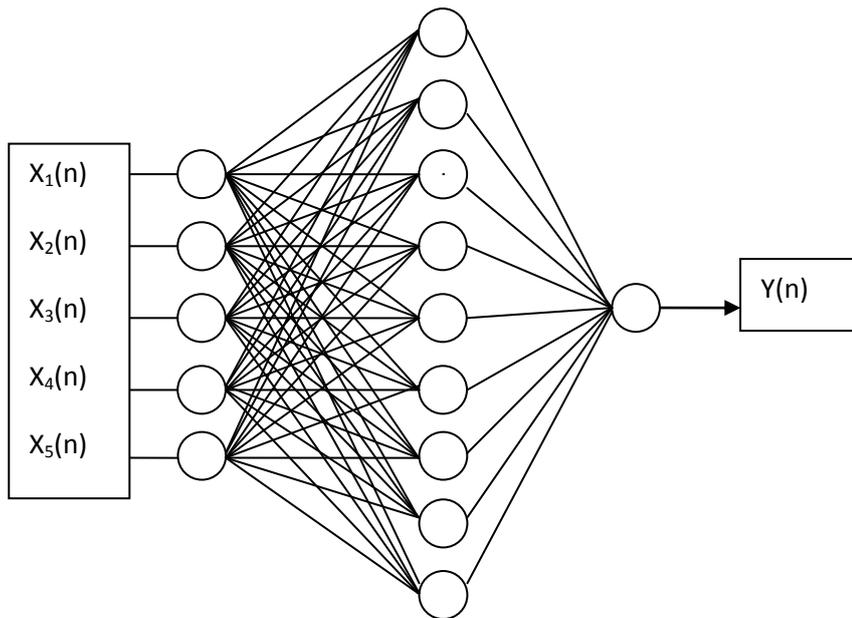


Figura 23 - Arquitetura da rede neural proposta LT BarraA-BarraB

Onde :

$X(n)$ representa o vetor padrão da entrada n ;

$X_1(n)$ representa o módulo da tensão no barramento onde vai ser fechado o disjuntor;;

$X_2(n)$ representa a configuração do sistema;

$X_3(n)$ representa a presença ou não da linha paralela ;

$X_4(n)$ representa o fluxo de potência ativa no circuito paralelo ;

$X_5(n)$ representa a presença do reator da LT BarraC-BarraD na Barra D e

$Y(n)$ a saída da rede, ou seja, se o circuito pode (classe=1) ou não (classe=0) ser energizado.

A variável X_1 é obtida a partir do valor máximo de tensão de energização. Considerou-se que a tensão no barramento varia na faixa de 0,9 pu a 1,10 pu. Os valores abaixo da tensão máxima de energização foram discretizados com um intervalo de 0,01pu e passam a compor exemplos de padrões de treinamento da classe 1. Os valores acima

da tensão máxima de energização foram discretizados com um intervalo de 0,01pu e passam a compor exemplos de padrões de treinamento da classe 0.

A variável X_2 pode assumir os valores 1 ou 0 se o sistema estiver completo ou não, do mesmo modo a variável X_3 pode assumir o valor 1 ou 0 caso a linha paralela esteja presente ou não. Já a variável X_4 representa a carga do circuito paralelo e foi discretizada utilizando-se um intervalo de 10 MW na faixa de 0 a 200MW. A variável X_5 pode assumir os valores 1 ou 0 caso o reator da LT na Barra D esteja presente ou não respectivamente.

A metodologia é repetida para cada configuração da rede sendo obtidos 1260 padrões de treinamento. Esse conjunto de dados foi disposto de maneira aleatória sendo utilizados 80 % destes padrões para treinamento da rede neural e os 20 % restantes para teste.

Após o treinamento esta rede é capaz de classificar a energização do circuito como viável ou não. Os resultados obtidos foram:

Tabela 8 – Erro de classificação da rede neural da Linha AD-MH 1

Neuronios na camada escondida	MSE	Erro Absoluto	Erro %
5	0,00009655	2	0,8%
6	0,00004202	1	0,4%
7	0,00009062	1	0,4%
8	0,00003287	1	0,4%
9	0,00002991	0	0%

No sistema tronco estudado tínhamos também a finalidade de comparar os resultados obtidos de extração de regras de energização, obtidas a partir do sistema híbrido, com as Instruções de Operação. Foram então extraídas as regras do banco de dados utilizado para treinamento da rede neural:

A árvore de decisão extraída do banco de dados para classificação da energização da linha AD-MH1 pode ser representada da seguinte forma:

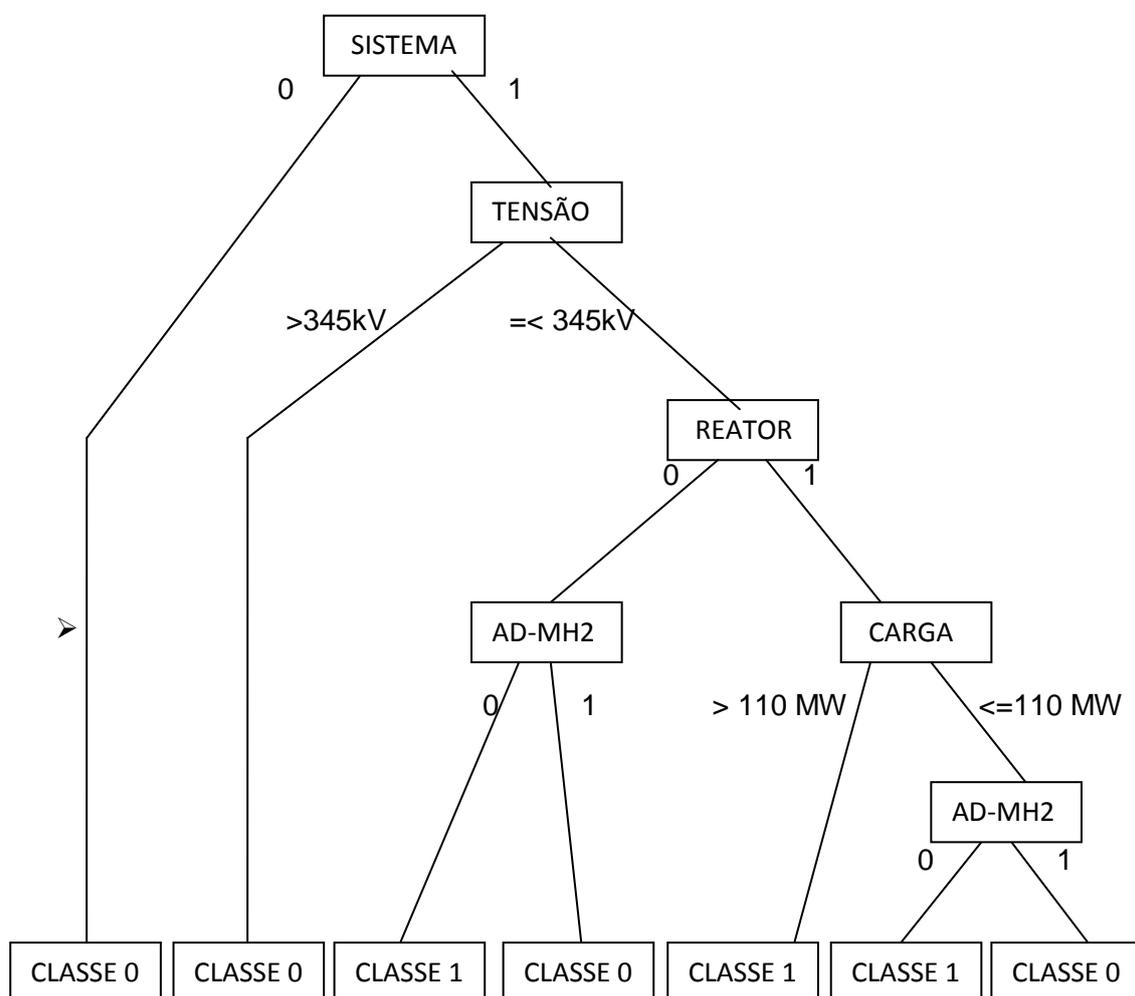


Figura 24 – Árvore de decisão extraída do banco de dados para classificação da energização da linha AD-MH circuito 1

As seguintes regras podem ser extraídas desta árvore:

Regra 1:

Se o restante do sistema não estiver completo

Então a energização não é viável

Regra 2:

Se a tensão de energização na Barra AD for maior que 345kV

Então a energização é inviável

Regra 3:

Se o restante do sistema estiver completo e

A tensão de energização na Barra AD for menor ou igual a 345kV e

O reator em VT estiver desligado e

A LT AD-MH circuito 2 estiver desligada

Então a energização é viável

Regra 4:

Se o restante do sistema estiver completo e

A tensão de energização na Barra AD for menor ou igual a 345kV e

O reator em VT estiver desligado e

A LT AD-MH circuito 2 estiver ligada

Então a energização é inviável

Regra 5:

Se o restante do sistema estiver completo e

A tensão de energização na Barra AD for menor ou igual a 345kV e

O reator em VT estiver ligado e

A carga na LT AD-MH circuito 2 maior que 110MW

Então a energização é viável

Regra 6:

Se o restante do sistema estiver completo e

A tensão de energização na Barra AD for menor ou igual a 345kV e

O reator em VT estiver ligado e

A carga na LT AD-MH circuito 2 for menor ou igual a 110MW e

A LT AD-MH circuito 2 estiver desligada

A energização é viável

Regra 7:

Se o restante do sistema estiver completo e

A tensão de energização na Barra AD for menor ou igual a 345kV e

O reator em VT estiver ligado e

A carga na LT AD-MH circuito 2 for menor ou igual a 110MW e

A LT AD-MH circuito 2 estiver ligada

A energização é inviável

As regras 3, 5 e 6 expressam as condições que permitem a energização:

A energização é viável

Se o restante do sistema estiver completo e

A tensão de energização na Barra AD for menor ou igual a 345kV e

O reator em VT estiver desligado e

A LT AD-MH circuito 2 estiver desligada ou

Se o restante do sistema estiver completo e

A tensão de energização na Barra AD for menor ou igual a 345kV e

O reator em VT estiver ligado e

A carga na LT AD-MH circuito 2 for maior que 110MW ou

Se o restante do sistema estiver completo e

A tensão de energização na Barra AD for menor ou igual a 345kV e

O reator em VT estiver ligado e

A carga na LT AD-MH circuito 2 for menor ou igual a 110MW e

A LT AD-MH circuito 2 estiver desligada.

Conforme já mencionado as regras extraídas diretamente da árvore podem ser mais complexas que o necessário, no caso estudado as regras 3 e 6 poderiam ser unificadas da seguinte forma:

A energização é viável se

Se o restante do sistema estiver completo e

A tensão de energização na Barra AD for menor ou igual a 345kV e

A LT AD-MH circuito 2 estiver desligada .

As regras que permitem a energização se resumiriam a:

A energização é viável SE

O restante do sistema estiver completo E

A tensão de energização na Barra AD for menor ou igual a 345kV E

O reator em VT estiver ligado E

A carga na LT AD-MH circuito 2 for maior que 110MW OU

Se o restante do sistema estiver completo E

A tensão de energização na Barra AD for menor ou igual a 345kV E

A LT AD-MH circuito 2 estiver desligada

As regras assim obtidas se assemelham bastante as diretrizes contidas nas Instruções de Operação. Outra observação importante é que a regra 1 expressa a impossibilidade de energização com o sistema incompleto. Essa foi uma premissa adotada no início do estudo, ou seja, a consideração de perturbação apenas no tronco em análise, permanecendo o restante do sistema em operação.

IV.5 Análise dos Resultados

Os resultados obtidos nos sistemas testados foram bastante aceitáveis, com erros de classificação no conjunto de teste de 1%, 3,2% e 0%. Estes percentuais correspondem apenas a 1 exemplar classificado erroneamente. Uma análise destes erros mostrou que se referem a pontos próximos à superfície de decisão. Uma forma de minimizar o problema foi a utilização de intervalos menores na discretização das variáveis de entrada tensão e fluxo de potência ativa. É também de extrema importância que o conjunto de dados de treinamento seja suficientemente representativo do problema em análise de forma a permitir um bom desempenho do classificador.

As regras que são lidas diretamente de uma árvore de decisão são mais complexas que o necessário, conforme mencionado no Capítulo III. Após a remoção das cláusulas desnecessárias, estas regras se assemelham bastante as diretrizes contidas nas Instruções de Operação para restabelecimento do Sistema Elétrico.

IV.6 Simulador

Para se avaliar a possibilidade de energização de uma linha de transmissão deste tronco inicialmente são solicitados os valores dos atributos necessários à classificação. A partir destes valores é montado o vetor padrão de entrada z que é normalizado entre -1 e 1 segundo a seguinte expressão:

$$z_n = 2 * \frac{(z - \text{minp})}{(\text{maxp} - \text{minp})} - 1 \quad (\text{IV. 1})$$

Onde:

z é o vetor padrão de entrada

z_n representa o vetor padrão de entrada normalizado

minp e maxp representam os valores mínimo e máximo dos vetores padrões de entrada utilizados no treinamento da rede neural

Esse valor normalizado é apresentado à rede neural que efetua a classificação. Se a energização for viável a classe atribuída a esse padrão será 1, caso contrário será 0.

Em seguida através da análise das regras extraídas pela árvore de decisão dos dados de treinamento da rede neural é exibido ao usuário o porquê daquela classificação. O seguinte diagrama de blocos resume esta simulação:

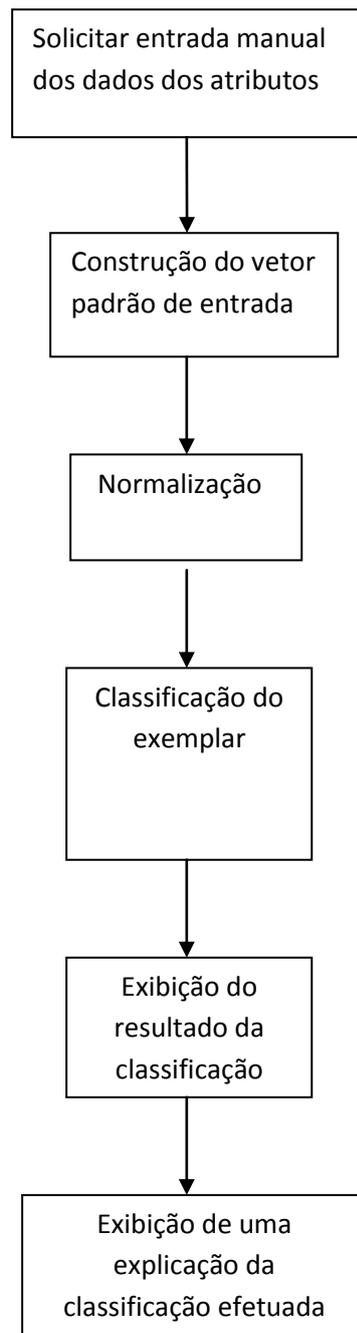


Figura 25 – Diagrama de blocos do Simulador

A seguinte tela é exibida :

Entre com a tensão de energização

360

Entre 1 se o sistema estiver completo e 0 caso contrário

1

Entre 1 se o circuito paralelo estiver presente e 0 caso contrário

1

Entre com a carga em MW no circuito paralelo

200

Entre com 1 se o reator da CM-VT em VT estiver presente e 0 caso contrário

1

saída =

0

ans =

NÃO ENERGIZAR

ans =

A tensão de energização na Barra AD é maior que 345kV

Deseja continuar? SIM=1 ou NAO=0

0

IV.7 Sumário do Capítulo

Neste capítulo foram apresentados resultados da aplicação da metodologia a dois sistemas teste e um trecho de um sistema real numa configuração antiga de estudo. O conjunto de regras extraído dos dados utilizados no treinamento da rede neural, que expressa os valores dos atributos que permitem ou não a energização do circuito, são de fácil compreensão e utilização. Foi também apresentada uma simulação de classificação da energização com apresentação da regra utilizada nesta classificação.

CAPÍTULO V

CONCLUSÕES

V.1 Considerações Iniciais

A complexidade do problema de Restabelecimento de Sistemas Elétricos de Potência dificulta a utilização de uma técnica inteligente única para construção de uma ferramenta que resolva todos os aspectos envolvidos no problema. Os métodos tradicionais de análise de energização que envolve estudos de regime permanente e transitórios eletromagnéticos são bastante demorados, de modelagem complexa e análise bastante especializada o que os torna inviáveis em tempo real.

As alternativas atualmente adotadas são a execução de estudos na fase de planejamento da operação de caminhos preferenciais de restabelecimento e consideração de algumas indisponibilidades com transcrição dos resultados em Instruções de Operação. O stress a que os Operadores ficam submetidos nas ocasiões de grandes perturbações associado a fatos imprevistos podem retardar ou mesmo impedir o restabelecimento. A técnica sugerida para apoio à decisão pode contemplar uma combinação bem maior de configurações e indisponibilidades fornecendo um resultado bastante rápido, de fácil consulta e utilização.

O valor das sobretensões resultantes da energização de linhas de transmissão é muito influenciado pela potência de curto-circuito do sistema. O fato de o sistema ser forte ou fraco pode ser traduzido para as diretrizes de restabelecimento associando-se à configuração da rede elétrica utilizada no estudo, uma vez que a utilização de um valor de potência de curto-circuito é de difícil construção prática. A metodologia proposta permite combinar um grande número de configurações de rede e utilizar os resultados

para treinar a rede neural para classificar a energização de maneira rápida o que seria de difícil consulta e implantação em Instruções de Operação.

A preparação do banco de dados envolve exaustivas simulações com diferentes combinações de configuração da rede, seleção de atributos de entrada para a rede neural e montagem do conjunto de dados de treinamento e teste da rede neural, sendo bastante demorada. Esta etapa, que envolve um grande esforço computacional, é feita de maneira off-line e uma vez concluída permite a classificação rápida da viabilidade de energização para uma dada condição do sistema em um formato simples de saída, o que permite sua utilização para apoio a decisão em tempo real.

A metodologia proposta se revelou promissora para apoio a decisão no Restabelecimento de Sistemas de Potência nos sistemas testados. A utilização de um sistema inteligente híbrido, associando uma árvore de decisão a uma rede neural, pretende superar a falta de compreensibilidade desta última, que é um dos principais obstáculos à utilização de redes neurais em aplicações onde segurança é uma preocupação primordial. Para se obter uma melhor aceitação pelos usuários é importante que se tenha um melhor entendimento de como a rede efetuou a classificação da energização. Além disso, as regras extraídas do conjunto de dados de treinamento se assemelham bastante ao formato das Instruções de Operação atualmente em vigor em algumas empresas. Através da análise destas regras, um especialista pode também identificar regiões do espaço onde os dados não são suficientemente representativos do problema em análise ou onde a generalização poderia falhar.

Pesquisas têm sido desenvolvidas para extração de regras diretamente da rede neural sendo o principal obstáculo o compromisso entre simplicidade, precisão e abrangência. Neste trabalho optamos por extrair regras diretamente do conjunto de

dados utilizados no treinamento da rede neural utilizando a árvore de decisão. Com esta aproximação poderá existir alguma situação onde a regra extraída não corresponda ao resultado da classificação. A simplicidade e forma das regras extraídas pela árvore de decisão justificam esta escolha.

Uma possível solução para este problema seria efetuar a classificação pela rede neural e pela árvore de decisão e nas situações onde os resultados das classificações não forem iguais exibir para o usuário uma mensagem do tipo “nada se pode afirmar”. Embora se acredite que o resultado de classificação da rede neural seja mais preciso, exibir resultados conflitantes pode diminuir a confiança do usuário na utilização da ferramenta.

V.2 Desenvolvimentos Futuros

No presente trabalho não foram considerados alguns aspectos:

- Inclusão dos resultados da análise de transitórios eletromecânicos;
- Energização de transformadores;
- Fechamento de paralelo ou anel;
- Dinâmica da carga.

Numa análise preliminar a análise de resultados de estudos de transitórios eletromecânicos poderia ser incorporada ao treinamento da rede neural. Quanto ao fechamento de anel ou paralelo e consideração da dinâmica da carga seria necessário a incorporação de novos módulos inteligentes para construção da ferramenta de apoio à decisão.

No estágio atual de desenvolvimento a metodologia indica se uma linha de transmissão pode ou não ser energizada, as regras que permitem ou impedem a energização do circuito ou o porquê a energização é viável ou não. Numa próxima etapa de desenvolvimento poderia ser incluído um aconselhamento indicando quais as providências que poderiam ser tomadas para tornar a energização viável. Reduzir a tensão de pré-energização, conectar um reator, tomar carga no circuito paralelo, sincronizar um gerador para tornar o sistema mais forte e outras providências poderiam ser analisadas e sugeridas. Para isso deveria ser incorporado um módulo inteligente para fazer o aconselhamento.

Seria também interessante implantar uma interface gráfica com o usuário onde uma vez escolhida a linha a ser energizada num diagrama unifilar, os dados pudessem ser obtidos diretamente do sistema de supervisão ou de um simulador de sistema para classificar a energização e validar caminhos de restabelecimento.

Outro desenvolvimento possível seria a análise da utilização da lógica nebulosa para modelar a saída da rede neural .

APÊNDICE A

TRANSITÓRIOS ELETROMAGNÉTICOS

A.1 Considerações Iniciais

Neste apêndice são apresentados os resultados das simulações de transitórios eletromagnéticos realizados com o programa ATP nos diferentes sistemas teste utilizados

A.2 Sistema Teste 1

A.2.1: Energização da LT Usina A - Usina B com 2 máquinas na Usina A

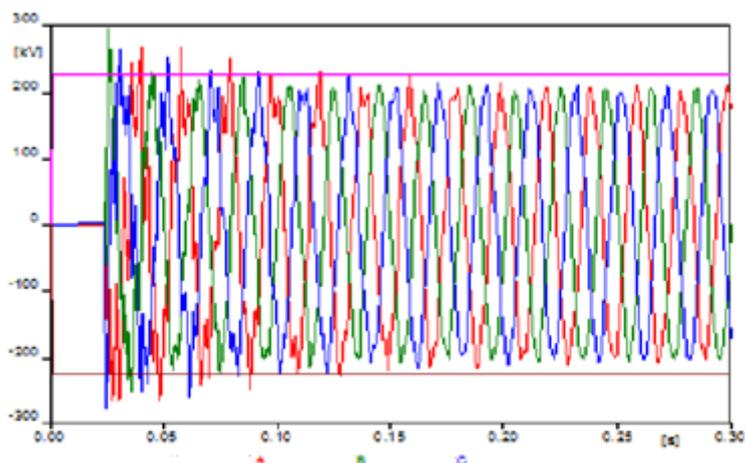
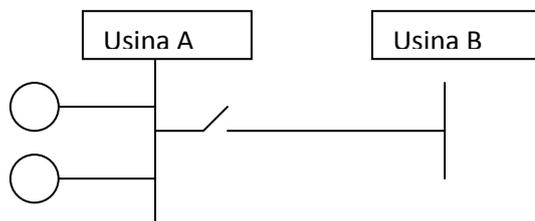


Figura 26 – Energização da LT UsinaA- UsinaB - Tensão no extremo da linha

A.2.2 - Energização da LT Usina B- Usina C com 1 máquina na Usina A e 1 máquina na Usina B

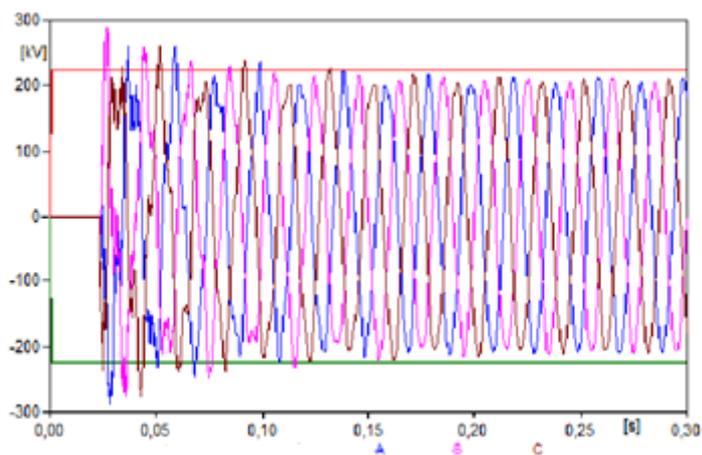
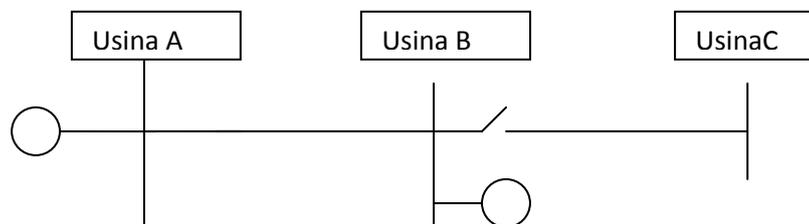


Figura 27 – Energização da LT UsinaB- UsinaC com 1 máquina na UsinaB - Tensão no extremo da linha

A.2.3 - Energização da LT Usina B- Usina C com 1 máquina na Usina A e 2 máquinas na Usina B

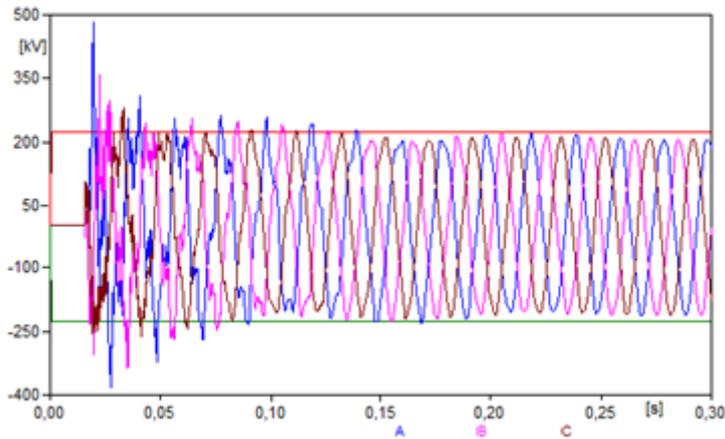
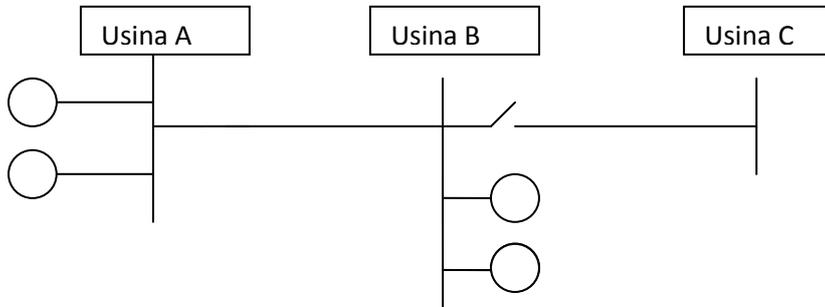


Figura 28 – Energização da LT UsinaB- UsinaC com 2 máquinas na UsinaB - Tensão no extremo da linha

A.3 Sistema Teste 2

A.3.1: Energização da LT Usina A - Usina B com 2 máquinas na Usina A

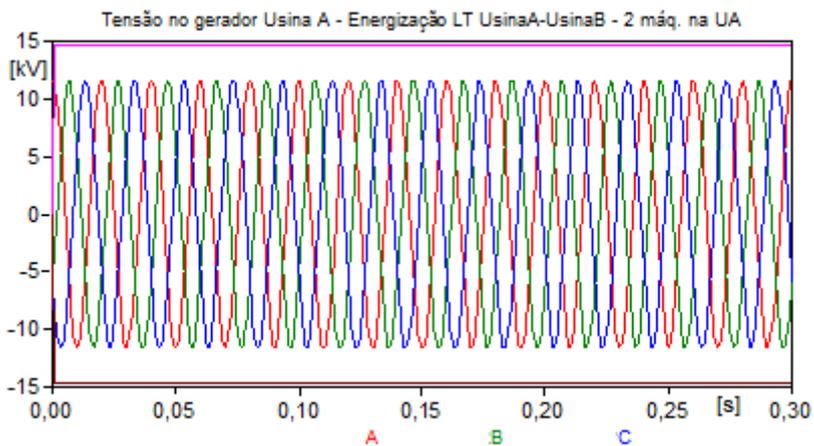
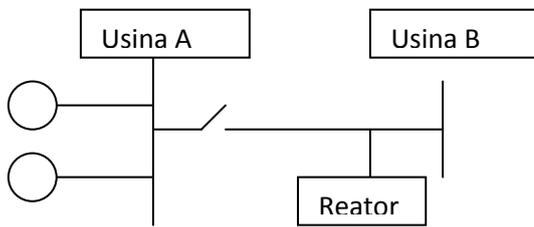


Figura 29 - Energização da LT Usina A - Usina B com 2 máquinas na Usina A –Tensão no gerador Usina A

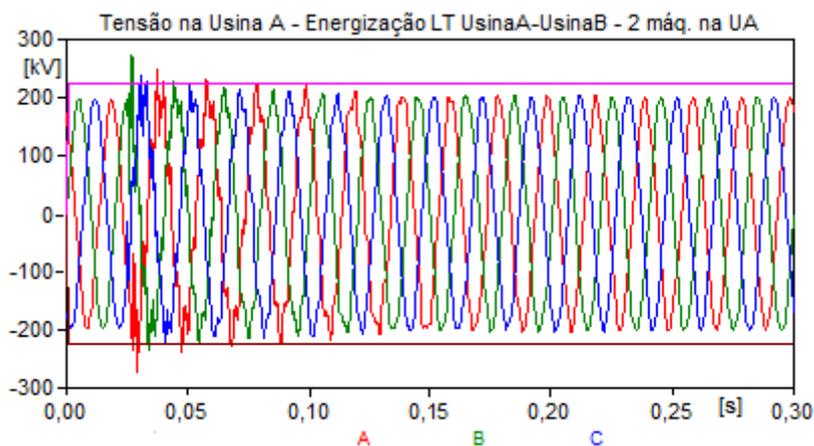


Figura 30 - Energização da LT Usina A - Usina B com 2 máquinas na Usina A –Tensão na Usina A

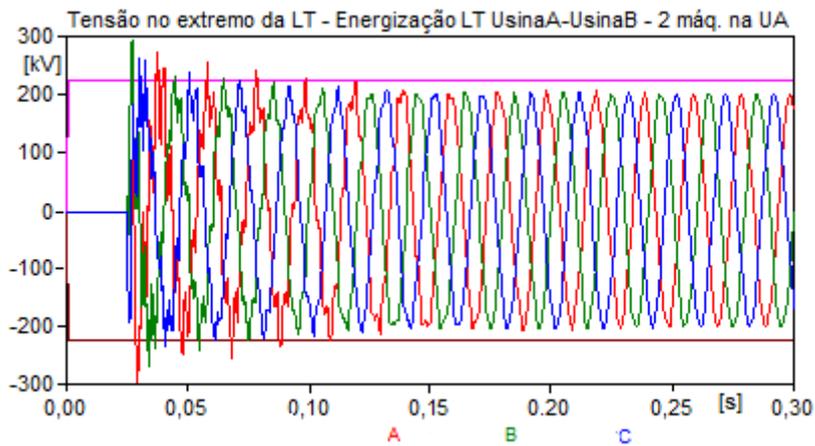


Figura 31 - Energização da LT Usina A - Usina B com 2 máquinas na Usina A – Tensão no extremo da LT

A.3.2 Energização da LT Usina B – SE1 com 2 máquinas na Usina A

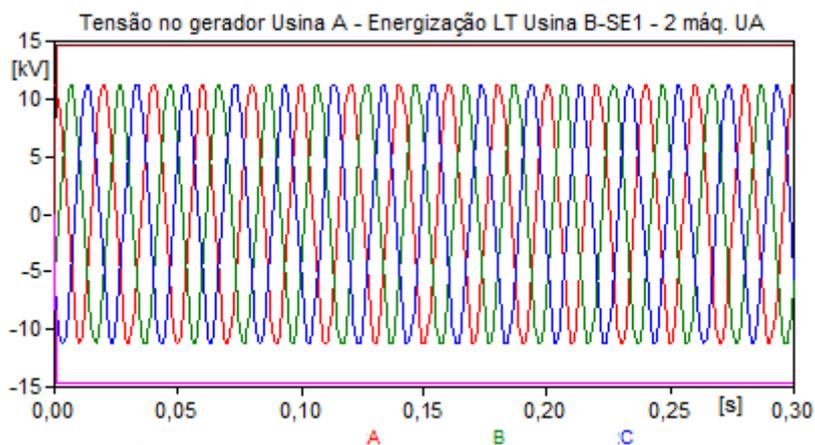
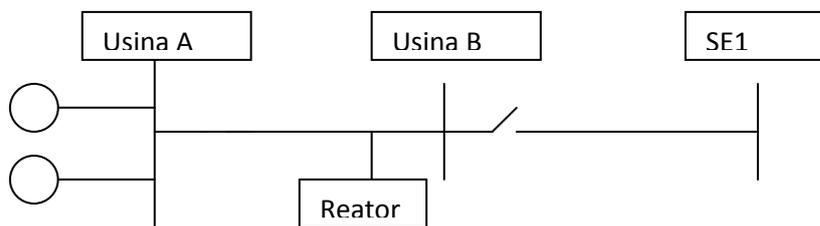


Figura 32 - Energização da LT Usina B – SE1 com 2 máquinas na Usina A – Tensão no extremo da LT

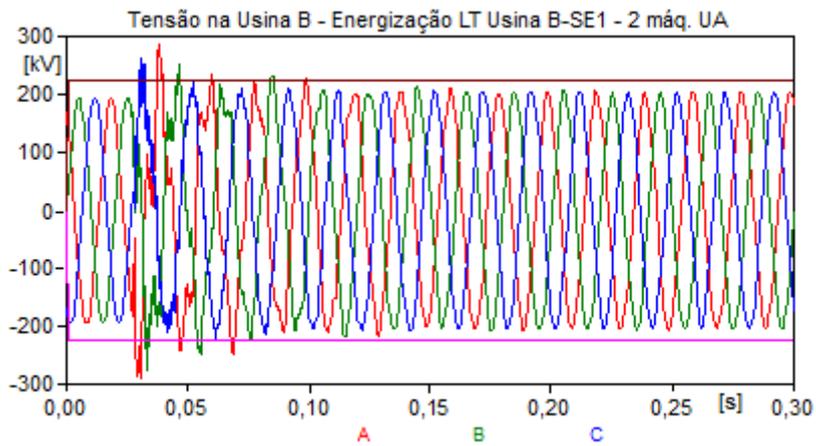


Figura 33 - Energização da LT Usina B – SE1 com 2 máquinas na Usina A – Tensão na Usina B

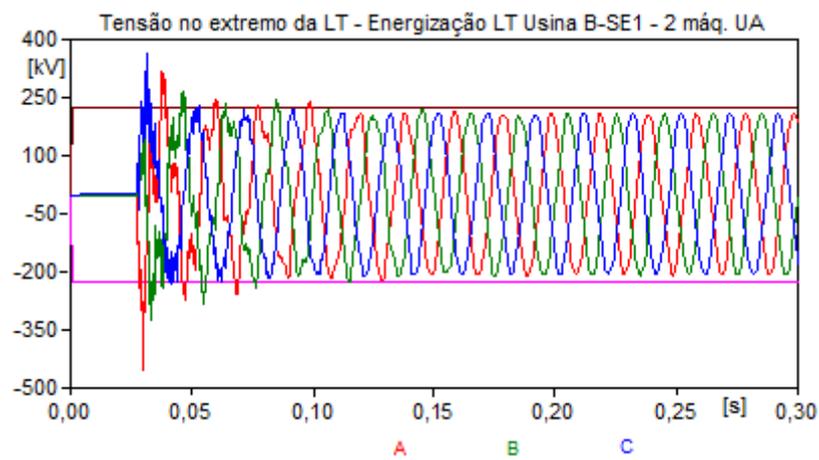


Figura 34 - Energização da LT Usina B – SE1 com 2 máquinas na Usina A – Tensão no extremo da LT

A.3.3 Energização da LT Usina A- SE2 com 2 máquinas na Usina A

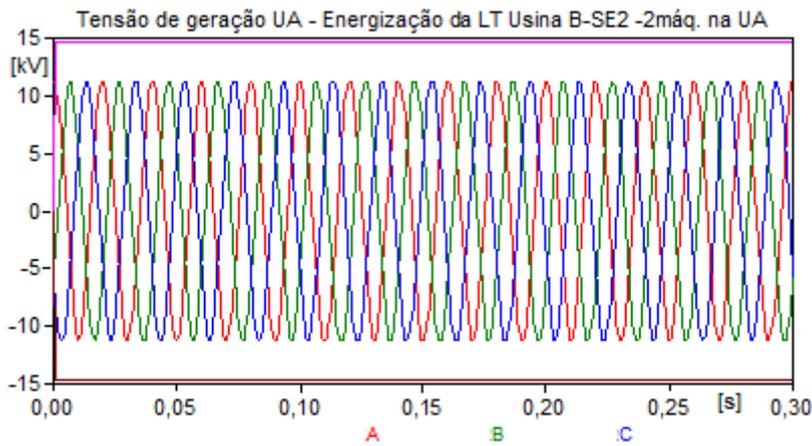
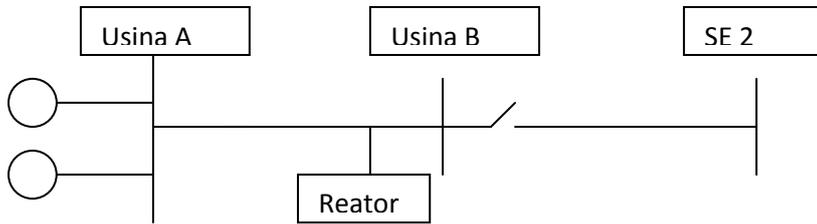


Figura 35 - Energização da LT Usina B – SE2 com 2 máquinas na Usina A – Tensão de geração Usina A

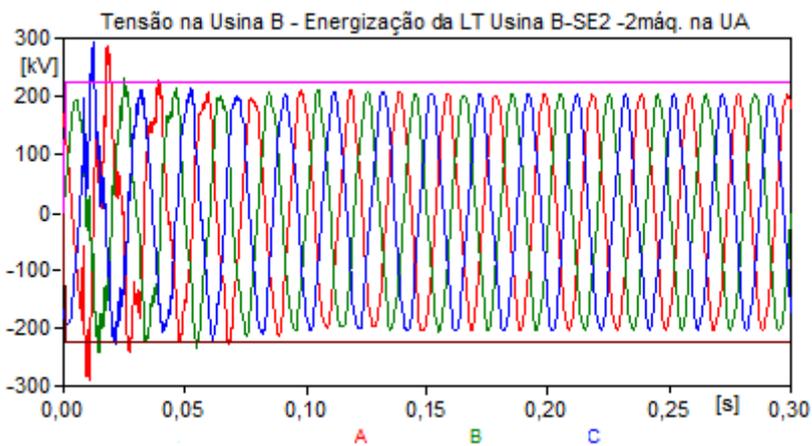


Figura 36 - Energização da LT Usina B – SE2 com 2 máquinas na Usina A – Tensão na Usina B

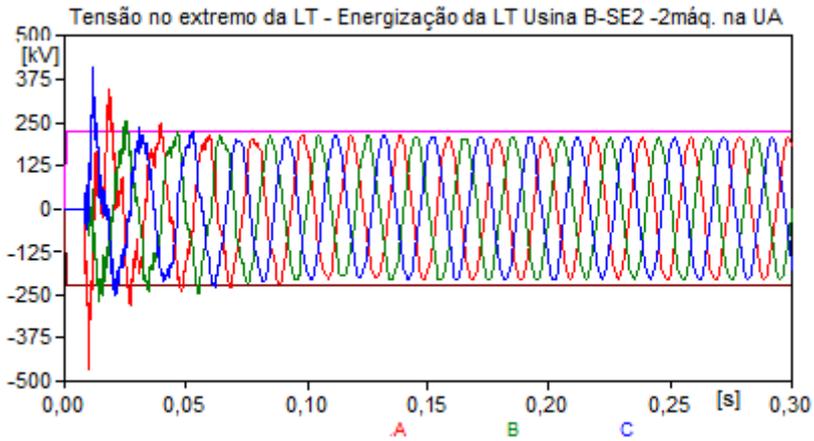


Figura 37 - Energização da LT Usina A- SE2 com 2 máquinas na Usina A – Tensão no extremo da LT

A.3.4 Energização da LT SE2-SE1 com 2 máquinas na Usina A

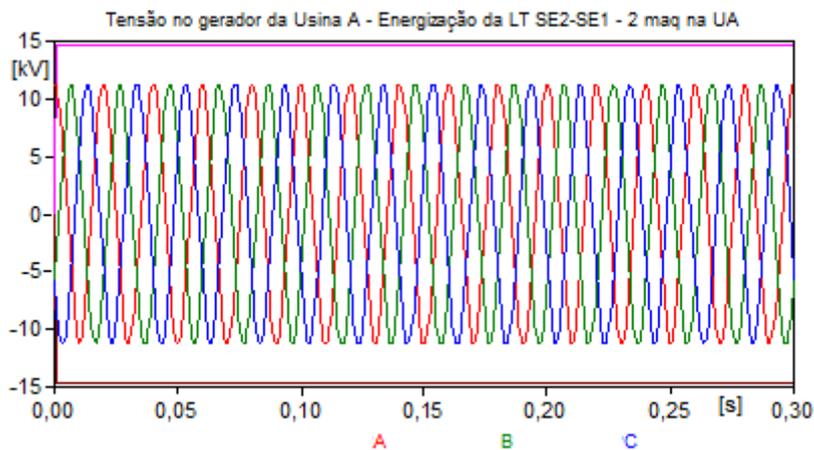
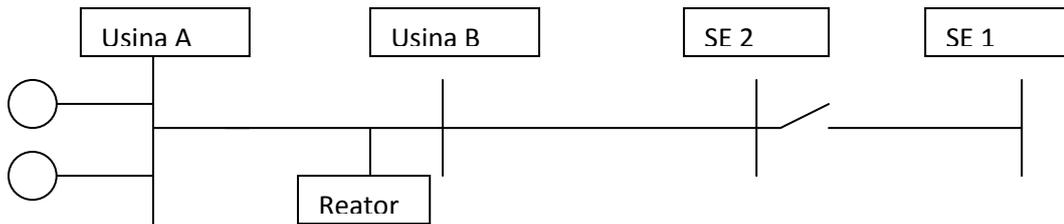


Figura 38 - Energização da LT SE2-SE1 com 2 máquinas na Usina A – Tensão no gerador da Usina A

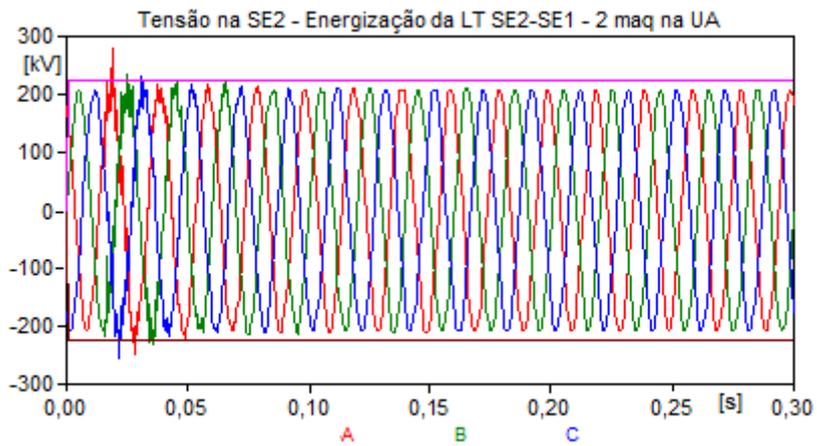


Figura 39 - Energização da LT SE2-SE1 com 2 máquinas na Usina A – Tensão na SE2

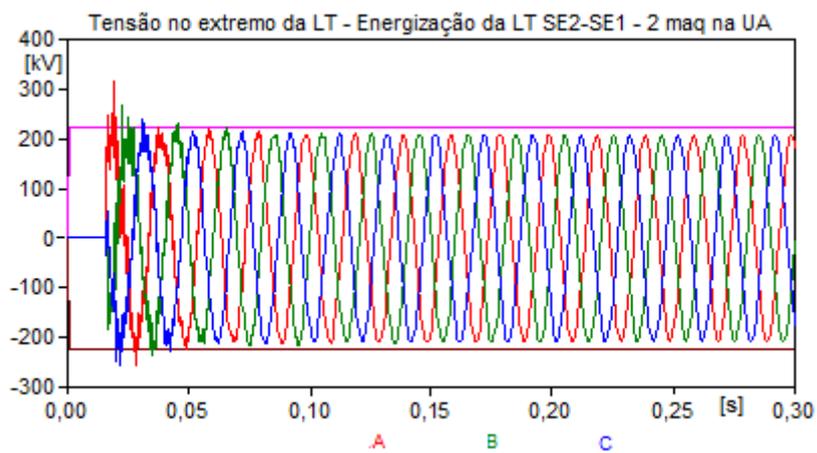


Figura 40 - Energização da LT SE2-SE1 com 2 máquinas na Usina A – Tensão no extremo da LT

A.3.5 Energização da LT Usina B – SE2 com 2 máquinas na Usina A

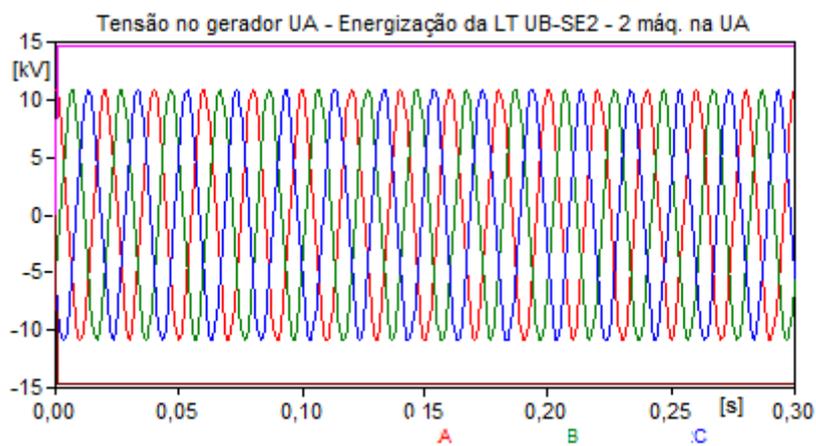
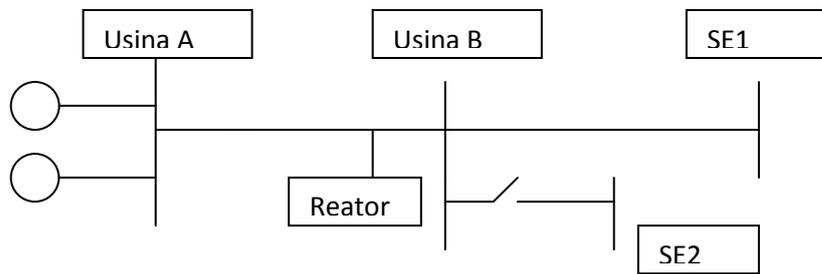


Figura 41 - Energização da LT Usina B – SE2 com 2 máquinas na Usina A – Tensão no gerador da Usina A

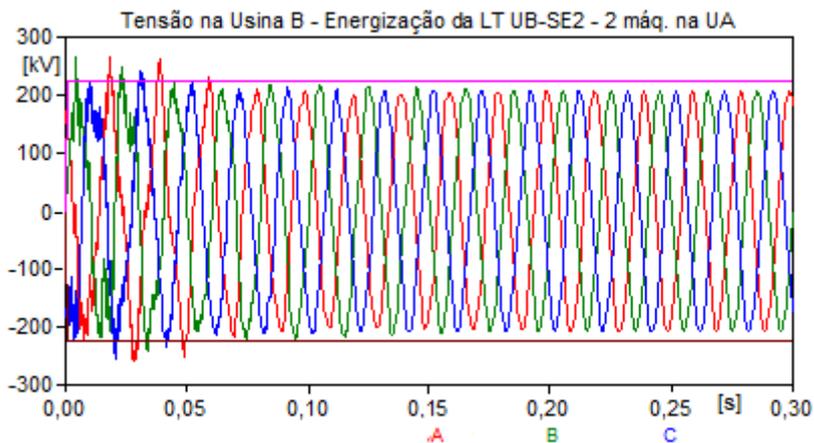


Figura 42 - Energização da LT Usina B – SE2 com 2 máquinas na Usina A – Tensão na Usina B

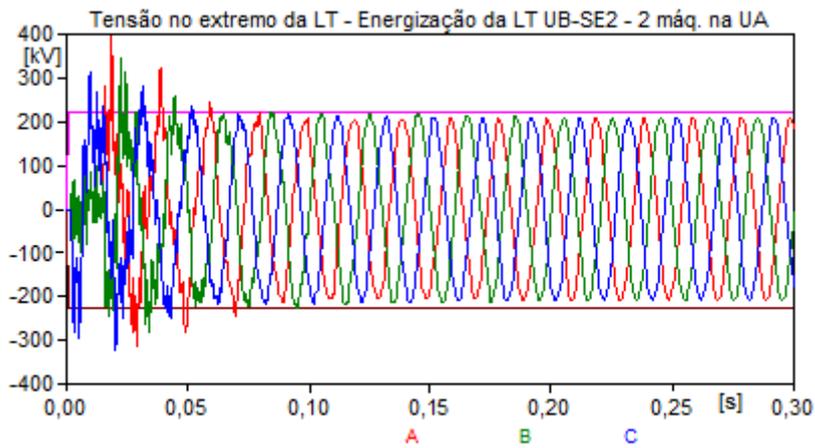
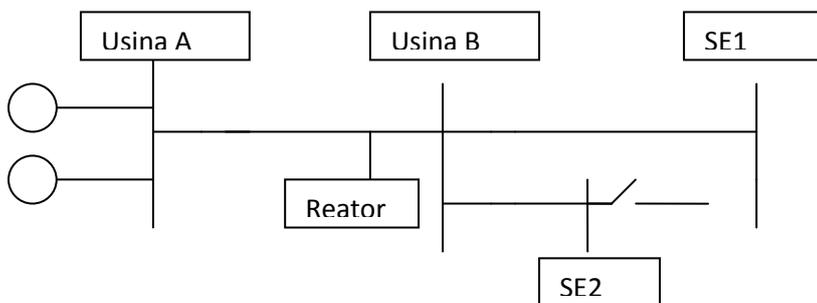


Figura 43 - Energização da LT Usina B – SE2 com 2 máquinas na Usina A- Tensão no extremo da LT

A.3.6 Energização da LT SE2 – SE1 com 2 máquinas na Usina A



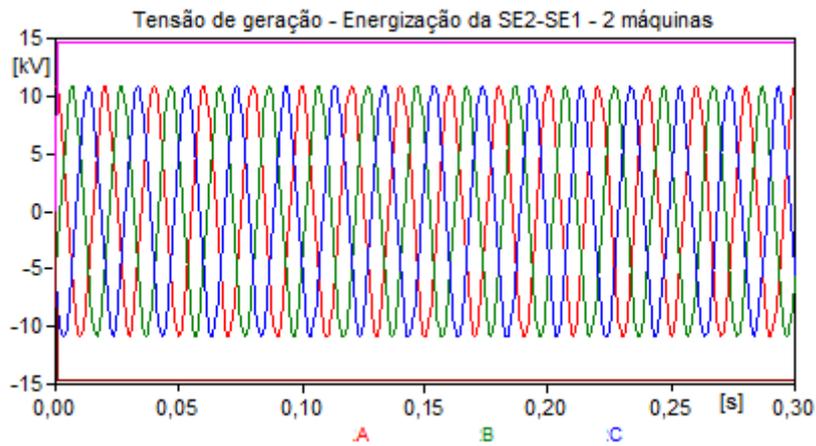


Figura 44 - Energização da LT SE2 – SE1 com 2 máquinas na Usina A – Tensão de geração

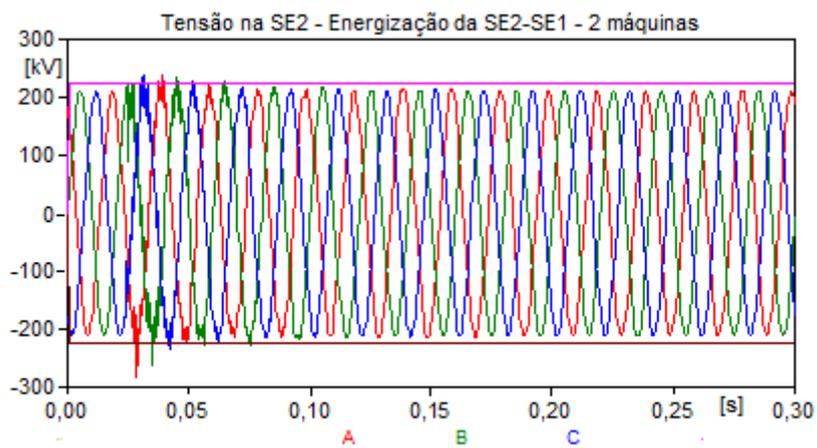


Figura 45 - Energização da LT SE2 – SE1 com 2 máquinas na Usina A – Tensão na SE2

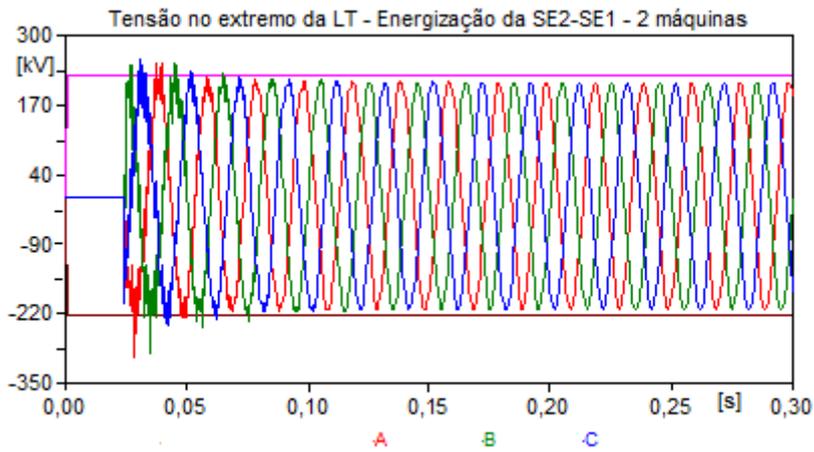
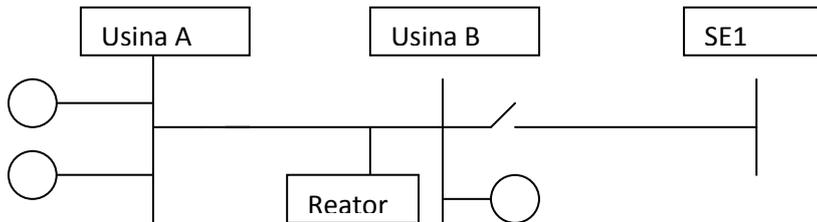


Figura 46 - Energização da LT SE2 – SE1 com 2 máquinas na Usina A – Tensão no extremo da LT

A.3.7 Energização da LT UsinaB – SE1 com 2 máquinas na Usina A e 1 na UsinaB



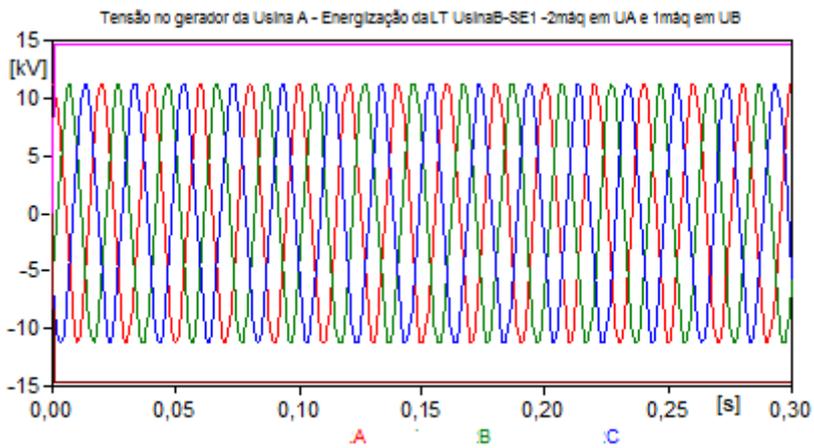


Figura 47 - Energização da LT UsinaB – SE1 com 2 máquinas na Usina A e 1 na UsinaB – Tensão no gerador

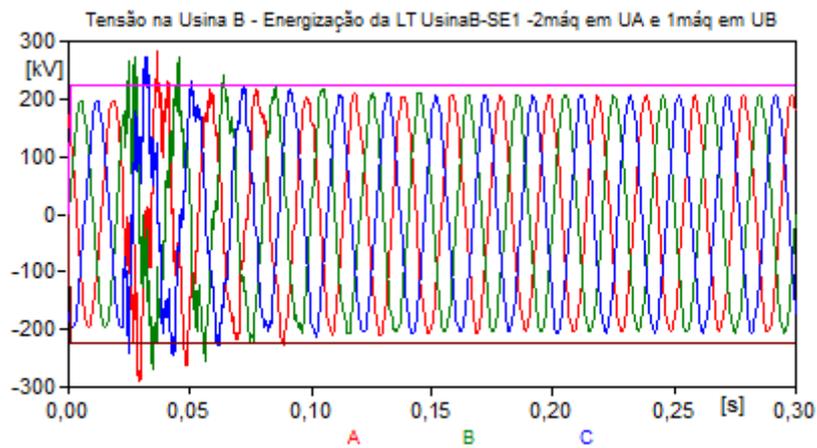


Figura 48 - Energização da LT UsinaB – SE1 com 2 máquinas na Usina A e 1 na UsinaB – Tensão na Usina B

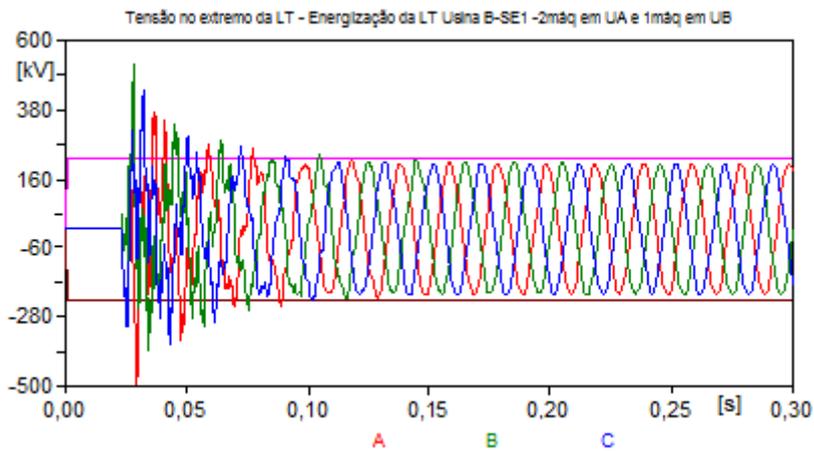


Figura 49 - Energização da LT UsinaB – SE1 com 2 máquinas na Usina A e 1 na UsinaB – Tensão no extremo da LT

A.3.8 Energização da LT Usina B-SE2 com 2 maq na Usina A e 1 maq na Usina B

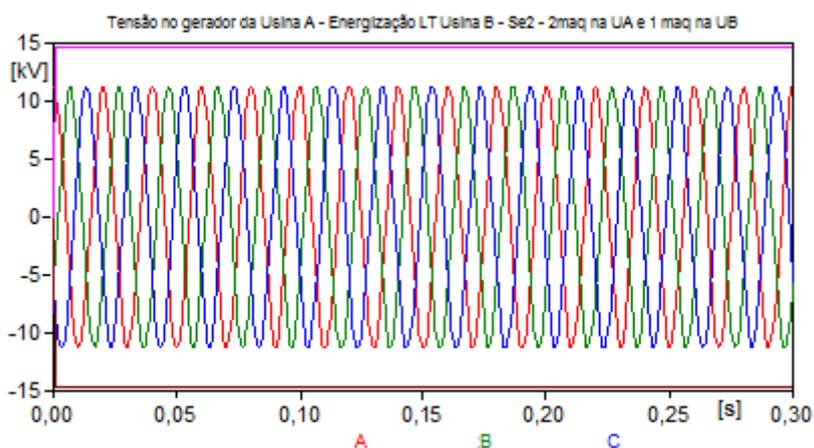
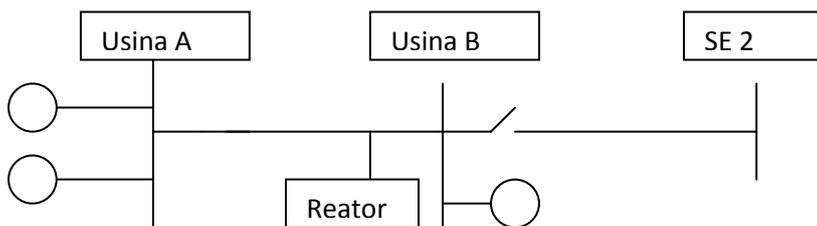


Figura 50 -Energização da LT Usina B-SE2 com 2 maq na Usina A e 1 maq na Usina B – Tensão no gerador

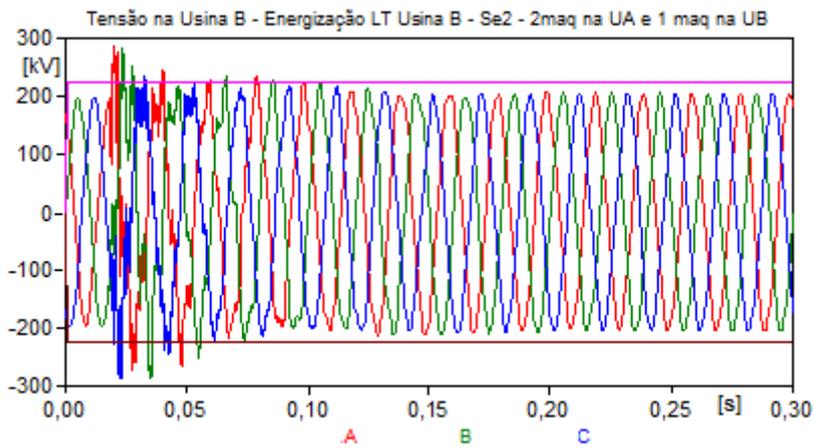


Figura 51 -Energização da LT Usina B-SE2 com 2 maq na Usina A e 1 maq na Usina

B – Tensão na Usina B

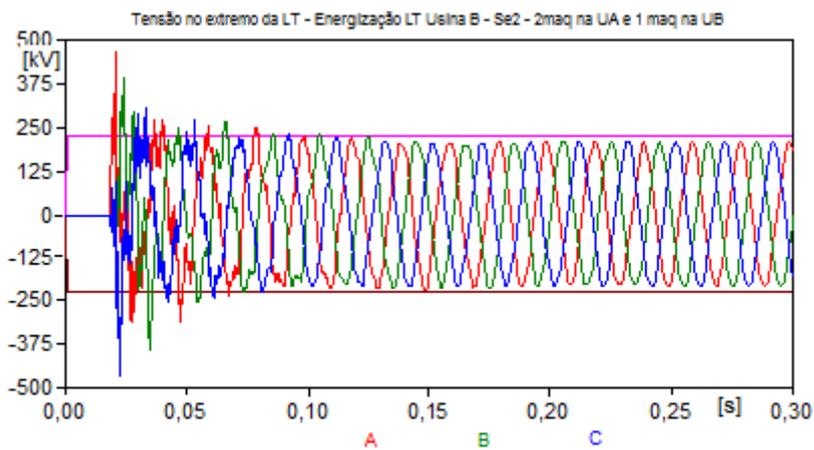


Figura 52-Energização da LT Usina B-SE2 com 2 maq na Usina A e 1 maq na Usina B

– Tensão no extremo da LT

A.3.9 Energização da LT SE2-SE1 com 2 máquinas na Usina A e 1 na Usina B

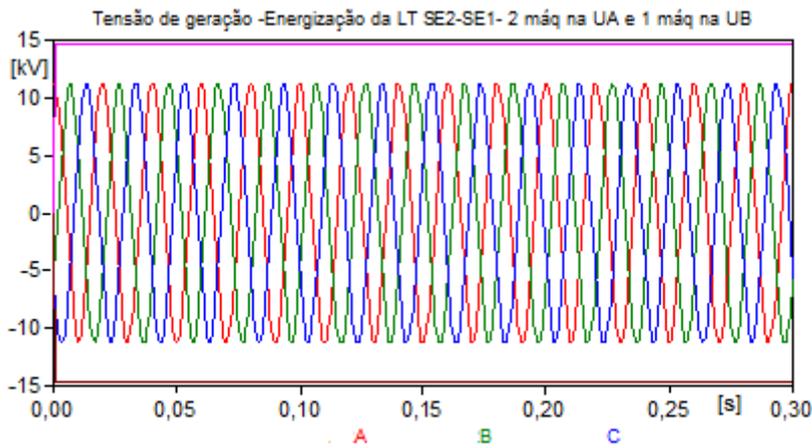
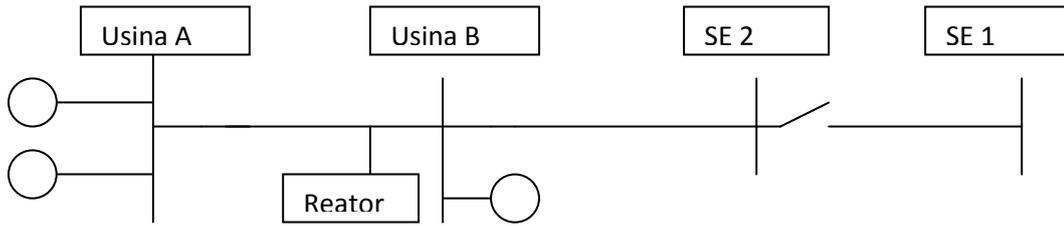


Figura 53- Energização da LT SE2-SE1 com 2 máquinas na Usina A e 1 na Usina B –
Tensão de geração

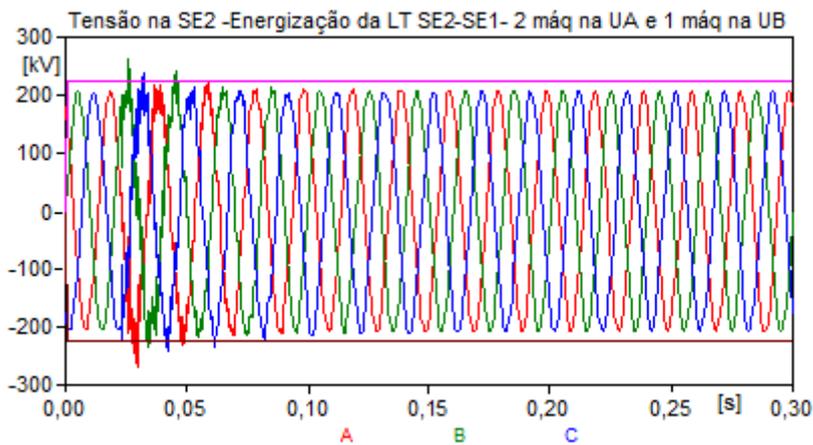


Figura 54 - Energização da LT SE2-SE1 com 2 máquinas na Usina A e 1 na Usina B –
Tensão na SE2

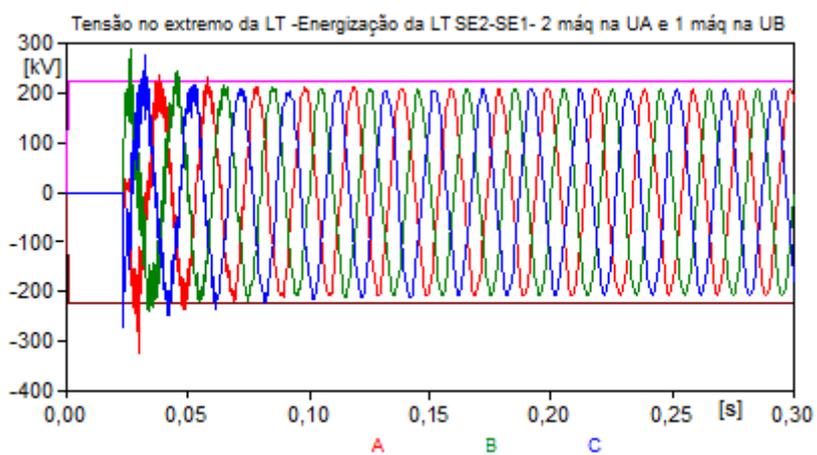


Figura 55 - Energização da LT SE2-SE1 com 2 máquinas na Usina A e 1 na Usina B –
Tensão no extremo da LT

A.4 Sistema Tronco

A.4.1 Energização da primeira LT BarraA-BarraB

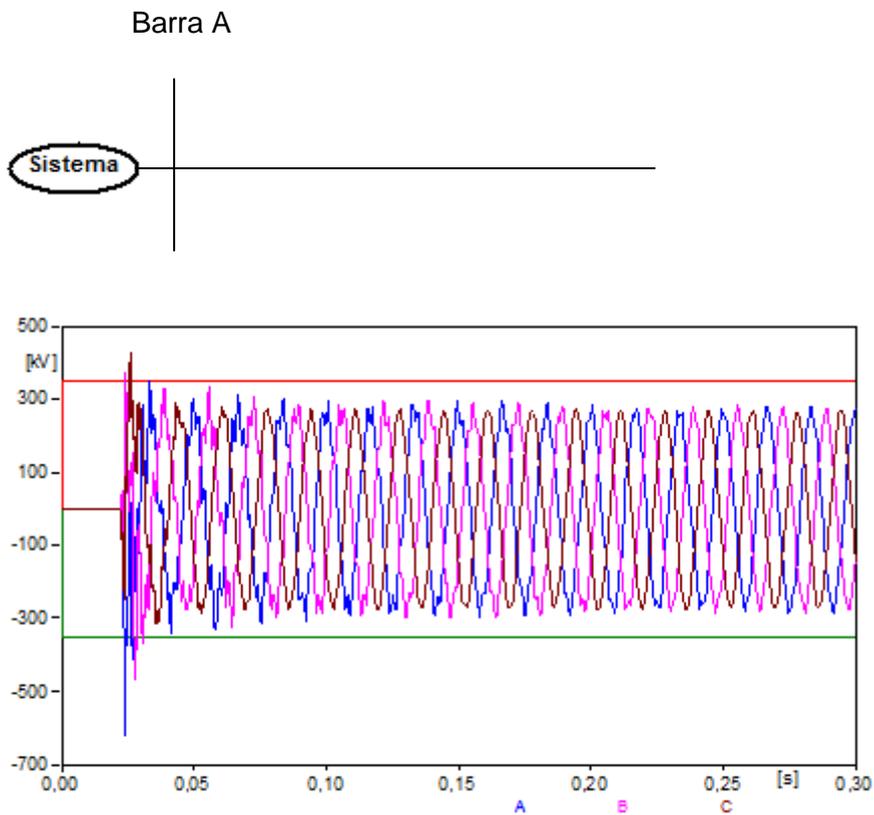
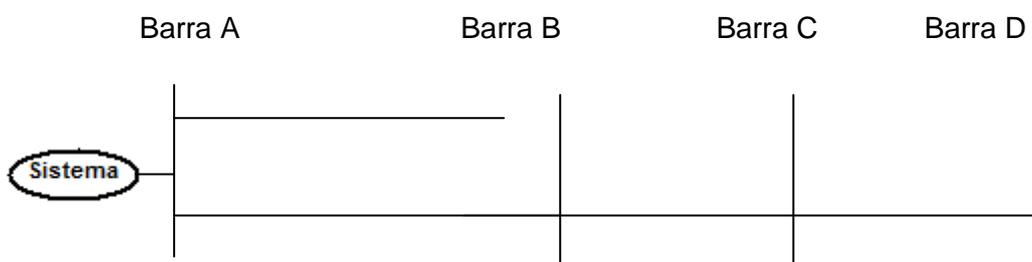


Figura 56 - Energização da primeira LT - Tensão no extremo da LT

A.4.2 Energização da segunda LT BarraA-BarraB sem reator na Barra D



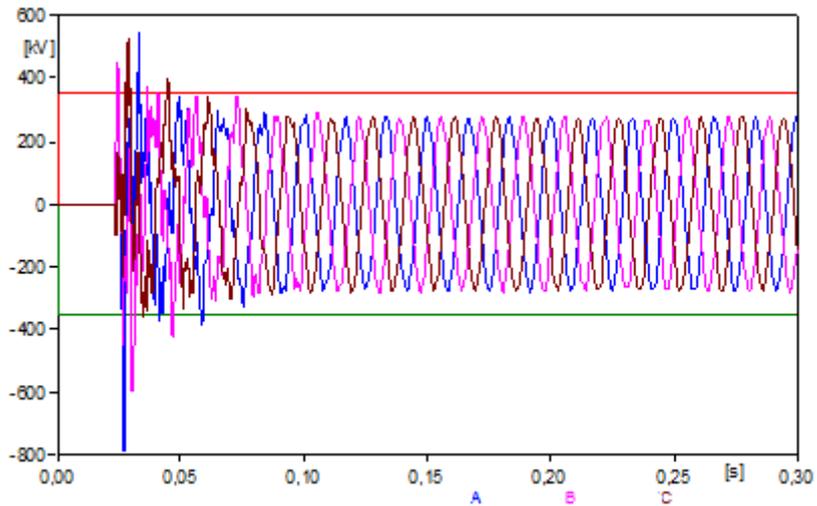
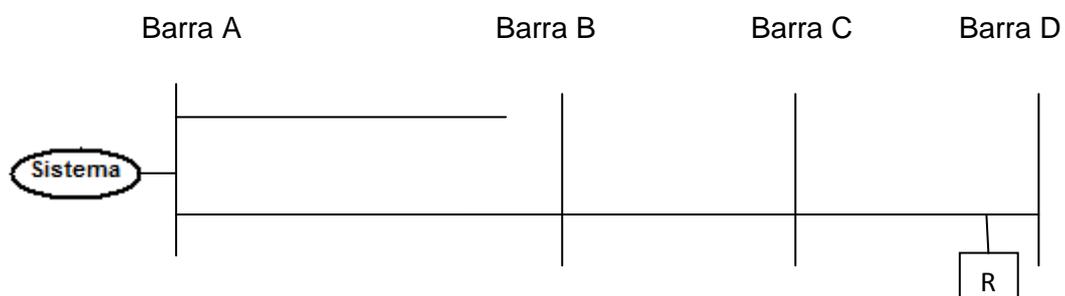


Figura 57 – Energização da segunda LT - Tensão no extremo da LT

A.4.3 Energização da segunda LT Barra A- Barra B com reator na Barra D



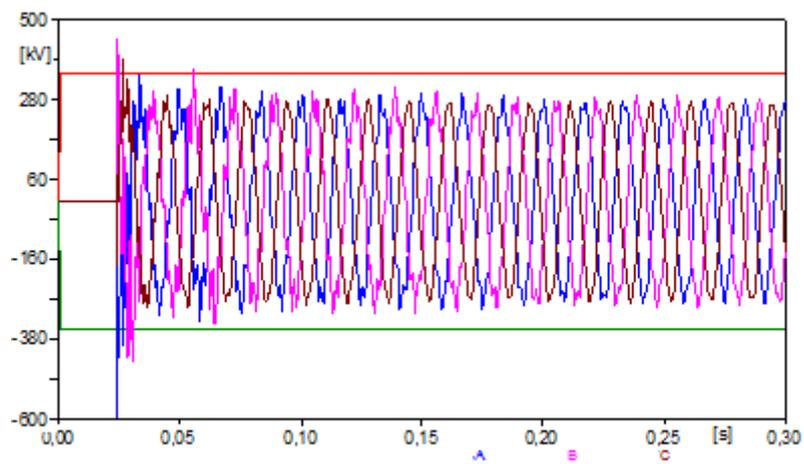


Figura 58 – Energização da segunda LT - Tensão no extremo da LT

APÊNDICE B

REDES NEURAIS

B.1 Considerações Iniciais

Neste apêndice são apresentados os conceitos básicos de redes neurais, os elementos básicos do neurônio artificial, as principais funções de ativação utilizadas e os diversos tipos e algoritmos de aprendizagem.

B.2 Introdução

A rede neural artificial é uma técnica de Inteligência Computacional que tenta simular o funcionamento do cérebro humano, de uma maneira simplificada. Ela é capaz de reconhecer padrões, extrair regularidades e detectar relacionamentos em um conjunto de dados aparentemente desconexos.

Uma rede neural, segundo Haykin [24], pode ser definida como, um processador maciçamente paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. Ela assemelha-se ao cérebro em dois aspectos: o conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem e forças de conexão entre neurônios (os pesos sinápticos) são utilizadas para armazenar o conhecimento adquirido.

As redes neurais são formadas por neurônios e conexões entre eles. O neurônio representa uma região onde informações são processadas. Seus três elementos básicos são: os pesos sinápticos, a função de soma e a função de ativação.

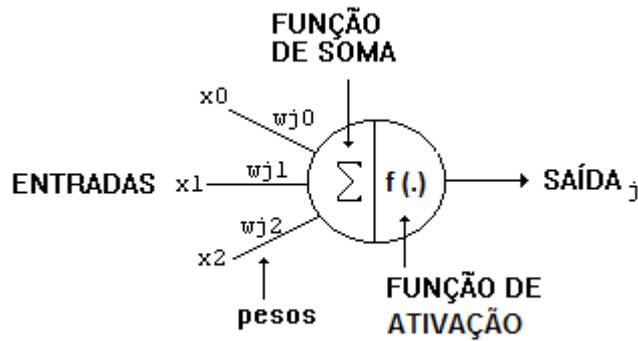


Figura 59 - Neurônio Artificial

As conexões entre os neurônios, denominadas pesos sinápticos, são responsáveis pelo armazenamento das informações. Além disso, elas definem o efeito que a saída de um neurônio exerce sobre a entrada do neurônio seguinte. Os pesos sinápticos de um neurônio artificial podem assumir valores positivos e negativos. .

A função de soma processa os estímulos ponderados pelos respectivos pesos, ou seja:

$$u_j = \sum_{i=0}^n w_{ji} y_i \quad (\text{B.1})$$

onde y_i é a saída gerada por cada neurônio da camada anterior.

Já a função de ativação, limita a amplitude do intervalo do sinal de saída do neurônio para algum valor finito, geralmente no intervalo normalizado $[0,1]$ ou $[-1,1]$.

$$y_j = f(u_j) \quad (\text{B.2})$$

Dentre as principais funções de ativação utilizadas, os tipos básicos são:

a) Função Degrau. É o tipo mais simples de função de ativação. Sua resposta pode assumir dois valores:

$$f(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ 0 & \text{se } u < 0 \end{cases} \quad (\text{B.3})$$

b) Função Linear. Um exemplo de função linear pode ser descrito como:

$$f(u) = \begin{cases} 1 & \text{se } u \geq \frac{1}{2} \\ u & \text{se } -\frac{1}{2} < u < \frac{1}{2} \\ 0 & \text{se } u \leq -\frac{1}{2} \end{cases} \quad (\text{B.4})$$

onde $(-\frac{1}{2}$ e $\frac{1}{2})$ é o intervalo que define a saída linear e 0 e 1 são os limites mínimo e máximo da função.

c) Função Sigmóide. Esta função assume valores em um intervalo contínuo entre 0 e 1. Sua fórmula é dada por:

$$f(x) = \frac{1}{1 + \exp(-\alpha x)} \quad (\text{B.5})$$

na qual α determina a inclinação da função.

Além dos elementos básicos já citados, o neurônio pode ainda apresentar um bias que tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação [24].

Usualmente as redes neurais apresentam três níveis de camadas de neurônios

a) uma camada de entrada: onde os padrões são apresentados à rede;

b) uma camada de saída: onde o resultado é apresentado;

c) camadas intermediárias ou ocultas: onde é feita a maior parte do processamento, através das conexões ponderadas. Elas situam-se entre a camada de entrada e a camada de saída e podem ser consideradas como extratoras de características.

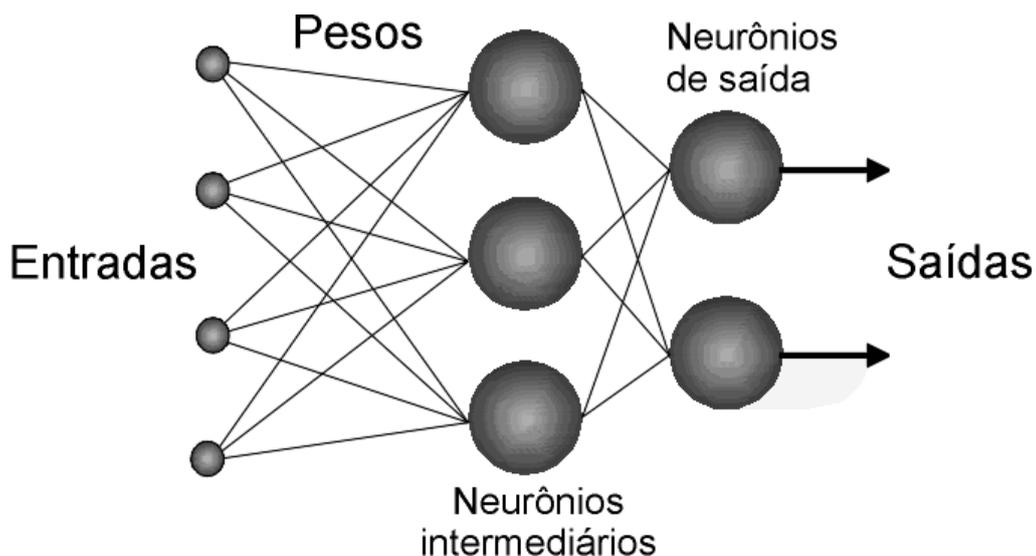


Figura 60: Estrutura de uma Rede Neural

A camada de entrada, na verdade, não é formada por neurônios reais, pois eles não realizam nenhum processamento. Eles simplesmente distribuem os valores das entradas da rede para os neurônios da primeira camada oculta. Já a camada intermediária, também denominada camada oculta, tem a função de processar a informação provinda da camada de entrada.

O tipo de conexão, número de camadas de neurônios e o tipo de treinamento são os aspectos que diferem os tipos de redes neurais. Cada um é mais adequado para determinado tipo de tarefa. Os diferentes tipos de conexões entre os neurônios de uma rede determinam a topologia (ou arquitetura) desta rede. As principais topologias de rede são descritas a seguir.

a) Redes alimentadas adiante (feedforward) – os neurônios estão dispostos em camadas conectadas por pesos unidirecionais na direção da entrada para saída. Esta estrutura é totalmente conectada uma vez que cada um dos os nós de uma camada da rede está conectado a todos os nós da camada adjacente seguinte.

b) Redes recorrentes – Um neurônio pode receber entradas de qualquer outra camada da rede. Destas fazem parte as redes com realimentação nas quais os neurônios da entrada recebem sinais vindos diretamente dos neurônios da saída.

A rede neural deve ter a capacidade de generalização, ou seja, ela deve ser capaz não apenas de classificar as entradas para as quais ela recebe treinamento, mas também de generalizar e classificar entradas que não tenham sido a ela apresentadas. Isto é possível graças a um processo de aprendizagem ao qual a rede é submetida. Esta propriedade permite que a rede encontre respostas corretas mesmo quando os dados disponíveis para as entradas estão incompletos ou danificados.

O desenvolvimento de uma rede neural ainda é um processo de tentativa e erro. A seleção da rede envolve a escolha da topologia da rede (ou arquitetura), da função de transferência e do algoritmo de aprendizagem.

A definição da estrutura de uma rede neural para a resolução de um determinado problema depende de vários fatores, entre eles: [25]

- complexidade do problema;
- dimensionalidade do espaço de entrada;
- características dinâmicas ou estáticas;
- conhecimento a priori sobre o problema;
- representatividade dos dados

B.3 Processo de Aprendizagem

A propriedade mais importante das redes neurais é a habilidade de aprender de seu ambiente e com isso melhorar seu desempenho. Isto é feito através de um processo iterativo de ajustes aplicado a seus pesos, o treinamento. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas. O procedimento utilizado para realizar o processo de aprendizagem é chamado de algoritmo de aprendizagem.

O processo de aprendizagem nas redes neurais acontece internamente por meio do ajuste dos pesos sinápticos das conexões durante a exposição dos exemplos, em resposta aos erros gerados pela rede. Ou seja, a rede neural é capaz de modificar-se, ajustando seus pesos sinápticos, em função da necessidade de aprender a informação que lhe foi apresentada.

As redes neurais são treinadas para aprender a partir dos dados de entrada. É de extrema importância que o conjunto de treinamento escolhido seja representativo do problema em análise de forma que a rede neural possa a partir dos exemplos construir um mapeamento de entrada-saída para o problema considerado.

Como já mencionado anteriormente, a rede deve ser capaz de generalizar. Mas, ao mesmo tempo, deve-se tomar cuidado para que não aconteça um “supertreinamento” e memorização dos dados. Se uma rede neural é submetida a um supertreinamento, ela perde a capacidade de reconhecer padrões fora do conjunto de treinamento. Para evitar esta situação deve-se ter um conjunto de teste com dados diferentes do conjunto de treinamento, e a rede deve ser capaz de classificá-los corretamente, provando assim sua flexibilidade e capacidade de generalização.

Os três principais paradigmas de aprendizagem são apresentados a seguir [27]:

a) Aprendizagem supervisionada, quando é utilizado um agente externo que indica à rede a resposta desejada para o padrão de entrada. O ajuste dos pesos ocorre quando o sistema compara a saída da rede com a resposta desejada previamente conhecida.

b) Aprendizagem não-supervisionada, quando não existe um agente externo indicando a resposta desejada para os padrões de entrada. A rede neural utiliza os neurônios como classificadores, e os dados de entrada como elementos de classificação. Esse tipo de rede trabalha essas entradas e se organiza de modo a classificá-las mediante algum critério de semelhança.

c) Aprendizagem híbrida, que mescla os conceitos apresentados acima. Parte dos pesos é determinada através da aprendizagem supervisionada, enquanto outros são obtidos através da aprendizagem não-supervisionada.

Em um processo de aprendizagem, os pesos dos neurônios são ajustados através de um algoritmo de aprendizagem. O algoritmo de aprendizagem é um conjunto preestabelecido de regras bem-definidas para resolução de um problema de aprendizagem

Ele tem como objetivo encontrar pesos para a rede que permitam que esta gere saídas compatíveis com as desejadas. Os algoritmos existentes diferem entre si pela forma como ocorre o ajuste dos pesos sinápticos dos neurônios, ou seja, pela regra de aprendizagem adotada.

De acordo com Haykin [24], existem cinco regras básicas de aprendizagem através das quais os pesos sinápticos de uma rede podem ser ajustados: aprendizagem por correção de erro, baseada em memória, hebbiana, competitiva e aprendizagem de Boltzmann.

Aprendizagem por correção de erro

A aprendizagem por correção de erro é baseada no paradigma de aprendizagem supervisionada no qual a saída desejada para cada padrão de entrada é fornecida para a rede. O sinal de saída gerado pela rede é comparado com a resposta desejada, produzindo um sinal de erro.

O sinal de erro é então utilizado para ajustar os pesos das conexões com o objetivo de aproximar o sinal de saída da resposta desejada, reduzindo o erro.

Aprendizagem baseada em memória [27]

Nesta regra de aprendizagem, todas as experiências passadas são armazenadas em uma grande memória de exemplos de entrada-saída classificados corretamente: (x_i, d_i) , onde $i = 1..n$, x_i representa um padrão de entrada e d_i representa a resposta desejada correspondente. Quando se deseja classificar um vetor de teste X (não visto antes), o algoritmo responde buscando e analisando os dados de treinamento em uma “vizinhança local” de X .

Esta regra envolve dois ingredientes essenciais, e a forma como eles são definidos é que vai diferenciar os algoritmos de aprendizagem baseada em memória entre si. Os ingredientes são: o critério utilizado para definir a vizinhança local do vetor de teste X e a regra de aprendizagem aplicada aos exemplos de treinamento em uma “vizinhança local” de X .

Aprendizagem hebbiana [27]

O postulado de aprendizado de Hebb é a mais antiga regra de aprendizagem existente. O princípio básico desta regra é: se dois neurônios em ambos os lados de uma conexão são ativados simultaneamente, então a força desta conexão é seletivamente aumentada.

Uma vantagem desta regra é que a aprendizagem é feita localmente, ou seja, a mudança nos pesos depende somente da ativação dos dois neurônios conectados pelo peso, o que simplifica bastante a complexidade da aprendizagem.

Aprendizagem competitiva [27]

Na regra de aprendizagem competitiva, os neurônios da camada de saída competem entre si para se tornarem ativos, considerando que somente um neurônio pode estar ativo em um determinado instante.

Para um neurônio ser o vencedor, isto é, estar ativo, seu campo local induzido v_k para um padrão de entrada x deve ser o maior dentre todos os neurônios da rede. Quando isto acontece, o sinal de saída y_k deste neurônio é igual a um. Caso contrário o sinal de saída é colocado em zero

Este tipo de aprendizagem é adequado para descobrir características nos dados de entrada que podem ser utilizadas para agrupar padrões similares.

Aprendizagem de Boltzmann [27]

A regra de aprendizagem de Boltzmann é um algoritmo de aprendizagem estocástico que realiza o ajuste dos pesos baseando-se na probabilidade e na mecânica estatística. A rede neural que utiliza esta regra é denominada máquina de Boltzmann.

Os neurônios nesta máquina formam uma estrutura recorrente e podem assumir dois estados: ligado (+1) ou desligado (-1). Os estados de cada neurônio na máquina determinam o valor de uma função de energia que caracteriza esta rede.

B.4 Algoritmo Backpropagation

Este algoritmo consiste em realizar a retropropagação do erro gerado na comparação entre a saída da rede e a saída desejada com o objetivo de minimizar o erro total da saída gerada pela rede. O treinamento de uma rede através deste algoritmo envolve três etapas: a propagação dos dados da camada de entrada para a camada de saída da rede, o cálculo e a retropropagação do erro gerado pela rede, e o ajuste dos pesos.

Na primeira etapa, estímulos de entrada são apresentados à rede e as ativações fluem até chegarem à camada de saída, gerando um resultado. Já na segunda e terceira etapas, o resultado obtido pela rede é comparado com a saída desejada e o erro gerado é computado para as unidades de saída. Os pesos conectados às unidades de saída são então ajustados para reduzir este erro. Em seguida, o erro da camada de saída é utilizado para derivar estimativas de erro para as unidades da(s) camada(s) oculta(s), para que o erro seja então propagado para trás até a conexão da camada e entrada.

O método backpropagation atualiza os pesos incrementalmente, depois de analisar cada par entrada-saída. Depois da apresentação de todos os pares entrada-saída diz-se que uma época foi concluída. Este treinamento, em geral, requer muitas épocas.

APÊNDICE C

CLASSIFICADORES

C.1 Considerações Iniciais

Conforme descrito no capítulo I o objetivo do trabalho foi desenvolver uma ferramenta para apoio a decisão dos operadores, durante o Restabelecimento do Sistema na fase de tempo real, que pudesse determinar se um determinado elemento do sistema elétrico pode ser ou não energizado sem violação dos valores admissíveis de sobretensão transitórias e sustentadas. Este problema foi abordado como um problema de classificação com duas classes possíveis: energização viável ou não. Neste apêndice serão apresentados alguns fundamentos teóricos, discutidos diversos tipos de classificadores e justificada a escolha da rede neural para classificar a energização do circuito.

C.2 Introdução

Diversas técnicas têm sido usadas para extrair conhecimento de dados. Estes padrões após terem sido identificados e validados podem ser utilizados para classificar novos exemplares. Entre estas técnicas existentes podemos citar as redes neurais, árvores de decisão, classificadores Bayesianos e classificadores lineares.

A tarefa de classificação é um processo que mapeia um espaço de padrões de entrada num espaço de classes. Para que um classificador, tendo como entrada um conjunto de padrões desconhecidos, forneça como saída rótulos que identifiquem a que classes tais padrões provavelmente pertençam, ele deve ser treinado utilizando

um conjunto de amostras em número suficiente e que seja representativo do problema em análise, chamado conjunto de treinamento.

Este treinamento é utilizado pelo algoritmo do classificador para determinar as fronteiras de decisão do espaço de características. Fronteiras de decisão são superfícies multidimensionais no espaço de características que particionam o espaço em regiões correspondentes as classes.

Cada exemplo, ou padrão de treinamento, é descrito por um vetor de valores de atributos, que descrevem o objeto de interesse, sendo que cada atributo descreve uma característica ou aspecto de um exemplo, e pelo rótulo da classe associada. É de grande importância a seleção adequada de características que irão compor os padrões de treinamento de forma a se obter um subespaço de menor dimensão possível, mas que preserve o poder de discriminação das classes.

Apesar da existência de vários algoritmos diferentes para determinar as fronteiras de decisão os objetivos principais são minimizar o erro de classificação e permitir que a classificação seja eficiente computacionalmente. Portanto, não existe um único algoritmo que apresente o melhor desempenho para todos os problemas. A escolha da técnica a ser utilizada depende fundamentalmente do problema em análise.

C.3 Classificador Bayesiano

O classificador Bayesiano pertence a classe dos classificadores probabilísticos e assumem como conhecida a distribuição de probabilidade “a priori” para as variáveis de entrada .

Cada padrão é representado por um vetor de características x

$$x = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \quad (\text{C.1})$$

Um dado padrão deve ser classificado em uma das C classes, w_1, w_2, \dots, w_c com base no seu vetor de características. Assume-se que o vetor de características possui uma f.d.p típica de sua classe, tal como a Gaussiana.

A tarefa de classificação consiste em associar um rótulo ao vetor de observações x . Uma abordagem probabilística envolve a modelagem da distribuição conjunta do espaço de observações e da classe. Conhecida a distribuição, a escolha da classe que maximiza a taxa de acerto esperada do classificador é feita utilizando-se a regra de decisão de Bayes.

$$P(w_j|x) = \frac{p(x|w_j)P(w_j)}{p(x)} \quad (\text{C.2})$$

Onde $P(w_j|x)$ representa a probabilidade a posteriori, $p(x|w_j)$ a densidade de probabilidade condicional, $P(w_j)$ a probabilidade a priori e a densidade de probabilidade $p(x) = \sum_{j=1}^c p(x|w_j)P(w_j)$ um fator de escala .

Neste classificador, que se baseia na regra de Bayes para cálculo da probabilidade condicional, uma das premissas adotadas, além da consideração da distribuição normal para os atributos numéricos, é que os atributos são tratados como se fossem completamente independentes, quando em muitas aplicações isto não ocorre. É necessário também que existam dados suficientes para treinamento de forma a estimar precisamente os parâmetros das distribuições.

Além disso, a consideração de atributos redundantes pode atrapalhar todo o processo de aprendizagem do classificador [28], sendo de extrema importância a seleção adequada de atributos para melhorar o desempenho do mesmo.

No caso de restabelecimento de sistema de potência além de não se conhecer a distribuição de probabilidade das variáveis de entrada, existe uma interdependência clara entre os atributos considerados. A tensão máxima que permite a energização de um circuito é dependente da presença ou não do reator do circuito ou a tensão no barramento é bastante influenciada pela configuração do sistema no momento da energização. Por estes motivos este classificador não foi utilizado para o problema em questão.

C.4 Árvores de Decisão

Árvore de decisão é um dos métodos de aprendizado simbólico mais amplamente utilizados para inferência indutiva, podendo também ser utilizado como método de preparação de dados para servir de entrada para outros algoritmos de mineração de dados como, por exemplo, uma rede neural. Além disso, permite a extração de regras utilizadas na classificação, característica bastante importante para aceitação do método pelos usuários em determinadas aplicações.

Apresenta também a vantagem de ser pouco sensível a alguns erros nos dados ou dados incompletos, de não necessitar de um pré-processamento de dados e de considerar apenas os atributos que tem influência na classificação (seleção de atributos).

A árvore é composta de nós onde é testado um atributo particular. Basicamente existe o nó raiz que inicia a árvore, os nós comuns que dividem um determinado atributo e

geram ramificações e os nós folha que contém as informações de classificação do algoritmo. As ramificações possuem os valores possíveis do atributo indicado no nó.

Para classificar uma amostra desconhecida, percorrem-se os ramos e nós da árvore de acordo com os valores dos atributos da amostra desconhecida e quando uma folha é atingida a instância é classificada de acordo com a classe atribuída a folha.

O problema de construção de uma árvore de decisão pode ser resumido da seguinte forma: primeiro selecione um atributo para colocar no nó raiz e construa ramos para cada valor possível deste atributo, isto divide o conjunto de exemplares em subconjuntos, um para cada atributo; em seguida repita o processo para cada ramo utilizando para nós somente os atributos que realmente dividem o ramo. Se em algum momento todos os exemplares num nó têm a mesma classificação, o desenvolvimento desta parte da árvore é parado.

Existem diversos algoritmos que constroem árvores de decisão, entre eles ID3, C4.5, CART. O algoritmo utiliza testes estatísticos para selecionar os atributos que serão utilizados no nó raiz e demais nós para melhor classificar os dados.

O objetivo do algoritmo de aprendizado de árvores de decisão é gerar a menor árvore que classifique corretamente todo o conjunto de exemplos. Para isso, é preciso escolher, a cada passo, o atributo mais relevante, ou seja, o atributo que melhor agrupa os exemplos segundo os valores das suas respectivas classes. Uma das diferenças entre os algoritmos de aprendizado de árvores de decisão é a função de escolha do atributo mais relevante. O cálculo do ganho para cada atributo e escolha do atributo que produz o maior ganho até que todos os nós folha sejam puros, ou seja todos os exemplares tenham a mesma classificação, tem sido amplamente utilizado na construção de árvores de decisão.

A árvore de decisão foi desenvolvida e aperfeiçoada por muitos anos pelo Prof. Ross Quinlan da Universidade de Sydney, na Austrália. O uso da razão de ganho foi um dos

muitos aperfeiçoamentos feitos para o ID3. O C4.5 é um outro aperfeiçoamento que inclui métodos para lidar com atributos numéricos, valores incompletos, dados ruidosos e geração de regras das árvores [28]. O algoritmo C4.5 particiona recursivamente um conjunto de treinamento, até que cada subconjunto deste particionamento contenha casos de uma única classe. Para identificar o nó raiz e os nós subseqüentes são utilizados o cálculo de entropia e o ganho de informação. A entropia é uma medida que indica o grau de aleatoriedade do atributo e é calculado através da expressão:

$$\text{Entropia}(D) = - \sum_{j=1}^C p(D, j) \cdot \log_2(p(D, j)) \quad (\text{C.3})$$

Onde $p(D, j)$ é a proporção de casos em D que pertencem à classe j , e C é o número total de classes. Quanto menor o valor da entropia, menor o grau de aleatoriedade do atributo, ou seja, melhor a capacidade de previsão. A entropia de um conjunto pode ser definida como sendo o grau de pureza do conjunto

O ganho de informação mede a redução da entropia causada pela partição dos exemplos de acordo com os valores do atributo. Portanto, o ganho de informação é obtido através da seguinte expressão :

$$\text{Ganho}(D, T) = \text{Entropia}(D) - \sum_{i=1}^K \frac{|D_i|}{|D|} \cdot \text{Entropia}(D_i) \quad (\text{C.4})$$

Onde k é a quantidade de classes, D_i são os casos por classe e $\text{Ganho}(D, T)$ significa a redução na entropia de D , ordenando pelo atributo T .

Analisando-se uma árvore montada podem ser extraídas as regras utilizadas na classificação.

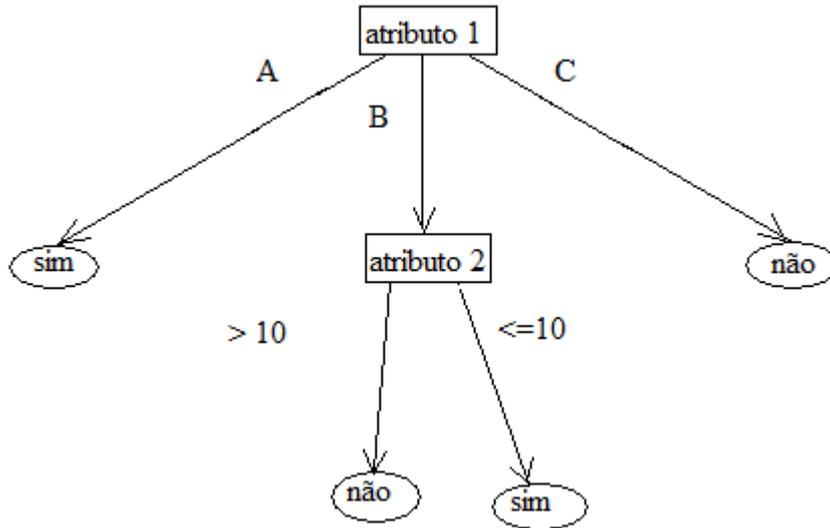


Figura 61 - Exemplo de árvore de decisão

Se atributo 1 = A então sim

Se atributo 1 = B e atributo 2 > 10 então não

Se atributo 1 = B e atributo 2 < = 10 então sim

Se atributo 1 = C então não

Um conjunto de regras pode ser extraído diretamente de uma árvore de decisão. Uma regra é gerada por cada folha. O antecedente da regra inclui uma condição para todo nó ou caminho da raiz até a folha e o conseqüente da regra é a classe atribuída a folha. Este procedimento produz regras que não são ambíguas em que a ordem em que são executadas é irrelevante. Entretanto, em geral, regras que são lidas diretamente de uma árvore de decisão são mais complexas que o necessário e são usualmente podadas para remover testes desnecessários.

A simplicidade da forma com que regras podem ser extraídas de árvores de decisão utilizando o algoritmo C4.5 e o formato com que as mesmas se apresentam, que se

assemelha bastante as Instruções de Operação utilizadas atualmente para apoio ao pessoal de operação durante o restabelecimento de sistema elétrico de potência, motivaram a escolha deste método para extração de regras dos dados utilizados no processo de classificação.

C.5.Redes Neurais

C.5.1 Perceptron

O perceptron é um classificador que opera sob a premissa de que os padrões a ser classificados sejam linearmente separáveis. Portanto a utilização do perceptron deve estar restrita a solução de problemas linearmente separáveis, ou seja, a problemas cuja solução possa ser obtida pela separação de duas regiões por meio de uma reta ou um hiperplano para o caso n-dimensional. A regra de aprendizado do perceptron é o algoritmo que acha o hiperplano de separação.

$$w_0 + w_1 x_1 + w_2 x_2 + \dots + w_n x_n = 0 \quad (C.5)$$

onde:

$x_0, x_1, x_2, \dots, x_n$ são os valores dos atributos e $w_0, w_1, w_2, \dots, w_K$ são os pesos que definem o hiperplano. O atributo x_0 têm sempre o valor 1 (bias).

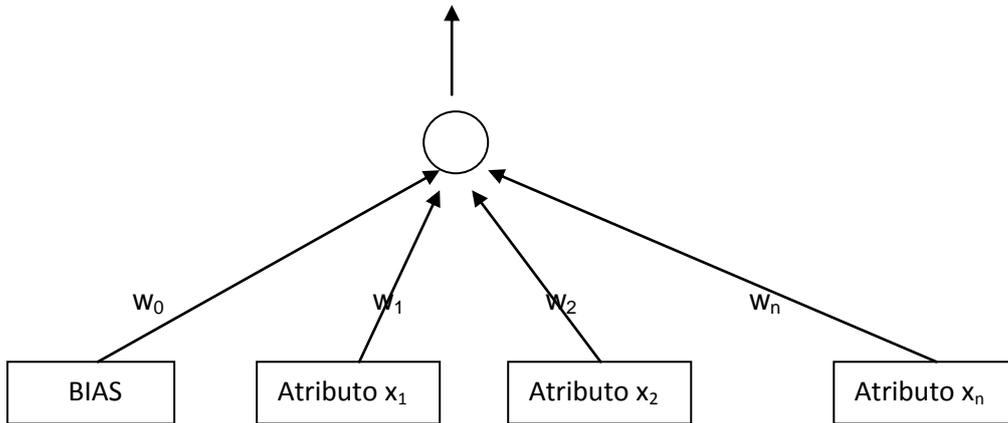
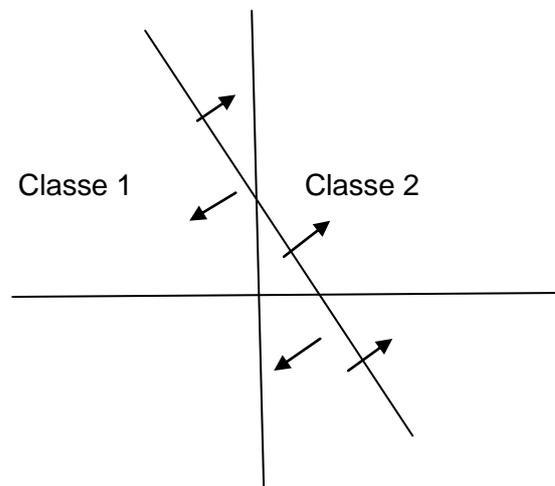


Figura 62 - Perceptron

Se a soma é maior que zero a classe é 1, caso contrário a classe é 0. Os valores dos pesos sinápticos do perceptron são ajustados de iteração para iteração até que os dados de treinamento sejam corretamente classificados pelo hiperplano.

A figura mostra o hiperplano, neste caso uma reta, como fronteira de decisão para um problema de classificação de padrões bidimensional de duas classes.



Fronteira de decisão

$$w_1 x_1 + w_2 x_2 + b = 0$$

Figura 63 - Fronteira de decisão

Este tipo de classificador foi utilizado no início do trabalho em alguns testes para restabelecimento de circuitos em sistemas mais simples apresentando um desempenho bastante satisfatório. Nestes circuitos cada padrão de entrada é composto de três atributos: tensão, número de máquinas na usina e configuração do sistema (sistema completo ou não). A representação gráfica dos dados de entrada evidenciou a existência de um hiperplano de separação entre exemplares de cada classe (energização possível ou não), justificando este bom desempenho.

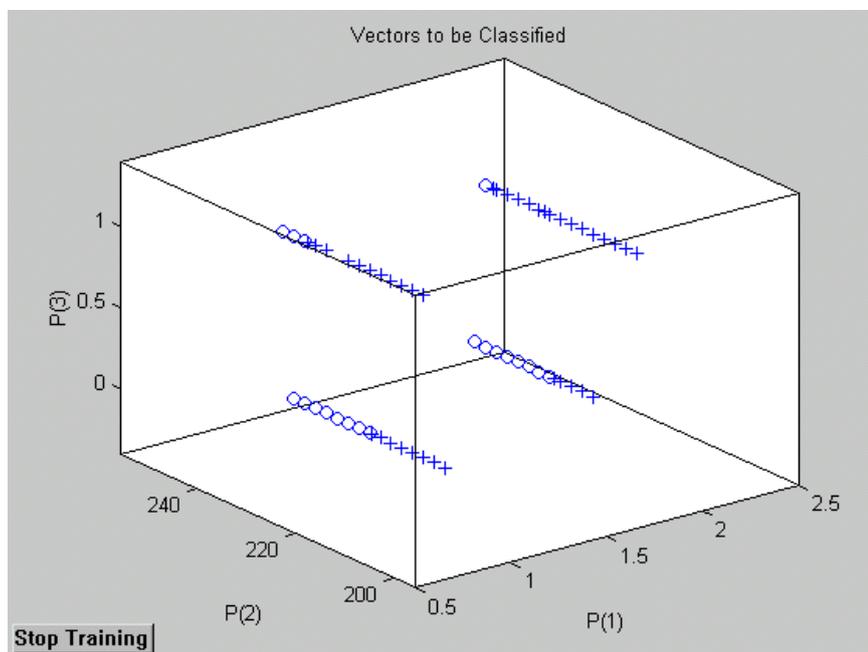


Figura 64 – Representação gráfica dos dados de entrada

O perceptron é a forma mais simples de uma rede neural usada para classificação de padrões linearmente separáveis (padrões que se encontram em lados opostos de um hiperplano) [24].

Posteriormente testes realizados utilizando o perceptron para classificação em restabelecimento de sistemas mais complexos, com diferentes atributos de entrada

não apresentaram bons resultados. Diversas combinações de número de máquinas nas usinas, tensões, configuração do sistema, presença de reator no circuito a ser energizado, etc..., compõem os padrões que não são linearmente separáveis. Para estes sistemas foi necessário utilizar redes neurais MLP.

C.6 Redes Neurais MLP

Redes Neurais são técnicas computacionais que apresentam um modelo inspirado na estrutura do cérebro, que adquirem conhecimento através da experiência e podem aprender a reconhecer padrões pela exposição repetida a muitos exemplos diferentes. Elas são capazes de resolver problemas de classificação passando inicialmente por uma seção de treinamento onde se apresenta repetidamente à rede um conjunto de padrões de entrada junto com a classe à qual cada padrão pertence. A rede deverá, então, adaptar os seus pesos de forma a mapear as relações entre padrões de entrada e classes correspondentes de saída, tendo por base os dados do conjunto de treinamento. Mais tarde apresenta-se à rede um novo padrão que não foi visto antes, mas que pertence à mesma população de padrões utilizada para treinar a rede. A rede é capaz de identificar a classe daquele padrão particular por causa da informação que ela extraiu dos dados de treinamento.

O reconhecimento de padrões realizado por uma rede neural é de natureza estatística, com os padrões sendo representados por pontos em um espaço de decisão multidimensional. O espaço de decisão é dividido em regiões, cada uma das quais associada à uma classe. As fronteiras de decisão são determinadas pelo processo de treinamento. [24].

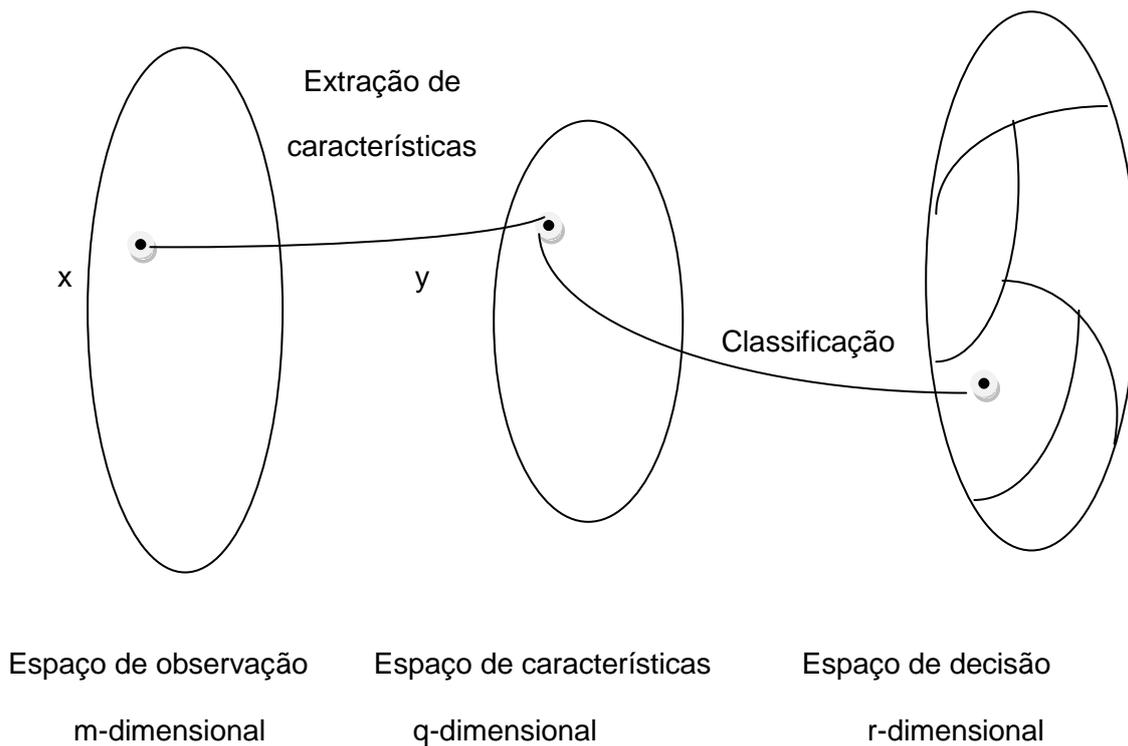


Figura 65 – Abordagem clássica para classificação de padrões

Dado um ponto x no espaço de observações m -dimensional a extração de característica é descrita por uma transformação que mapeia o ponto x para um ponto y em um espaço de características q -dimensional, com $q < m$. Esta transformação pode ser vista como uma redução de dimensionalidade cuja utilização é justificada por ela simplificar a tarefa de classificação. A própria classificação é descrita como uma transformação que mapeia o ponto intermediário y para uma das classes em um espaço de decisão r -dimensional, onde r é o número de classes a ser distinguidas. [24]

O anexo B apresentou os conceitos clássicos de Redes Neurais Artificiais, o modelo do neurônio artificial, as principais funções de ativação utilizadas, as topologias e tipos de aprendizagem existentes.

O projeto de uma rede neural compreende a seleção da arquitetura apropriada da rede e apresentação de um subconjunto de exemplos representativo do problema utilizados para treinar a rede por meio de um algoritmo apropriado (fase de aprendizagem). Em seguida o desempenho da rede é testado com dados não apresentados anteriormente (generalização).

O excelente desempenho de redes neurais para tarefas de classificação, a resposta rápida em formato simples e tolerância a falhas nos dados [23] são alguns aspectos que reforçam a possibilidade de utilização desta técnica a solução de problemas de tempo real.

As principais razões que levam a escolha das redes neurais para classificar a viabilidade de restabelecimento são:

- A existência de uma interação complexa entre os parâmetros de entrada entre si e com a saída;
- O bom desempenho para classificação destes padrões complexos e que não sejam necessariamente linearmente separáveis;
- Independem do conhecimento do tipo de distribuição de probabilidade das variáveis de entrada;
- Rapidez de resposta;
- Robustez para ruídos nos dados de entrada ;
- Capacidade de generalização.

Em contrapartida existe uma reação natural à utilização de técnicas, comumente chamadas caixas pretas, em que apenas um resultado é apresentado sem que se conheça a forma com que se chegou a esta conclusão, em especial em alguns tipos

de aplicação onde a segurança é fator primordial. Diversas pesquisas têm sido feitas em extração de regras de redes neurais como uma forma de resolver esta limitação.

C.7 Sumário

Neste apêndice foram discutidos alguns tipos de classificadores e justificada a escolha de redes neurais para classificar a energização de circuitos no restabelecimento de sistemas. Entretanto em aplicações deste tipo onde a segurança é fator primordial, existe uma reação natural a utilização de técnicas, comumente chamadas caixas pretas, onde apenas um resultado é apresentado, sem que se conheça a forma com que se chegou a esta conclusão.

APÊNDICE D

EXTRAÇÃO DE REGRAS E SISTEMAS HÍBRIDOS INTELIGENTES

D.1 Considerações Iniciais

Conforme descrito no capítulo I o objetivo do trabalho foi desenvolver uma ferramenta que pudesse ser utilizada para apoio a decisão dos operadores, durante o Restabelecimento do Sistema na fase de tempo real, que pudesse classificar a energização de um circuito como viável ou não. No capítulo III foi justificada a escolha de redes neurais para efetuar a classificação, entretanto a limitação desta técnica de não apresentar a forma com que se chegou ao resultado da classificação levou a necessidade de extração de regras para aumentar a confiança do usuário na utilização da ferramenta. Neste apêndice serão apresentados alguns métodos de extração de regras de redes neurais bem como da construção de sistemas híbridos com esta finalidade.

D.2 Extração de Regras de Redes Neurais

A falta de compreensibilidade se constitui o um dos principais obstáculos à utilização de redes neurais em aplicações onde segurança é uma preocupação primordial. Para se obter uma melhor aceitação pelos usuários é importante que se tenha um melhor entendimento de como a rede solucionou um dado problema. Além disso, a explicitação em forma de regras do conhecimento adquirido pela rede neural, após o processo de treinamento, permite sua análise por um especialista numa tentativa de

descobrir se o conjunto de dados utilizados é limitado e não representativo do problema numa tentativa de melhorar a generalização da rede.

O conhecimento adquirido por um modelo de rede neural é codificado nos pesos das conexões, que determinam os valores das funções de ativação das unidades ocultas, que são consideradas detentoras de características.

A tarefa de expressar em poucas regras o complexo mapeamento entre as entradas e saídas feito pela rede neural num compromisso entre precisão e simplicidade além de se ter um método que produza bons resultados para variáveis de entrada discretas e contínuas e que independa da arquitetura da rede tem motivado diversas pesquisas. Entre os algoritmos que têm sido propostos para extrair conhecimento de redes neurais treinadas podem ser citados como exemplo os algoritmos SUBSET, MofN, Rulex, Trepan e VIA. As referências [29, 30] descrevem estes algoritmos de forma resumida. O conhecimento extraído pode ser usado para apoiar a tomada de decisão, explicar fenômenos observados e facilitar a integração com outras técnicas como, por exemplo, os sistemas especialistas.

THRUN [31] descreve uma abordagem para a extração de regras do tipo se-então de redes neurais baseada num mecanismo de análise do intervalo de validade -*Validity Interval Analysis* (VIA). VIA é uma ferramenta genérica utilizada para extrair conhecimento simbólico de redes neurais do tipo backpropagation. Este método de extração de regras analisa a rede como um todo. As regras são do tipo SE x ENTÃO y onde x e y são descritos por um grupo de restrições lineares. Em [23] é descrita uma aplicação de redes neurais em análise de segurança de sistemas elétricos de potência que utiliza o VIA para extrair regras da rede neural treinada, adaptado ao problema de estabilidade de tensão, para utilização em tempo real.

Algumas pesquisas, entre elas [32, 33], têm sido desenvolvidas a partir do algoritmo RX que se baseia nos valores das ativações das unidades ocultas. As ativações se referem à soma, ponderada pelos pesos, das entradas da unidade. Basicamente, pode-se resumir o algoritmo de extração de regras, denominado de **RX** nos seguintes passos: [32]

- 1) Processar os eventos do conjunto de treinamento através da rede computando-se os valores de ativação das unidades ocultas;
- 2) Aplicar um algoritmo de *agrupamento* a estes valores;
- 3) Enumerar os valores de ativação discretizados e computar os respectivos valores de saída da rede. Gerar regras que descrevam as saídas da rede em termos dos valores de ativação discretizados em 2);
- 4) Para cada unidade oculta, enumerar os valores de entrada que conduzem aos respectivos valores de ativação das unidades ocultas, gerando regras que descrevam os valores discretizados das unidades ocultas em termos das entradas da rede neural.
- 5) Combinar as regras obtidas em 3) e 4) para obter as regras que relacionam as variáveis dependentes às variáveis independentes.

Este algoritmo serviu de base para a implementação do Algoritmo RX Modificado. Basicamente, as modificações realizadas no Algoritmo RX são baseadas no fato de que cada classe possui um conjunto próprio de ativações, o que sugere uma extração de regras particular para cada classe. Definido o modelo de rede neural, computam-se as ativações para cada classe, por meio da separação dos exemplos de treinamento nas diferentes classes. Além disso, esta abordagem simplifica o algoritmo, eliminando os passos 3) e 4) do Algoritmo RX. [32]

Em [34] foi criado um método chamado TREPAN que utiliza respostas à perguntas feitas à uma rede neural treinada para construir uma árvore de decisão que aproxima o conhecimento representado por essa rede. Para guiar a construção da árvore,

TREPAN utiliza um oráculo, capaz de responder a perguntas durante o processo de construção.

Em [35] é descrito um algoritmo para extrair regras de classificação de redes neurais feedforward onde as variáveis de entrada podem ser contínuas ou discretas . A principal característica do algoritmo é sua natureza hierárquica onde as regras são geradas a partir dos atributos discretos e refinadas considerando os atributos contínuos, de forma recursiva. Entretanto quando os rótulos de classe dos dados são melhor descritos como uma função não linear das entradas contínuas, as regras extraídas não serão capazes de preservar a precisão da rede neural.

Em [36] um método para extrair regras de uma rede neural utilizada como aproximador é também apresentado.

D.3 Sistemas Híbridos Inteligentes

Cada técnica inteligente tem características particulares tais como: habilidade para aprender, explicação de decisões e outras que os tornam adequados para determinados problemas e não adequadas para outros. Sistemas híbridos combinam técnicas diferentes para obter uma melhor solução para o dado problema, cada uma contribuindo numa área onde tem melhor desempenho que a outra.

A principal idéia do desenvolvimento de Sistemas Híbridos Inteligentes é que uma única técnica, em razão de suas limitações e/ou deficiências, pode não ser capaz de, por si só, resolver um dado problema. Para isso a combinação de várias técnicas pode levar a uma solução mais robusta e eficiente. [37].

Em [37] é encontrado o seguinte esquema para classificação de sistemas híbridos:

Tipo I: Substituição de função. Nessa categoria utiliza-se uma técnica para implementar uma função de outra técnica, tentando superar alguma limitação da técnica principal ou otimizar sua execução

Tipo II: Híbridos Intercomunicativos. Categoria utilizada para resolver problemas complexos que possam ser divididos em várias subtarefas independentes. O sistema híbrido é formado por módulos independentes, nos quais cada um usa uma técnica inteligente para resolver uma das subtarefas do problema principal.

Tipo III: Híbridos Polimórficos. Nessa categoria, uma única técnica é adaptada para realizar uma tarefa inerente a uma outra técnica. A motivação desta categoria é descobrir novas funcionalidades de uma técnica e entender como diferentes técnicas podem se relacionar. [37]

Sistemas neurais híbridos combinam duas ou mais técnicas para solução de um problema sendo uma delas uma rede neural. Desta forma consegue-se superar limitações ou deficiências ou melhorar o desempenho reunindo as potencialidades de cada uma das técnicas na solução de um dado problema. Algumas abordagens têm sido propostas para integrar redes neurais com algoritmos genéticos, lógica fuzzy, sistemas especialistas e árvores de decisão em diversos tipos de aplicação.

A capacidade de aprender por exemplos, excelente desempenho para classificação de padrões complexos, rapidez de resposta e capacidade de generalização das redes neurais podem ser associadas à capacidade de seleção de atributos relevantes e excelente capacidade de explanação das árvores de decisão para construção de um sistema híbrido para utilização em restabelecimento de sistema.

Além disso, consegue-se também melhorar o desempenho de generalização das redes neurais identificando regiões do espaço de entrada onde os dados de

treinamento não estão adequadamente representados, indicando as circunstâncias onde a rede neural pode falhar na generalização, descobrir características marcantes dos dados de entrada e satisfazer a crítica necessidade de segurança em uma classe especial de sistemas na qual segurança é uma condição obrigatória [24].

D.4 Sumário

Neste apêndice foram apresentadas algumas formas de apresentar ao usuário uma justificativa do resultado da classificação feita pela rede neural, uma vez que esta técnica por si só não tem esta característica. Os métodos de extração de conhecimento diretamente da rede neural tem sido objeto de diversas pesquisas, alguns deles possuem diversas limitações do tipo não apresentarem bons resultados quando se utiliza variáveis discretas e contínuas, dependerem do tipo de arquitetura da rede e algumas outras. A utilização de sistemas híbridos associando uma rede neural para fazer a classificação à uma árvore de decisão para extrair as regras utilizadas para classificação tem se mostrado uma alternativa bastante interessante.

APÊNDICE E

DADOS DO SISTEMA ELÉTRICO

E.1 Considerações Iniciais

Neste apêndice estão resumidos os dados utilizados para os diferentes sistemas teste.

E.2 Dados de Linhas de Transmissão

A tabela 9 apresenta as impedâncias das linhas de transmissão que compõem os sistemas teste 1 e 2 e o sistema tronco.

Tabela 9 – Dados de Linhas de Transmissão

Sistema	Linha de Transmissão	Impedância de Seqüência Positiva em pu Sbase=100MVA		
		Resistência	Reatância	Susceptância
Sistema teste 1	UsinaA-UsinaB	0,023	0,104	0,158
Sistema teste 1	UsinaB-UsinaC c1	0,033	0,150	0,230
Sistema teste 1	UsinaB-UsinaC c2	0,033	0,150	0,230
Sistema teste 2	UsinaA-UsinaB	0,023	0,104	0,158
Sistema teste 2	UsinaB-SE1	0,033	0,150	0,230
Sistema teste 2	UsinaB-SE2	0,030	0,136	0,208

Sistema	Linha de Transmissão	Impedância de Seqüência Positiva em pu Sbase=100MVA		
		Resistência	Reatância	Susceptância
Sistema teste 2	SE2-SE1	0,003	0,016	0,024
Sistema tronco	BarraA-BarraB c1	0,005	0,053	0,927
Sistema tronco	BarraB-BarraC c1	0,003	0,029	0,505
Sistema tronco	BarraC-BarraD c1	0,006	0,069	1,193
Sistema tronco	BarraA-BarraB c2	0,005	0,053	0,927
Sistema tronco	BarraB-BarraC c2	0,003	0,029	0,505
Sistema tronco	BarraC-BarraD c2	0,006	0,069	1,193

E.3 Dados de Transformadores

A tabela 10 apresenta as impedâncias dos transformadores dos sistemas teste 1 e 2.

Tabela 10 – Dados de Transformadores

Subestação	Tensão	Reatância em pu Sbase=100MVA
Usina A G1	230/13,8 kV	0,073
Usina A G2	230/13,8 kV	0,073
Usina B G1	230/13,8kV	0,236
Usina B G2	230/13,8kV	0,236

Subestação	Tensão	Reatância em pu Sbase=100MVA
Usina B G3	230/13,8kV	0,236
Usina B G4	230/13,8kV	0,236

E.2 Dados das Usinas

A tabela 10 apresenta os dados das usinas dos sistemas teste 1 e 2..

Tabela 11 – Dados das Usinas

Usina	Potência MVA	Tensão kV	Número de geradores
Usina A	290	13,8kV	2
Usina B	290	13,8kV	4

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] – GOMES, P., GUARINI, A. de P., BARROS, H. M., GUARINI, M. C. "Recentes Blecautes e conseqüentes aperfeiçoamentos no processo de Recomposição do Sistema Interligado Nacional", *IX SEPOPE*, Rio de Janeiro, RJ, Brasil, maio 2004
- [2] – BRETAS, A. S., CECCON, M. V., "Restauração Automática de Sistemas Elétricos de Potência através do uso de Redes Neurais Artificiais. Estudos no Sistema Elétrico Sul", *VII Congresso brasileiro de Redes Neurais*, Natal 2005
- [3] – BRETAS, A. S., PHADKE, A. G. Artificial Neural Networks in Power System Restoration, *IEEE Transactions on Power Delivery*, v.18, n.4, p.1181-1186, October 2003
- [4] – THUKARAM, D., KHINCHA, H. P., KHANDELWAL, S., "Estimation of switching transient peak overvoltages during transmission line energization using artificial neural network", *ELSEVIER-Electric Power Systems Research*, v.76, pp 259–269, India, 2006
- [5] – GIRI, J., KIRSSCHEN, D. S., SHAHIDEHPOUR, S. M. et al, ZABORSZKY, J. "New Approaches in Power System Restoration", *IEEE Transactions on Power Systems*, v.7, n.4, pp. 1428-1434, November 1992
- [6] – WU, F.F., MONTICELLI, A.J. "Analytical Tools for Power System Restoration - Conceptual Design", *IEEE Transactions on Power Systems*, v. 3, n. 1, pp. 10-26, February 1988.
- [7] – TEO, C. Y. , JIANG, W. ,GOOI, H. B. " Review of restoration strategies and a real time knowledge based approach for bulk power system restoration", *ELSEVIER-Knowledge-Based Systems* ,v. 9, pp 15-21, Singapore, 1996

- [8] – LAFÉVRE, M. A. P. “Sistemas Inteligentes e sua Aplicação na Operação de Itaipu Binacional”, *XIII SNPTEE*, Bal. Camboriú, SC, outubro 1995.
- [9] – SHIMAKURA, Y., INAGAKI, J., FUKUI, S., HORI, S., “Knowledge-based approach for the determination of restorative operation procedures for bulk power systems”, *Electrical Power & Energy System*, v.16, n.3, p 183-190, 1994
- [10] – KOSTIÈ, T., GERMOND, A., ALBA, J.J., “Optimization and learning of load restoration strategies”, *Electrical Power & Energy System*, v.20, n.2, p.131-140,1998
- [11] – CHAVES, C. M. S., *Um sistema especialista para treinamento em Recomposição de Sistemas de Transmissão de Energia Elétrica*, Tese de M.Sc., COPPE/ UFRJ , Rio de Janeiro, RJ, Brasil, 1993
- [12] – MACEDO, J. D. , CHAVES, C. M. S. , PITTA, R. L. A. ET al, “Sistema Especialista de Auxílio à Recomposição do Sistema Furnas”, *XV SNPTEE*, Foz do Iguaçu, Paraná, Brasil, outubro 1999
- [13] – LINDENMEYER, D., DOMMEL, H. W, ADIBI, M. M.,”Power system restoration - a bibliographical survey”, *Electrical Power and Energy Systems* ,v.23, pp. 219-227, 2001
- [14] – ADIBI, M. M., CLELLAND, P., FINK, L., HAPP, H., KAFKA, R., RAINE, J., SCHEURER, D. and TREFNY, F. “Power System Restoration – A Task Force Report”, *IEEE Transactions on Power Systems*, v.. 2, n. 2, pp. 271-277, May, 1987.
- [15] – ANDREWS, C. J., ARSANJANI, F., LANIER, M. W., MILLER, J. M., VOLKMANN, T. A. , WRUBEL, J. , “Special considerations in power system restoration”, *IEEE Transactions on Power Systems*, v.7, n.4, pp 1419-1427, November 1991

- [16] – ADIBI, M. M.; BORKOSKI, J. N.; KAFKA, R. J. Analytical Tool Requirements for Power System Restoration, *IEEE Transactions on Power System*, v.9, n.3, p. 1582-1591, August 1994.
- [17] – GOMES, P.; LIMA, A. C. S. de, GUARINI, A. de P. , "Guidelines for Power System Restoration in the Brazilian System", *IEEE Transactions on Power Systems*, v.19, n. 2, p. 1159-1164, May 2004.
- [18] – D'AJUZ, A., FONSECA, C. S., CARVALHO, F. M. S. et AL, *Transitórios elétricos e Coordenação de Isolamento – Aplicação em Sistemas Elétricos de Alta Tensão*, 1 ed , Rio de Janeiro, FURNAS/UFF- Editora Universitária, 1987.
- [19] – ZANETTA JÚNIOR, L. C., *Transitórios Eletromagnéticos em Sistemas de Potência*, 1 ed , São Paulo, Editora da Universidade de São Paulo, 2003
- [20] – KOSTIÈ, T., CHERKAoui, R., GERMOND, A., PRUVOT, P. " Decision aid function for restoration of transmission power systems: Conceptual design and real time considerations", *IEEE Transactions on Power Systems*, v.13, n.3, p. 923-929, August 1998
- [21] – FALCÃO, D. M., *Conjuntos, Lógica e Sistemas Fuzzy, Técnicas Inteligentes Aplicadas a Sistemas de Potência*, COPPE-UFRJ, Agosto de 2002
- [22] – ALVES, F. R .M., "*Aplicação de Buscas Heurísticas ao Problema de Determinação de Rotas Alternativas para Recomposição Fluente de Sistemas Elétricos de Potência*", Tese de D.Sc., Rio de Janeiro, RJ, Brasil, 2007.
- [23] – SILVA, A. P. A. da , "Overcoming Limitations of NNs for On-Line DSA", *IEEE PES General Meeting, Painel on Intelligent System Applications to Dynamic Security Assessment*, v.1, pp.1-8, San Francisco, 2005

- [24] – HAYKIN, S., *Redes Neurais, Princípios e Prática.*, 2 ed., Porto Alegre, Bookman, 2001.
- [25] – BRAGA, A. P., CARVALHO, A. P. L. F., LUDERMIR, T. B., *Redes Neurais Artificiais Teoria e Aplicações*, 2 ed , Rio de Janeiro, LTC, 2007
- [26] – Leuven EMTP Center, ATP - Alternative Transiente Program, Rule Book, Belgium,1987
- [27] – MELLO, M. T.,”Aplicação de Redes Neurais no processo de precificação de ações” - Universidade Federal de Pelotas, 2004
- [28] – WITTEN, I. H.,FRANK, E. *Data Mining Practical Machine Learning Tools and Techniques* , 2ªed., Morgan Kaufmann, 2005
- [29] – ALVES, C. A. M., *Uma ferramenta de extração de regras de redes neurais* Tese de M.Sc., COPPE/UFRJ , Rio de Janeiro, RJ, Brasil, 2001
- [30] – NOBRE, C. N., Um estudo comparativo entre técnicas clássicas e conexionistas de Extração de conhecimento e Mineração de dados , CPDEE – Universidade Federal de Minas Gerais , 1998
- [31] – THRUN, S., “Extracting Rules from Artificial Neural Networks with Distributed Representations”, *Advances in Neural Information Processing Systems*, 1995.
- [32] – HRUSCHKA, E. R., *Algoritmos genéticos de agrupamento para extração de regras de redes neurais*, Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 2001.
- [33] – HRUSCHKA, E. R., EBECKEN, N. F. F., “Extração de Regras de Redes Neurais por meio do Algoritmo RX Modificado : Um exemplo de Aplicação em Modelagem de Dados Metereológicos”, IV Conferência Brasileira de Redes Neurais , p.047-051, ITA, São José dos Campos , SP, Brasil,July 1999.

- [34] – CRAVEN, M. W., “Extracting comprehensible Models from Trained Neural Networks”, Tese de D.Sc., University of Wisconsin, Madison, 1996
- [35] – SETIONO, R., BAESENS, B., MUES, C., “Recursive Neural Network Rule Extraction for Data With Mixed Attributes”, *IEEE Transactions on Neural Networks*, v.19, n..2, February 2008.
- [36] – SETIONO, R.,LEOW, W. K., ZURADA, J. M. ”Extraction of Rules from Artificial Neural Networks for Nonlinear Regression”, *IEEE Transactions on Neural Networks*, v.13, n.3, May 2002.
- [37] – RESENDE, S. O., *Sistemas Inteligentes Fundamentos e Aplicações*, 1 ed São Paulo, Manole, 2005
- [39] – J. F. Neto, E. Sodr , M. A. Carvalho Jr., Monitora o da Seguran a Est tica do Sistema Sul – Sudeste atrav s da Tecnologia de Redes Neurais, IV Confer ncia Brasileira de Redes Neurais, S o Jos  dos Campos - SP – julho 1999 – ITA.
- [40] – ADIBI, M. M., BORKOSKI, J. N., KAFKA, R. J. “ Power System Restoration – The Second Task Force Report, *IEEE Transactions on Power System* , v.2, n.4, p.927-933, November 1987
- [41] – M.M. Adibi, D. Barrie.M.E. Cooper, K.W. Heusssner, M.E. Robertson, J. L. Scheidt, D.Scheurer – System Operations Challenges, *IEEE Transactions on Power System*, v.3, n.1, p.118-124, February 1988
- [42] – M.M. Adibi, R.J. Kafka – Power System Restoration Issues, *IEEE Computer Applications in Power System*, v.4, n.2, p.19-24, April 1991

[43] – M.M.Adibi – Special consideration in power system restoration – The second working group report, *IEEE Transactions on Power System*, v.9, n.1, p.15-21, February 1994

[44] – ANCONA, J.J. "A framework for power system restoration following a major power failure", *IEEE Transactions on Power Systems*, v.10,n.3, pp. 1480-1485, August 1995

[45] – E. Martineli, *Extração de conhecimento de Redes Neurais Artificiais*, Tese M.Sc, USP – São Carlos, 1999.

[46] – ONS, *Procedimentos de Rede, Submódulo 23.3 – Diretrizes e Critérios para Estudos Elétricos*, Julho, 2001.

[47] – ONS, *Procedimentos de Rede, Manual de Procedimentos da Operação, submódulo 10.11, Norma de Operação – Recomposição da Rede de Operação após Perturbação*