



COPPE/UFRJ

**CONTROLE REGIONAL DE TENSÃO UTILIZANDO LÓGICA FUZZY E
APRENDIZADO POR REFORÇO**

Alessandro Bulhões Marques

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.

Orientadores: Glauco Nery Taranto
Djalma Mosqueira Falcão

Rio de Janeiro
Agosto de 2009

CONTROLE REGIONAL DE TENSÃO UTILIZANDO LÓGICA FUZZY E
APRENDIZADO POR REFORÇO

Alessandro Bulhões Marques

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ
COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE) 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. Glauco Nery Taranto, Ph.D.

Prof. Djalma Mosqueira Falcão, Ph.D.

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

Prof. Antônio Carlos Zambroni de Souza, Ph.D.

Prof. Júlio César Stacchini de Souza, D.Sc.

Prof. Ricardo Tanscheit, Ph.D.

RIO DE JANEIRO, RJ - BRASIL

AGOSTO DE 2009

Marques, Alessandro Bulhões

Controle Regional de Tensão Utilizando Lógica Fuzzy e Aprendizado por Reforço / Alessandro Bulhões Marques. – Rio de Janeiro: UFRJ/COPPE, 2009.

XIII, 153 p.: il.; 29,7 cm.

Orientadores: Glauco Nery Taranto

Djalma Mosqueira Falcão

Tese (Doutorado) – UFRJ/ COPPE/ Programa de Engenharia Elétrica, 2009.

Referencias Bibliográficas: p. 130-134.

1. Lógica Fuzzy. 2. Aprendizado por Reforço. 3. Controle de Tensão. I. Taranto, Glauco Nery *et al.*.II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

A minha esposa, Bianca
e aos meus filhos, Maria Clara e Gabriel Augusto

Agradecimentos

No momento em que elaboro este documento me vem a recordação uma estatística que ouvi quando ainda era criança. Naquela época, dizia-se que a probabilidade de um aluno de escola pública atingir a graduação era de uma em mil. Mesmo sem saber de que lado dos dados estaria, a única certeza era de que, diante das dificuldades, estudaria todo o tempo em escolas públicas. Porém, estamos aqui e em grande parte pelo incentivo que recebia toda vez que manifestava dúvida sobre até onde chegaria, quando então ouvia a seguinte frase: “Meu filho, é dessa massa que se faz!”, com o sentido de mostrar que a situação social não significa inferioridade. Acredito, realmente, que esta simples frase, sem muito rebuscamento, mas de grande sabedoria é uma das grandes responsáveis por minha trajetória. Por isso, mesmo ciente de que ele não está aqui para recebê-lo, este é o meu agradecimento ao Senhor Augusto Cassiano, meu avô. Já adulto, diante das responsabilidades da vida, agradeço imensamente a minha esposa Bianca, pelo incentivo incessante e pela compreensão da importância profissional e pessoal da execução deste trabalho. Agradeço também aos meus pequenos motivadores que, mesmo sem saber, foram essenciais, meus filhos Maria Clara e Gabriel Augusto. Agradeço também ao Sistema Petrobras, particularmente aos meus gerentes imediatos durante o período de desenvolvimento da Tese, Ricardo Mello e Ronaldo de Magalhães, pela flexibilização dos horários. Não posso deixar de agradecer e enfatizar a importância dos orientadores Djalma Falcão e Glauco Taranto e também do Mestre Camilo Braga Gomes por sua presteza no desenvolvimento da integração deste trabalho com o FASTSIM. Finalmente agradeço a Deus, por tudo que tem me proporcionado.

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

CONTROLE REGIONAL DE TENSÃO UTILIZANDO LÓGICA FUZZY E
APRENDIZADO POR REFORÇO

Alessandro Bulhões Marques

Agosto/2009

Orientadores: Glauco Nery Taranto
Djalma Mosqueira Falcão

Programa: Engenharia Elétrica

Este trabalho apresenta uma proposta de controle regional de tensão utilizando Lógica Fuzzy e algoritmo de Aprendizado por Reforço. Controladores baseados em lógica fuzzy já foram propostos com desempenho relativamente adequado, porém o sucesso da implantação neste tipo de controlador é completamente dependente do conhecimento do especialista. Com a implantação do algoritmo de Aprendizado por Reforço é possível descobrir a política ótima de controle através de interação com o ambiente, sendo então possível confirmar ou eventualmente corrigir a política proposta por um especialista. Resultados de simulação demonstram a eficiência das regras provenientes do algoritmo proposto, enfatizando a sua robustez diante de múltiplos eventos.

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

REGIONAL VOLTAGE CONTROL USING FUZZY LOGIC AND
REINFORCEMENT LEARNING

Alessandro Bulhões Marques

August/2009

Advisors: Glauco Nery Taranto

Djalma Mosqueira Falcão

Department: Electrical Engineering

This thesis proposes a procedure of reinforcement learning for a regional voltage control based on fuzzy logic. The implementation success of the fuzzy-logic-based control, in a first attempt, depends exclusively on the knowledge expertise of the system operators. With the implementation of the reinforcement learning algorithm, it is possible to find the optimal control strategy by interacting with the system environment. In this way, it is possible to confirm or even change the experts control rules. Simulation results show the efficacy of the rules created by the proposed algorithm, even in face of multiple events.

Sumário

Capítulo I	Introdução.....	1
I.1	Revisão da Literatura	2
I.2	Organização da Tese	4
Capítulo II	Aprendizado por Reforço.....	6
II.1	Modelo de Aprendizado por Reforço	7
II.2	Fundamento Teórico do Aprendizado por Reforço	9
II.3	Métodos de Solução do Aprendizado por Reforço.....	10
II.3.1	Programação Dinâmica.....	11
II.3.1.1	Algoritmo de Iteração de Valor.....	12
II.3.1.2	Algoritmo de Iteração de Política.....	13
II.3.2	H-Learning	15
II.3.3	Método das Diferenças Temporais TD-Learning	17
II.3.4	Q-Learning	19
II.3.5	SARSA	22
II.3.6	R-Learning.....	23
II.4	Aspectos Relevantes na Implementação.....	25
Capítulo III	Descrição do Problema	27
III.1	Definição do Problema.....	28
III.2	Sistema Estudado	30
III.3	Hierarquia Utilizada	32
III.4	Sistema de Inferência Fuzzy.....	34
III.5	Integração SIF Sistema de Potência	35
III.5.1	Variáveis Lingüísticas e Funções de Pertinência	37
III.5.2	Base de Regras.....	38
III.6	Limites Operacionais.....	40
III.7	Resultados Obtidos.....	43
III.7.1	Simulação com Variações em Degrau	43
III.7.2	Simulação com Variações em Rampa.....	48
III.8	Resultados Obtidos Com Modificação das Regras.....	51
III.8.1	Simulação com Variações em Degrau	51
III.8.2	Simulação com Variações em Rampa.....	57
III.9	Conclusões Finais do Capítulo	61
Capítulo IV	Implementação e Resultados	63
IV.1	Determinação dos Estados do Ambiente	64
IV.2	Determinação do Conjunto de Ações	67
IV.3	Definição da Política de Reforços	76
IV.4	Estratégia de Exploração	77

IV.5	Definição do Parâmetro γ	78
IV.6	Operacionalização do Aprendizado.....	78
IV.7	Resultados Obtidos Antes do Aprendizado	83
IV.7.1	Simulação com Variações em Degrau	83
IV.7.2	Simulação com Variações em Rampa.....	87
IV.8	Resultados Obtidos Após o Aprendizado.....	91
IV.8.1	Simulação com Variações em Degrau	99
IV.8.2	Simulação com Variações em Rampa.....	102
IV.9	Confirmação da Eficiência do Controlador Após o Aprendizado	106
IV.9.1	Simulação com Perda de Duas Linhas de Transmissão	107
IV.9.2	Simulação com Perda e Retorno de Linhas de Transmissão.....	111
IV.9.3	Simulações com Utilização do Segundo Nível, Contendo Variação de Carga e Perdas de Linhas de Transmissão.....	114
IV.10	Análise de Sensibilidade	124
Capítulo V	Conclusões	128
Referências Bibliográficas.....		130
Apêndice A -Implementação dos Sistemas Fuzzy no MATLAB		135
A.1	Sistema Fuzzy 1	135
A.2	Sistema Fuzzy 2	137
A.3	Sistema Fuzzy 3	139
A.4	Sistema Fuzzy 4	141
A.5	Sistema Fuzzy 5	143
A.6	Sistema Fuzzy 6	145
A.7	Sistema Fuzzy 7	147
A.8	Sistema Fuzzy 8	149
A.9	Sistema Fuzzy Após Aprendizado.....	151

Lista de Figuras

Figura II-1 - Modelo Padrão de Aprendizado por Reforço.....	7
Figura III-1 - Sistema de Transmissão para a Área Rio	31
Figura III-2 - Níveis Hierárquicos	33
Figura III-3 - Sistema de Inferência Fuzzy.....	34
Figura III-4 - Entradas e Saídas do Controlador.....	36
Figura III-5 - Integração SIF - Sistema de Potência	36
Figura III-6- Funções de Pertinência da Variável de Entrada ADKV	37
Figura III-7 - Funções de pertinência da Variável de Saída MRKV	38
Figura III-8- Supervisão de Violação de Limites	42
Figura III-9 - Tensão de Marimbondo 500 kV	44
Figura III-10 - Tensão de Angra 500 kV	44
Figura III-11 - Tensão de Furnas 345 kV	45
Figura III-12 - Tensão de Jacarepaguá 138 kV	45
Figura III-13 - Tensão de Adrianópolis 138 kV	46
Figura III-14 - Geração dos Compensadores Síncronos de Grajaú	46
Figura III-15 - Tensão de Marimbondo 500 kV	48
Figura III-16 - Tensão de Angra 500 kV	49
Figura III-17 - Tensão de Adrianópolis 138 kV	49
Figura III-18 - Geração dos Compensadores Síncronos de Grajaú	50
Figura III-19 - Tensão de Marimbondo 500 kV	52
Figura III-20 - Tensão de Angra 500 kV	53
Figura III-21 - Tensão de Furnas 345 kV	53
Figura III-22 - Tensão de Jacarepaguá 138 kV	54
Figura III-23 - Tensão de Adrianópolis 138 kV	54
Figura III-24 - Geração dos Compensadores Síncronos de Grajaú	55
Figura III-25 - Tensão de Marimbondo 500 kV	57
Figura III-26 - Tensão de Angra 500 kV	58
Figura III-27 - Tensão de Furnas 345 kV	58
Figura III-28 - Tensão de Adrianópolis 138 kV	59
Figura III-29 - Tensão de Jacarepaguá 138 kV	59
Figura III-30 - Geração dos Compensadores Síncronos de Grajaú	60
Figura IV-1 - Determinação do Conjunto de Estados do Sistema	64
Figura IV-2 - Exemplo de Política de Reforço	77
Figura IV-3 - Tensão de Angra 500 kV.....	84
Figura IV-4 - Tensão de Furnas 345 kV.....	84
Figura IV-5 - Tensão de Jacarepaguá 138 kV	85
Figura IV-6 - Tensão de Adrianópolis 138 kV.....	85
Figura IV-7 - Geração dos Compensadores Síncronos de Grajaú	86

Figura IV-8 - Tensão de Marimbondo 500 kV	88
Figura IV-9 - Tensão de Furnas 345 kV	88
Figura IV-10 - Tensão de Jacarepaguá 138 kV	89
Figura IV-11 - Tensão de Adrianópolis 138 kV	89
Figura IV-12 - Geração dos Compensadores Síncronos de Grajaú	90
Figura IV-13 - Tensão de Angra 500 kV	99
Figura IV-14 - Tensão de Furnas 345 kV	100
Figura IV-15 - Tensão de Jacarepaguá 138 kV	100
Figura IV-16 - Tensão de Adrianópolis 138 kV	101
Figura IV-17 - Geração dos Compensadores Síncronos de Grajaú	101
Figura IV-18 - Tensão de Angra 500 kV	103
Figura IV-19 - Tensão de Furnas 345 kV	103
Figura IV-20 - Tensão de Jacarepaguá 138 kV	104
Figura IV-21 - Tensão de Adrianópolis 138 kV	104
Figura IV-22 - Geração dos Compensadores Síncronos de Grajaú	105
Figura IV-23 - Tensão de Angra 500 kV	108
Figura IV-24 - Tensão de Furnas 345 kV	108
Figura IV-25 - Tensão de Jacarepaguá 138 kV	109
Figura IV-26 - Tensão de Adrianópolis 138 kV	109
Figura IV-27 - Geração dos Compensadores Síncronos de Grajaú	110
Figura IV-28 - Tensão de Angra 500 kV	112
Figura IV-29 - Tensão de Furnas 345 kV	112
Figura IV-30 - Tensão de Jacarepaguá 138 kV	113
Figura IV-31 - Tensão de Adrianópolis 138 kV	113
Figura IV-32 - Geração dos Compensadores Síncronos de Grajaú	114
Figura IV-33 - Tensão de Marimbondo 500 kV	115
Figura IV-34 - Tensão de Angra 500 kV	116
Figura IV-35 - Tensão de Furnas 345 kV	116
Figura IV-36 - Tensão de Jacarepaguá 138 kV	117
Figura IV-37 - Tensão de Adrianópolis 138 kV	117
Figura IV-38 - Tensão de Marimbondo 500 kV	120
Figura IV-39 - Tensão de Angra 500 kV	120
Figura IV-40 - Tensão de Furnas 345 kV	121
Figura IV-41 - Geração dos Compensadores Síncronos de Grajaú	121
Figura IV-42 - Tensão de Adrianópolis 138 kV	122
Figura IV-43 - Tensão de Jacarepaguá 138 kV	122
Figura IV-44 - Tensão de Marimbondo 500 kV	125
Figura IV-45 - Tensão de Angra 500 kV	125
Figura IV-46 - Tensão de Furnas 345 kV	126
Figura IV-47 - Tensão de Adrianópolis 138 kV	126

Figura IV-48 - Tensão de Jacarepaguá 138 kV 127

Lista de Tabelas

Tabela III-1 -Exemplos de Regras de Operação.....	39
Tabela III-2 - Eventos considerados.....	43
Tabela IV-1 - Total de Estados Possíveis.....	65
Tabela IV-2 - Estados Considerados.....	66
Tabela IV-3 - Ações Consideradas.....	68
Tabela IV-4 - Exemplos dos Impactos nas Simulações.....	80
Tabela IV-5 - Eventos considerados.....	83
Tabela IV-6 - Base de Regras Aprendida.....	91
Tabela IV-7 - Eventos considerados.....	103
Tabela IV-8 - Eventos considerados.....	107
Tabela IV-9 - Eventos considerados.....	111
Tabela IV-10 - Eventos considerados.....	115
Tabela IV-11 - Eventos considerados.....	119
Tabela IV-12 - Regras Aprendidas.....	124
Tabela IV-13 - Regras Modificadas.....	124

Capítulo I

Introdução

Os sistemas de energia elétrica vêm sofrendo mudanças estruturais de grande impacto devido a alterações na sua estrutura organizacional, visando o estabelecimento de competição nos segmentos de geração e comercialização, e à introdução de novas tecnologias e equipamentos. Essas mudanças têm levado os sistemas a operarem muito próximo de seus limites físicos. Por razões de ordem econômica, é de fundamental importância que tais limites sejam elevados o máximo possível para um melhor aproveitamento dos investimentos realizados no sistema.

Em particular, o fenômeno da instabilidade de tensão tem ganhado destaque no estabelecimento dos limites operativos, suplantando em muitos casos os limites térmicos e de estabilidade transitória. Uma forma de reduzir as limitações impostas pela instabilidade de tensão é através de sistemas coordenados de controle de tensão, que aproveitam de forma ótima os recursos de geração de potência reativa disponíveis no sistema e, desta forma, permitem uma utilização mais ampla do sistema de transmissão e, conseqüentemente, um melhor desempenho do sistema como um todo.

A implantação de sistemas de controle coordenado de tensão e potência reativa resulta em benefícios para o desempenho do sistema elétrico, minimizando a possibilidade de ocorrência do fenômeno de instabilidade de tensão de médio e longo prazo, além de automatizar o processo de controle e liberar os operadores para execução de outras atividades na supervisão do sistema.

A adoção de estratégias de controle coordenado que mantenham o perfil de tensão dentro de limites operativos e as reservas girantes de potência reativa maximizadas para diversos níveis de carregamento e configurações de rede requer uma eficiente coordenação entre os diversos centros de controle regionais. Ações de controle em sentidos opostos em um período de tempo

invariavelmente se traduzem em manobras desnecessárias, e devem ser evitadas.

I.1 Revisão da Literatura

Nos últimos anos, foram publicados vários artigos ressaltando os benefícios do controle coordenado de tensão, como por exemplo, [1][2], assim como experiências positivas de implementação na França [3][4][5], Itália [6][7] e Bélgica [8].

Em [9], foi proposta uma ferramenta para o controle coordenado de tensão do sistema de transmissão, baseada em lógica fuzzy, onde as estratégias de controle foram definidas pelos próprios operadores do sistema, levando em consideração as suas experiências e as orientações fornecidas pelas instruções de operação.

Uma aplicação de lógica fuzzy no controle coordenado de tensão foi implementada com sucesso na Bonneville Power Administration, conforme mostrado em [10].

A propriedade da lógica fuzzy de emular a capacidade do cérebro humano de raciocinar com informações incertas ou ambíguas e mesmo assim produzir soluções adequadas e também de solucionar problemas multi-objetivos deu à ferramenta um grande potencial para sua utilização no controle coordenado de tensão.

Devido a sua grande capacidade de emular o comportamento humano, foi proposta em [11] uma ferramenta para análise da estabilidade de tensão e determinação das margens de segurança, levando em consideração as ações de controle. Para tal, as ações são representadas por um sistema de inferência fuzzy, com o objetivo de representar as ações de controle tomadas durante a operação do sistema em tempo real.

Apesar dos resultados positivos obtidos com a utilização do controlador proposto em [9], todo o conhecimento inserido foi baseado na experiência de

especialistas. Desta forma, apesar de a ferramenta proposta ser capaz de controlar a tensão do sistema elétrico, não se pode afirmar que a política de controle seja a política ótima.

Além disso, o ajuste eficiente das regras de controle utilizadas despendeu um tempo muito grande, uma vez que, mesmo utilizando regras coerentes e retiradas de entrevistas de campo com os especialistas, alguns conjuntos de regras não foram eficazes o suficiente para controlar o sistema quando testados em múltiplos cenários.

Diante das dificuldades enfrentadas no ajuste das regras de controle feito através das entrevistas de campo e das simulações com vários conjuntos de regras possíveis, foi identificada a necessidade de utilização de uma ferramenta que fosse capaz de aprender a melhor política de controle, entre o conjunto de estratégias e regras de controle possíveis e coerentes.

A ferramenta identificada como de alto potencial para solução deste problema foi o Aprendizado por Reforço, por sua característica de aprendizado através de interações com o ambiente, sem a necessidade de conhecimento do modelo do sistema.

Desta forma, é possível aprender a política de controle ótima, entre todas as possíveis, bem como confirmar que a política implantada, para o caso de sistemas já existentes, é eficiente.

Mais especificamente, o algoritmo de aprendizado por reforço a ser utilizado é o proposto em [12], conhecido como Q-learning, que é um método de aprendizado já aplicado com sucesso em uma grande quantidade de sistemas [13].

Em aplicações para sistemas de potência, o aprendizado por reforço está ainda em fase embrionária. Porém, conforme mostrado em [14], métodos de aprendizado por reforço podem ser uma excelente ferramenta para projetos de controles em sistemas de potência, principalmente pela característica

adaptativa de aprendizado contínuo, que o torna capaz de se adequar as mudanças nas condições operativas.

O aprendizado por reforço junto com a programação dinâmica aproximada e o controle ótimo, são a base dos chamados ACD (“Adaptive Critic Design”). Em [15], temos um exemplo de um controle neuro-fuzzy, projetado para um compensador estático baseado em ACD, onde é possível observar os benefícios de utilizar estas técnicas para superar as dificuldades encontradas em controles lineares, devido às mudanças nos pontos de operação.

O Algoritmo Q-learning será adaptado para trabalhar com a base de regras e as variáveis lingüísticas do sistema de inferência fuzzy aplicado em [9]. Esta abordagem já foi objeto de estudo tanto para aplicações genéricas, como, por exemplo, em [16][17], como também em aplicações em sistemas de potência [18][19]

Como ferramenta de validação será ainda utilizado o simulador rápido (FastSim) da dinâmica de longo prazo desenvolvido na COPPE e proposto em [40]. O FastSim se baseia na eliminação dos efeitos transitórios rápidos dos modelos do sistema. Mecanismos de controle de tensão de atuação rápida, como, por exemplo, a regulação primária dos geradores, são representados somente pelo seu ganho de regime permanente e limites existentes. Sua principal vantagem vem do fato de produzir a trajetória aproximada da evolução temporal do sistema, representando importantes efeitos cronológicos para análise da estabilidade de tensão de médio e longo prazo.

I.2 Organização da Tese

Esta Tese está organizada da seguinte forma:

- No segundo capítulo desta proposta será feita uma descrição resumida da Teoria dos Conjuntos Fuzzy, onde serão apresentados o histórico da sua evolução, além das principais características e vantagens que a tornam uma ferramenta muito utilizada em sistemas de engenharia.

- No terceiro capítulo será feita uma descrição da técnica de aprendizado por reforço, abordando o fundamento teórico, as suas vantagens e as dificuldades na sua implantação.
- No quarto capítulo será feita uma descrição do problema que se deseja solucionar. Inicialmente será demonstrado o controlador proposto em [9] com alguns de seus resultados positivos obtidos. Posteriormente será demonstrando que, para determinados conjuntos de regras implantadas, mesmo sendo estas totalmente coerentes, o controlador pode não ser efetivo. Desta forma, existe a necessidade de se utilizar uma ferramenta para identificar a melhor política de controle dentre as possíveis.
- No quinto capítulo será demonstrado como foi feita a implantação do algoritmo de aprendizado por reforço e as estratégias utilizadas. Além disso, serão feitas simulações utilizando a base de regras aprendida pelo algoritmo e demonstrada a sua capacidade de controle em múltiplos cenários, ressaltando a sua robustez.
- No sexto e último capítulo serão feitas as conclusões, considerações finais e propostas de continuação nesta linha de pesquisa.

Capítulo II

Aprendizado por Reforço

O Aprendizado por Reforço é uma técnica inteligente que combina duas outras técnicas para resolver problemas que nenhuma delas conseguiria resolver individualmente: a programação dinâmica e o aprendizado supervisionado.

A Programação Dinâmica é uma área da matemática que tem sido tradicionalmente usada para resolver problemas de otimização e controle, sendo, no entanto, limitada por problemas de tamanho e complexidade das soluções.

O Aprendizado Supervisionado é um método geral para treinamento e parametrização que, no entanto, requer amostras de valores de entrada e saída para que a função seja aprendida, isto é, o aprendizado supervisionado necessita de um conjunto de perguntas, cujas respostas são conhecidas.

Infelizmente, há muitas situações onde não é possível saber a resposta correta. Por exemplo, em um sistema de controle de vôo, a pergunta seria o conjunto das leituras de todos os sensores em um dado momento e a resposta seria como o controle deveria mover a aeronave no próximo instante. Podemos observar que, neste caso, o aprendizado supervisionado não poderia ajudar, porque não há um conjunto de respostas conhecidas.

O Aprendizado por Reforço é uma técnica que busca a obtenção de uma política ótima de controle através da interação com o ambiente, mesmo que este seja inicialmente desconhecido.

O aprendizado baseia-se na exploração do ambiente através da tomada de ações e do recebimento de um sinal adicional, denominado reforço, que indica quão significativa foi aquela ação, isto é, se aquela ação tomada recebeu uma recompensa ou uma punição.

Desta forma, o aprendizado se assemelha ao aprendizado humano, já que, dependendo da ação tomada por uma criança, esta pode receber elogios, que representam a recompensa para o caso de ações corretas, ou receber punições, caso contrário.

Naturalmente, a tendência do aprendiz, seja ele humano ou não, deve ser a de buscar receber o máximo de recompensas e para isso, este passa a executar ações que receberam recompensas no passado, tendendo assim para uma política de comportamento ótimo.

II.1 Modelo de Aprendizado por Reforço

Em um modelo de aprendizado por reforço padrão o agente aprendiz é ligado ao seu ambiente conforme mostrado na Figura II-1. Em cada passo de iteração o agente recebe como entrada uma indicação do estado atual, s , do sistema; este então escolhe uma ação, a , como saída. A ação muda o estado do sistema, e o valor deste novo estado é comunicado ao aprendiz através de um sinal de recompensa ou reforço, isto é, um sinal que dá a avaliação do resultado da ação anterior. Sendo assim, o agente aprendiz deve escolher ações que aumentem o sinal de reforço, isto é, que indiquem uma evolução no seu ajuste.




Figura II-1 - Modelo Padrão de Aprendizado por Reforço

O modelo completo é composto de:

- Um conjunto discreto de estados do sistema, S ;
- Um conjunto discreto de ações de controle, A ; e

- Um conjunto de sinais de reforço; geralmente $\{0,1\}$, ou outros números reais.

Uma maneira didática de entender a relação entre o agente aprendiz e o ambiente é através do diálogo a seguir, proposto em [20]:

Ambiente – Você está no estado 65. Você tem 4 possíveis ações.

Agente - Executar a ação 2.

Ambiente – Você recebeu um reforço de 7 unidades. Você está agora no estado 15. Você tem 2 ações possíveis.

Agente - Executar a ação 1.

Ambiente – Você recebeu um reforço de -4 unidades. Você está agora no estado 65. Você tem 4 possíveis ações

Agente - Executar a ação 2.

Ambiente – Você recebeu um reforço de 5 unidades. Você está agora no estado 44. Você tem 2 ações possíveis. . .

O objetivo do agente é descobrir as estratégias de controle que representem um mapeamento da política ótima dos estados / ações de controle, através da maximização dos valores dos reforços recebidos.

Uma vez descoberta a política ótima, pelo princípio da otimalidade de Bellman, podemos afirmar que todas as políticas intermediárias, ou sub-políticas, são ótimas, isto é, em qualquer estado intermediário inicial, independentemente das decisões anteriores que tenham sido tomadas, as decisões futuras ainda serão ótimas.

No exemplo anterior podemos observar que o sistema é não-estacionário, isto é, tomando uma mesma ação, em um mesmo estado do sistema em duas diferentes ocasiões, podemos obter resultados diferentes e diferentes sinais de reforço. Isto ocorreu no estado 65, quando obtivemos sinais diferentes de reforço e atingimos dois estados distintos.

Na teoria do aprendizado por reforço é esperado que o sistema seja não-determinístico, porém é requerido que o sistema seja estacionário, isto é, que as probabilidades de transição de estados sejam fixas.

Apesar de a maioria dos sistemas reais serem não-estacionários, alguns algoritmos são efetivos se for possível assumir que o sistema seja de variação lenta, isto é, que a probabilidade de mudança de sinal de reforço e mudança de estados atingidos varie lentamente.

II.2 Fundamento Teórico do Aprendizado por Reforço

A teoria do Aprendizado por Reforço é baseada em técnicas estatísticas e métodos de programação dinâmica, para estimar a ação de melhor resultado para cada situação (estado) do ambiente.

Este problema pode ser modelado como um MDP (Processo Markoviano de Decisão). Um Processo de Decisão Markoviano é aquele que obedece à propriedade de Markov, que estabelece que a probabilidade de transição de um estado s para um estado s' de um sistema depende apenas do que se pode observar sobre o estado atual e da ação a a ser adotada, o que significa que o estado corrente fornece informação suficiente para o sistema de aprendizado. Um MDP é definido conforme a seguir:

- um conjunto de estados do ambiente, S ;
- um conjunto de ações, A ;
- uma função que determina a recompensa imediata para as decisões do agente ($r : S \times A \rightarrow R$), $r(s, a)$ é a recompensa por escolher a ação a no estado s .
- uma função que representa as transições de estado do ambiente ($t : S \times A \rightarrow \Pi(S)$), onde um elemento de $\Pi(S)$, é a distribuição de probabilidades sobre o conjunto S . $t(s, a, s')$ é a probabilidade do

ambiente mudar do estado s para o estado s' , caso a ação a seja executada.

A solução de um MDP significa o aprendizado da política ótima $\pi^* : S \times A$ que mapeia o estado atual s_t em uma ação desejada, de forma a maximizar a recompensa acumulada ao longo do tempo.

Um meio de descrever a recompensa esperada acumulada é utilizar a função de custo esperado $V^\pi(s_t)$ gerada quando se segue uma determinada política π a partir de um estado inicial s_t .

As recompensas recebidas são amortizadas por um fator de desconto γ , que varia entre 0 e 1, que determina o valor relativo da recompensa imediata em relação às possíveis recompensas futuras.

Desta forma, a função de custo esperado é expressa por (1):

$$V^\pi(s_t) = r_t + \gamma r_{t+1} + \gamma^2 r_{t+2} + \dots = \sum \gamma^i r_{t+i}, \text{ onde:} \quad (1)$$

- r_{t+i} é a sequência de reforços recebidos a partir do estado s_t , utilizando a política π para selecionar as ações; e
- γ é o fator de desconto.

Então, o objetivo do agente aprendiz é encontrar a política ótima estacionária π^* que maximiza $V^\pi(s)$, para todo estado $s \in S$:

$$\pi^* = \operatorname{argmax}_\pi V^\pi(s) \quad (2)$$

II.3 Métodos de Solução do Aprendizado por Reforço

A solução de problemas de Aprendizado por Reforço pode ser dividida em dois tipos: os sistemas baseados em modelos do ambiente (“Model-Based”), onde todas as probabilidades de transição de estados são conhecidas, e os sistemas em que os modelos do ambiente não são conhecidos, chamados (“Model-free”).

Como exemplo de sistemas baseados em modelos temos: a Programação Dinâmica [21] e o método H-Learning, proposto em [23]. Dentre os métodos que não necessitam de informações acerca do modelo do ambiente temos o Método da Diferenças Temporais [24], o R-Learning [22] e o Q-Learning [12].

Nas seções seguintes serão analisados individualmente os principais métodos de solução do aprendizado por reforço.

II.3.1 Programação Dinâmica

Programação Dinâmica é um conjunto de algoritmos capazes de obter políticas ótimas a partir de sistemas modelados estritamente como Processos Markovianos de Decisão (MDP), isto é, contendo um conjunto discreto de estados, de ações e todas as probabilidades de transição entre estados, para cada ação tomada.

O principal fundamento desta metodologia é o Princípio da Otimalidade de Bellman que afirma que dada uma política ótima $\pi^* = \{\mu_0, \mu_1, \dots, \mu_{n-1}\}$ para solução de um problema de controle, a política $\pi^* = \{\mu_i, \mu_{i+1}, \dots, \mu_{n-1}\}$ também é ótima, caso o estado inicial seja s_i ($0 < i < N-1$).

Desta forma, é possível afirmar que, a partir da determinação de uma política ótima entre um estado inicial e um estado final temos também todas as políticas ótimas quando partindo de estados intermediários entre os estados inicial e final.

Ainda como consequência deste princípio podemos afirmar que, caso seja necessário definir a política ótima de um sistema que se encontra no estado s_i , basta encontrar a melhor ação que conduz ao estado s_{i+1} e a partir de então seguir a política ótima até o estado final.

Utilizando este princípio, os dois principais algoritmos de Programação Dinâmica utilizados para solucionar problemas de Aprendizado por Reforço são: o algoritmo de Iteração de Valor e o algoritmo de iteração da política.

II.3.1.1 Algoritmo de Iteração de Valor

O Algoritmo apresentado a seguir consiste na busca indireta por políticas ótimas através da obtenção de maneira iterativa da função valor ótima V^* a partir da equação (3):

$$V(s_t) \leftarrow \max_{\pi(s_t)} [r(s_t, \pi(s_t)) + \gamma \sum_{s_{t+1} \in S} T(s_t, \pi(s_t), s_{t+1}) V'(s_{t+1})], \quad (3)$$

Onde:

- s_t é o estado atual,
- $\pi(s_t)$ é a ação realizada em s_t
- s_{t+1} é o estado resultante ao se aplicar ação $\pi(s_t)$ a partir do estado s_t
- V é a função valor e V' é o valor da função valor na iteração anterior.

Neste algoritmo a política ótima π^* é encontrada ao final do processamento, por meio da equação (4):

$$\pi^*(s_t) \leftarrow \operatorname{argmax}_{\pi(s_t)} [r(s_t, \pi(s_t)) + \gamma \sum_{s_{t+1} \in S} T(s_t, \pi(s_t), s_{t+1}) V'(s_{t+1})]. \quad (4)$$

-Repete:

-Compute a função valor $V(s)$ por meio da equação:

$$- V(s) \leftarrow \max_{\pi(s)} [r(s, \pi(s)) + \gamma \sum_{s' \in S} T(s, \pi(s), s') V'(s')]$$

-Até que o valor de $V(s) = V'(s)$.

-Calcule π^* através da equação:

$$- \pi^* \leftarrow \operatorname{argmax}_{\pi(s)} [r(s, \pi(s)) + \gamma \sum_{s' \in S} T(s, \pi(s), s') V'(s')]$$

-Onde:

$$s = s_t \text{ e } s' = s_{t+1} .$$

II.3.1.2 Algoritmo de Iteração de Política

O algoritmo de Iteração de Política consiste na busca direta por políticas ótimas, funcionando da seguinte maneira: a partir da política inicial $\pi^0 = \{a_0, a_1, a_2, \dots\}$, é calculado V^{π^0} , através da solução do sistema de equações lineares:

$$V^{\pi}(s_t) \leftarrow r(s_t, \pi(s_t)) + \gamma \sum_{s_{t+1} \in S} T(s_t, \pi(s_t), s_{t+1}) V^{\pi}(s_{t+1}). \quad (5)$$

Uma vez obtida V_{π^0} , uma política π^1 é computada, maximizando a soma do reforço $r(s, \pi(s))$ com o valor $V^{\pi}(s')$ do estado sucessor, descontado de γ :

$$\pi^1(s_t) \leftarrow \operatorname{argmax}_{\pi(s_t)} [r(s_t, \pi(s_t)) + \gamma \sum_{s_{t+1} \in S} T(s_t, \pi(s_t), s_{t+1}) V^{\pi}(s_{t+1})]. \quad (6)$$

Este processo é repetido até que π^* seja encontrada, o que ocorre quando $V^{\pi}(s_t) = V^{\pi'}(s_t)$ se estabiliza e $\pi = \pi'$.

A partir do momento em que não seja possível obter melhoria no valor V a política encontrada é a política ótima. O método completo é apresentado no Algoritmo a seguir.

-Inicializa $\pi \leftarrow \pi^0$ arbitrariamente

Repete:

-Passo 1: Compute a função valor $V^\pi(s)$ para a política π por meio da solução de equações lineares

$$- V^\pi(s) \leftarrow r(s, a) + \gamma \sum_{s' \in S} T(s, a, s') V^\pi(s').$$

-Passo 2: Melhore a política para cada estado:

$$-\pi'(s) \leftarrow \operatorname{argmax}_a [r(s, a) + \gamma \sum_{s' \in S} T(s, a, s') V^\pi(s')].$$

$$- \pi \leftarrow \pi'$$

-Até que $V^{\pi'}(s) = V^\pi(s)$.

-Onde:

$$s = s_t, s' = s_{t+1} \text{ e } a = a_t = \pi(s_t).$$

A política $\pi'(s_t)$ determinada segundo a equação anterior é chamada política gulosa (Greedy) para $V^{\pi}(s_{t+1})$, pois escolhe sempre a ação que possui o maior retorno estimado.

È possível perceber que a utilização direta da política “Greedy” pode conduzir o sistema, dependendo das condições iniciais, para mínimos. Para evitar isto, existe a estratégia de exploração aleatória também conhecida como “e-greedy”. Nesta estratégia o agente tem a probabilidade $1 - p$ de escolher a melhor ação e a probabilidade p de escolher uma ação aleatória.

Na comparação entre os dois algoritmos é possível perceber que o algoritmo de iteração de valor é mais rápido, uma vez que não necessita resolver um sistema de equações lineares. Porém o método de iteração de política utiliza menos passos para chegar a solução. Além disso, o algoritmo de iteração de valor atua

apenas sobre o estado, enquanto o algoritmo de iteração de política atua sobre o par estado-ação.

Com relação a desvantagens, os dois métodos exigem um custo computacional muito alto na busca da solução ótima. Além disso, para ambos é necessário que se conheça o modelo de probabilidade de transição dos sistemas.

II.3.2 H-Learning

Um outro método de solução utilizado quando é possível definir o modelo completo do ambiente é o proposto em [23]. Este algoritmo, chamado H-learning, foi introduzido para otimizar a recompensa média sem utilizar desconto.

O algoritmo H-learning estima as *probabilidades* $p_{ik}(a)$ e os reforços $r(i, a)$ por contagem direta, atualizando os valores de h utilizando uma equação que, segundo teorema provado em [34], converge para uma política ótima.

O método completo do H-learning pode ser observado a seguir:

-Seja $N(i, u)$ o número de vezes que a ação u foi executada no estado i , e seja $N(i, u, j)$ o número de vezes que ela resultou no estado j .

-Inicialize as matrizes $p_{ij}(u)$, $r(i, u)$, $h(i)$ e o escalar ρ em 0.

-Onde:

- $p_{ij}(u)$ é a probabilidade de ir de um estado i para um estado k executando a ação u .

- $r(i, a)$ é a recompensa estimada por executar a ação a no estado i .

- $h(i)$ é a recompensa máxima esperada para o estado i .

- A constante ρ representa a média das recompensas.

- $U_{best}(i)$ é o conjunto de ações ótimas no estado i e é inicializado com $U(i)$.

- T é o número total de passos que uma ação aparentemente ótima foi executada e é inicializado com 0.

- Repita:

- Se a estratégia de exploração sugere uma ação aleatória, pegue uma ação aleatória para i ; senão execute a ação $a \in U_{best}(i)$. Deixe k ser o estado resultante, e r' a recompensa imediata recebida.

- $N(i, a) < N(i, a) + 1$.

- $N(i, a, k) < N(i, a, k) + 1$.

- $p_{ik}(a) \leftarrow N(i, a, k) / N(i, a)$

- $r(i, a) \leftarrow r(i, a) + (r' - r(i, a)) / N(i, a)$

- Se a ação executada $a \in U_{best}(i)$, então:

- $T < T + 1$

- $\rho \leftarrow \rho + (r' - h(i) + h(k) - \rho) / T$

-Deixe:

- $H(i, u) = r(i, u) + \sum p_{ij}(u) h(j)$

- $U_{best}(i) \leftarrow \{v \mid H(i, v) = \max_{u \in U(i)} H(i, u)\}$

- $h(i) \leftarrow H(i, a) - \rho$, onde $a \in U_{best}(i)$

- $i \leftarrow k$

Até convergir.

II.3.3 Método das Diferenças Temporais TD-Learning

O método das Diferenças Temporais proposto em [24] é derivado da Programação Dinâmica, mais especificamente do algoritmo de iteração de política. Porém, neste método não é necessário um conhecimento completo do modelo do ambiente, dado que o aprendizado é feito a partir da experiência. Sendo assim, não há a necessidade de uma modelagem MDP, sendo este um dos tipos de técnica “model-free”.

Neste método, ao invés de se computar a função valor por meio de um sistema de equações, como ocorre na programação dinâmica, a função valor é determinada de maneira iterativa através da seguinte equação:

$$V_{t+1}(s_t) \leftarrow V_t(s_t) + \alpha [r(s_t, a_t) + \gamma V_t(s_{t+1}) - V_t(s_t)]. \quad (7)$$

Onde:

- s_t é o estado atual;
- $r(s_t, a_t)$ é o reforço recebido após realizar a_t em s_t ;
- s_{t+1} é o próximo estado;
- γ é o fator de desconto, entre 0 e 1; e
- α é a taxa de aprendizagem

A principal propriedade deste método é que, caso a taxa de aprendizagem decaia lentamente e a política seja mantida fixa, o algoritmo converge para o ótimo da função valor para esta política.

Além do Algoritmo das Diferenças Temporais proposto anteriormente, também conhecido como TD(0), existe um método mais geral, chamado de Algoritmo das Diferenças Temporais – TD(λ).

No TD(λ), a atualização do valor do estado atual pode ser feita usando apenas o próximo estado ($\lambda = 0$) – recaindo no TD(0) – até o uso de todos os estados futuros ($\lambda = 1$), conforme equação (8):

$$V_{t+1}(u) \leftarrow V_t(u) + \alpha [r(s_t, a_t) + \gamma V_t(s_{t+1}) - V_t(s_t)] e(u). \quad (8)$$

Onde:

- u é o estado que está sendo atualizado;
- s_t é o estado atual;
- $r(s_t, a_t)$ é o reforço recebido após realizar a_t em s_t ;
- s_{t+1} é o próximo estado;
- γ é o fator de desconto, entre 0 e 1; e
- α é a taxa de aprendizagem
- $e(u)$ é a elegibilidade do estado u

A elegibilidade de um estado define o grau em que este foi visitado no passado recente. O uso deste termo permite que um reforço recebido seja usado para atualizar todos os estados recentemente visitados. Isto faz com que os estados mais próximos das recompensas sejam mais influenciados por elas.

É possível perceber que a execução do algoritmo TD(λ) tem custo computacional mais elevado, quando comparada com o TD(0). Porém, dependendo do valor de λ , o primeiro pode convergir mais rápido.

Um dos principais algoritmos na área de Aprendizado por Reforço, o Q-learning, é baseado no método das Diferenças Temporais. Neste algoritmo, que será descrito em seguida, a regra de aprendizado é um caso especial da regra de atualização do TD(0). Um exemplo de algoritmo TD(λ) é apresentado a seguir:

- Inicializar $V_t(s)$ arbitrariamente
- Inicializar $e(s) = 0$
- Repetir:
 - Visitar o estado s e seleccionar uma ação a , de acordo com uma política π .
 - Executar a ação a .
 - Receber o reforço $r(s,a)$ e observar o próximo estado s' .
 - Atualizar a elegibilidade $e(s) = e(s) + 1$.
 - Para todos os estados u :
 - Atualizar os valores $V_t(u)$ de acordo com a regra de atualização:
 - $V_{t+1}(u) \leftarrow V_t(u) + \alpha [r(s,a) + \gamma V_t(s') - V_t(s)] e(u)$.
 - Atualizar $e(u) \leftarrow \gamma \lambda e(u)$.
 - Atualizar o estado $s \leftarrow s'$.
- Até que algum critério de parada seja atingido.

II.3.4 Q-Learning

Quando o agente aprendiz não conhece o modelo de transição de estados do ambiente (t), não é possível utilizar programação dinâmica para encontrar a política ótima.

No algoritmo Q-Learning, ao invés da maximização de $V^\pi(s)$, é utilizada uma função Valor-Ação, que é definida como sendo a soma dos reforços recebidos

pelo agente por ter realizado a ação a_t no estado s_t em um momento t , mais o valor de seguir a política ótima, descontado do valor de γ , ou seja:

$$Q^*(s_t, a_t) = r(s_t, a_t) + \gamma V^*(s_{t+1}). \quad (9)$$

Reescrevendo a equação utilizando o princípio de otimalidade temos:

$$Q^*(s_t, a_t) = r(s_t, a_t) + \gamma \max_{a_{t+1}} Q^*(s_{t+1}, a_{t+1}). \quad (10)$$

A função Q é normalmente memorizada em forma de uma tabela, onde as linhas são os estados e as colunas as ações. Esta tabela é inicializada com valores arbitrários, normalmente 0, e atualizada de acordo com a seguinte regra de aprendizado:

$$Q_{t+1}(s_t, a_t) = (1 - \alpha) Q(s_t, a_t) + \alpha [r(s_t, a_t) + \gamma \max_{a_{t+1}} Q_{t+1}(s_{t+1}, a_{t+1})], \quad (11)$$

onde:

- s_t é o estado atual;
- a_t é a ação realizada em s_t ;
- $r(s_t, a_t)$ é o reforço recebido após realizar a ação;
- s_{t+1} é o novo estado;
- γ é o fator de desconto, entre 0 e 1; e
- α é a taxa de aprendizagem, entre 0 e 1, podendo ser definida por $\alpha = 1/(1 + v(s,a))$, onde $v(s,a)$, é o número de escolhas de a , durante visitas ao estado s .

Os valores ajustados para γ , como pode ser observado na equação anterior, refletem a importância das recompensas mais recentes em relação as mais antigas.

Uma propriedade importante deste algoritmo é que as ações utilizadas durante o processo iterativo de aproximação da função podem ser escolhidas usando qualquer estratégia, e, além disso, a política ótima pode ser obtida diretamente.

A convergência é garantida desde que cada par estado ação seja visitado muitas vezes [13].

Uma estratégia bastante utilizada para a escolha das ações é a exploração aleatória ϵ – *Greedy*, na qual o agente executa a ação com maior valor de Q , com probabilidade $1 - \epsilon$ e escolhe uma ação aleatória com probabilidade ϵ .

O algoritmo *Q-Learning* foi proposto em [12] e é um dos mais importantes avanços na área de Aprendizado por Reforço, principalmente pelas seguintes razões:

- Foi o primeiro método a possuir fortes provas de convergência;
- É de fácil implementação; e
- Tem sido aplicado com sucesso em várias áreas.

Um exemplo de Algoritmo *Q-Learning* é mostrado a seguir:

Inicializar $Q(s, a)$ arbitrariamente (normalmente 0)

-Repete (para cada episódio):

- Inicializar s
- Repete (para cada passo episódio):

 - Escolher a ação a para s utilizando a estratégia escolhida
 - Executar a ação a
 - Observar r, s'
 - $Q_{t+1}(s_t, a_t) \leftarrow (1 - \alpha) Q(s_t, a_t) + \alpha[r(s_t, a_t) + \gamma \max_{a_{t+1}} Q_{at+1}(s_{t+1}, a_{t+1})]$
 - $s \leftarrow s'$

- Até s ser o estado final

II.3.5 SARSA

Inicialmente chamado de Q-Learning Modificado, o algoritmo SARSA [46] propõe que a política seja aprendida no tempo de execução, estimando o valor de uma política, ao mesmo tempo que a usa para interagir com o ambiente.

O nome SARSA tem origem em *State, Action, Reward, State, Action*, que são os elementos $(s_t, a_t, r_t, s_{t+1}, s_{t+1})$. Estes são os valores considerados na atualização de Q , conforme a equação (12):

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha_t[r(s_t, a_t) + \gamma Q(s_{t+1}, a_{t+1}) - Q(s_t, a_t)]. \quad (12)$$

O método converge para a política ótima com probabilidade 1, desde que cada par estado-ação seja visitado um número infinito de vezes.

Em [46], foi demonstrado que utilizando-se uma política *ϵ -greedy*, em que a probabilidade é reduzida gradualmente, os algoritmos Q-learning e SARSA convergem assintoticamente para a política ótima. Um exemplo de algoritmo SARSA é descrito a seguir:

Inicializar $Q(s, a)$ arbitrariamente

-Repetir (para cada ciclo):

-Inicializar s

-Repetir (para cada passo no ciclo):

-Escolher a ação a para s utilizando a estratégia escolhida

-Executar a ação a

-Observar r, s'

$Q_{t+1}(s_t, a_t) \leftarrow (1 - \alpha) Q(s_t, a_t) + \alpha[r(s_t, a_t) + \gamma \max_{a_{t+1}} Q_{at+1}(s_{t+1}, a_{t+1})]$

$s \leftarrow s'$

-Até s ser o estado final

II.3.6 R-Learning

Uma abordagem semelhante ao Q-Learning foi a técnica proposta em [22], chamada de R-learning. O R-Learning maximiza a recompensa média a cada passo, ou seja, utiliza “average-reward model”. Já o Q-learning não maximiza a recompensa média, mas descontos acumulados de recompensa.

O algoritmo R-learning possui regra similar ao Q-learning, sendo baseado na dedução de valores $R(s,a)$, e devendo escolher ações a no estado s . A cada situação, o aprendiz escolhe a ação que tem o maior valor R , exceto que algumas vezes ele escolhe uma ação qualquer de forma a evitar a convergência para mínimos locais.

Os valores de R são ajustados a cada ação, com base na seguinte regra de aprendizagem:

$$R(s, a) \leftarrow (1 - \alpha) R(s, a) + \alpha[r - \rho + eR(s')]. \quad (13)$$

Esta regra é diferente da regra do Q-learning, por subtrair a recompensa média ρ do reforço imediato r e por não ter desconto γ para o próximo estado, $eR(s') - \max_a R(s', a)$.

A recompensa média é calculada como:

$$\rho \leftarrow (1 - \beta) \rho + \beta [r + eR(s') - eR(s)]. \quad (14)$$

O ponto chave é que ρ somente é atualizado quando uma ação não aleatória foi tomada, ou seja, $\max_a R(s, a) = R(s, a)$. A recompensa média ρ não depende de nenhum estado particular, pois é uma constante para todo o conjunto de estados.

A seguir é apresentado o algoritmo R-learning, onde podem ser observadas pequenas reestruturações nas equações de atualização de R e ρ , que melhoram o custo computacional.

Inicializar ρ e $R(s, a)$ arbitrariamente

-Repetir (para sempre):

- s < estado atual

-Escolher a ação $a \in A(s)$

-Executar a ação a

-Observar r, s'

$R(s, a) \leftarrow R(s, a) + \alpha [r - \rho + eR(s') - R(s, a)]$

-se $R(s, a) = \max_a R(s, a)$, então

$\rho \leftarrow (1 - \beta) \rho + \beta [r + eR(s') - eR(s)].$

II.4 Aspectos Relevantes na Implementação

Mesmo sendo de fácil implementação, alguns aspectos devem ser considerados na aplicação de um algoritmo de Aprendizado por Reforço para garantir um resultado positivo:

- Dimensionalidade

O mapeamento dos estados e ações de um ambiente pode ser muito grande, o que dificulta a convergência do algoritmo, dado que é necessário que cada par estado-ação seja visitado um grande número de vezes. Esta dificuldade é mitigada com a utilização do conhecimento prévio do ambiente, que retira do mapeamento as situações pouco prováveis, ou impossíveis de ocorrer.

- Determinação dos Reforços

A determinação correta das recompensas e punições a serem recebidas pelo agente aprendiz é de fundamental importância para o aprendizado correto da política ótima. Valores muito altos de punições, por exemplo, podem conduzir o algoritmo a evitar explorar determinados estados ou tomar determinadas ações, como ocorrido em [26].

- Estratégia de Escolha das Ações

A política de escolha de ações deve ser bem estabelecida de forma a evitar a convergência para máximos locais.

Como o algoritmo procura sempre obter o valor máximo de retorno, escolhendo as ações que fornecem bons resultados, é possível que a convergência migre para um máximo local. Para evitar esta convergência, a exemplo da mutação no algoritmo genético, deve ser estabelecida uma estratégia que busque ações alternativas periodicamente, para garantir a convergência para a política ótima. Este é o conhecido dilema *exploration X exploitation*.

- Ambientes Não-Estacionários

Conforme já exposto, à teoria do Aprendizado por Reforço é baseada em sistemas estacionários, que praticamente não existem em sistemas reais. Porém, a sua aplicação é possível para o caso de ambientes não-estacionários que variem lentamente.

Capítulo III

Descrição do Problema

O controle de tensão em um sistema de energia elétrica é, em geral, executado pelos operadores de sistema que, dos centros de operação, observam o comportamento das tensões através dos sistemas de telemetria e executam ações para corrigir os desvios que ocorrem durante o dia. Estas ações são realizadas através de comunicação verbal entre os operadores de sistema e os operadores das usinas e subestações, sendo que, em alguns casos, os operadores de sistema executam manobras através de telecomando, como por exemplo, chaveamentos de equipamentos de controle de tensão, através do sistema de supervisão e controle.

O controle de tensão executado pelos operadores de sistema é baseado no seu conhecimento, na sua experiência e em instruções de operação, que estabelecem valores para as tensões de determinadas barras, limites de operação e filosofias de ação que devem ser adotadas, baseadas em estudos de simulação prévios.

Os equipamentos utilizados para controlar a tensão são: bancos de capacitores e reatores manobráveis, potência reativa das unidades geradoras, comutadores sob carga (LTC), compensadores síncronos e compensadores estáticos. No caso dos compensadores síncronos e estáticos há, geralmente, um valor de tensão determinado na barra onde estes estão instalados, que deve ser controlado por estes equipamentos. Este valor, na maioria das vezes, varia de acordo com o período de carga. Os operadores de sistema atuam de forma a evitar que estes equipamentos operem próximos aos seus limites de potência reativa, mantendo uma margem de segurança para possíveis distúrbios na área de influência destes equipamentos.

Nas usinas o controle é feito através do barramento de alta. Algumas usinas possuem o equipamento para controle conjunto de tensão, também conhecido como JVC. Neste equipamento, a tensão de referência do controlador é a do lado de alta. Sendo assim, quando a usina possui este equipamento, os operadores das usinas ajustam apenas o valor de referência, de acordo com o comando do operador de sistema e o controle conjunto de tensão ajusta a tensão das máquinas e, ao mesmo tempo, executa a partição da potência reativa entre elas. Mesmo quando a usina não possui JVC, o operador de sistema envia a ordem de comando em relação ao barramento de alta e cabe ao operador da usina executar manualmente, o trabalho do JVC.

Sistemas automatizados ou coordenados de controle de tensão vêm sendo propostos com o objetivo de otimizar o uso dos dispositivos de controle de tensão e fontes de potência reativa e liberar os operadores de tarefas repetitivas, como descritos em [1] a [10]. Algumas dessas propostas foram efetivamente implementadas nos sistemas elétricos de países da Europa.

Alguns dos sistemas propostos são baseados em técnicas inteligentes. Por exemplo em [9], foi proposto um Sistema de Inferência Fuzzy para o controle coordenado de tensão do sistema de transmissão da Área Rio, onde as estratégias de controle foram definidas pelos próprios operadores do sistema, levando em consideração as suas experiências e as orientações fornecidas pelas instruções de operação.

III.1 Definição do Problema

O controle coordenado de tensão em uma área de um sistema elétrico tem como objetivo a otimização dos recursos de controle local de tensão e suporte de potência reativa e a manutenção de um perfil de tensões adequado nos barramento da área. O controle é, em geral, implementado através da determinação de ações de controle (atuação na referência de tensão dos reguladores e compensadores, chaveamento de bancos de capacitores e

indutores, taps de transformadores, etc) de forma a manter a tensão em certas barras do sistema (barras piloto) dentro de limites considerados adequados para a operação dos sistemas e as fontes de potência reativa com alguma folga para atuação em casos de emergências. Restrições quanto a limites operativos dos equipamentos e número de chaveamentos devem ser observadas.

A utilização de sistemas baseados no conhecimento, em particular Sistemas de inferência Fuzzy (SIF), neste problema se justificativa pelos seguintes fatos:

A relação entre o fluxo de potência reativa e os módulos de tensão nos barramentos do sistema é altamente não linear. Além disso, as ações de controle, em muitos casos, são de natureza discreta, como é o caso de chaveamento de bancos de capacitores e indutores, taps de transformadores, etc.

Cada sistema elétrico, ou área do sistema, exige um esquema de controle específico tendo em vistas suas características topológicas (radial ou malhado), existência de linhas longas e/ou curtas, disponibilidade de fontes de potência reativa na área, etc.

Para a implantação de um SIF para controle de tensão do sistema elétrico, é necessária, conforme descrito no capítulo anterior, a identificação ou modelagem do operador humano. Para isto, é necessário que sejam feitas entrevistas com os operadores de sistema, com o objetivo de determinar:

- As variáveis de entrada e saída;
- As funções de pertinência; e, principalmente
- As regras de controle.

III.2 Sistema Estudado

Como um auxílio à caracterização do problema estudado nesta tese, desta seção até a seção III.6 será apresentada uma breve explicação do trabalho proposto em [41], de forma a demonstrar os principais pontos daquela proposta, bem como facilitar o entendimento do principal ponto de melhoria identificado, que é a base da proposta deste trabalho.

Em [41], o sistema estudado nas simulações foi um equivalente das regiões Sul e Sudeste do Sistema Interligado Nacional, contendo 730 barras AC, 1146 linhas de transmissão e transformadores e 104 geradores e compensadores síncronos. A área de interesse foi a Área Rio, constituída pelas Concessionárias de Serviços Públicos de Distribuição Light, Cerj, Escelsa e parte do sistema Furnas.

A Figura III-1 mostra os principais corredores de transmissão para a Área Rio, assim como as principais usinas com influência no controle de tensão da área. No corredor de 500 kV consideraram-se as usinas de Marimbondo e Angra como recursos girantes para controle de tensão, enquanto que no corredor de 345 kV considerou-se apenas a usina de Furnas. Os compensadores síncronos de Grajaú, ao invés de serem considerados como recursos para o controle de tensão e serem utilizados como variáveis de controle, são utilizados como variáveis controladas.

É importante ressaltar que as usinas utilizadas como recursos de controle de tensão devem ter uma grande influência no controle da área e, ao mesmo tempo, não ter influência significativa em outras áreas, de forma a não prejudicar a coordenação do controle de tensão em áreas adjacentes. Por este motivo, as usinas de L.C. Barreto e Volta Grande, apesar de fazerem parte da Figura III-1, não foram consideradas como recursos para o controle de tensão da Área Rio, dada a sua maior influência na Área Minas Gerais.

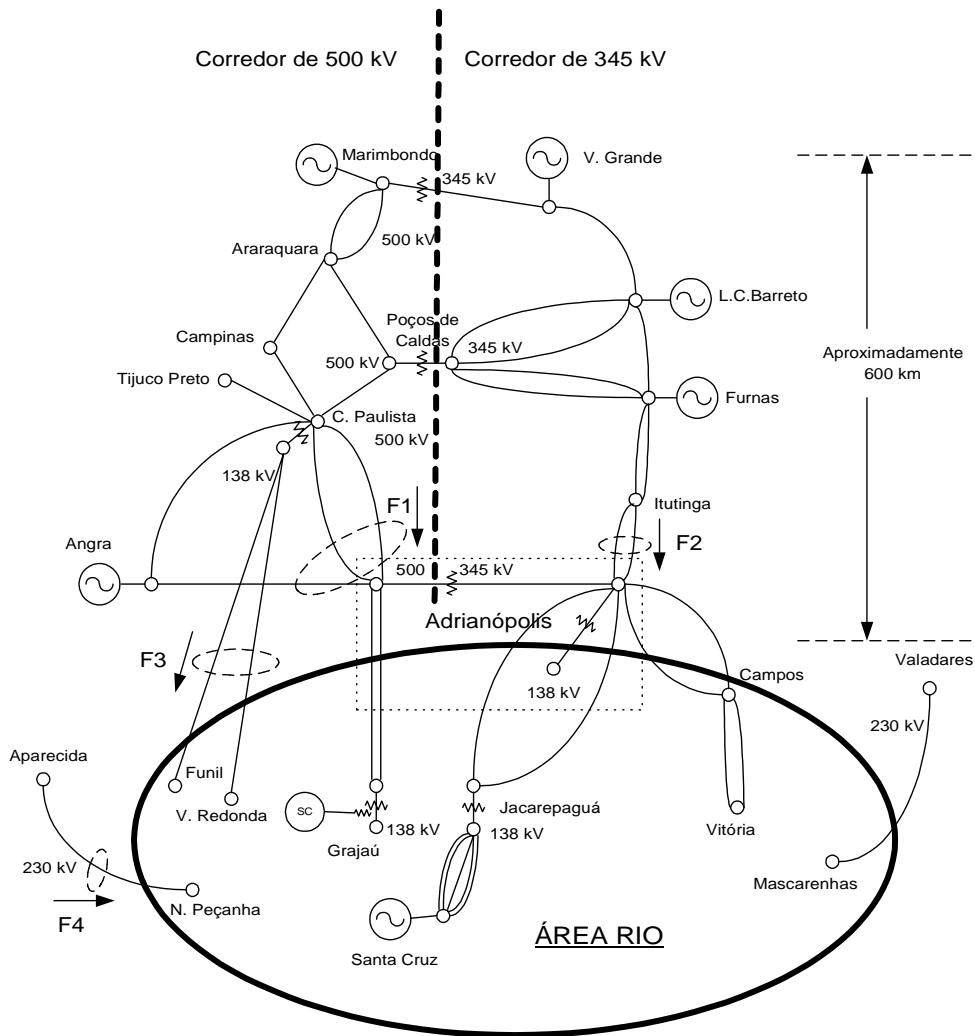


Figura III-1 - Sistema de Transmissão para a Área Rio

A topologia do sistema estudado representa uma configuração do ano de 1991. A utilização deste sistema foi motivada por limitações impostas à época pelo programa de simulação utilizado, o FASTSIM, que estava ainda em desenvolvimento e, por isso, não estava preparado para processar casos com número muito grande de barras, além de não estarem ainda modelados alguns equipamentos já utilizados no sistema brasileiro, como o TCSC, por exemplo.

O fato de se tratar de uma configuração antiga não trouxe prejuízos para os resultados obtidos, uma vez que o objetivo foi mostrar a possibilidade de controlar a tensão do sistema elétrico com um SIF. Assim, é razoável assumir que, se o SIF é capaz de controlar a tensão do sistema elétrico de 1991, é também capaz de controlar a tensão do sistema atual, sendo necessários apenas

ajustes nas regras de operação, com base nas novas influências. Esta é uma das grandes vantagens de um sistema baseado em Lógica Fuzzy, conforme ressaltado anteriormente.

Além da utilização das usinas de influência para o controle de tensão, foram utilizados também, de uma forma hierárquica, os bancos de capacitores e reatores chaveáveis disponíveis na Área Rio.

III.3 Hierarquia Utilizada

Buscando explorar os recursos de forma ótima e coordenada, foi estabelecida uma hierarquia, ficando divididos os recursos em dois níveis, sendo um de controle através das usinas de influência e outro através do chaveamento de bancos de capacitores e reatores.

A Figura III-2 mostra os dois níveis hierárquicos definidos, sendo que o segundo nível é subdividido em três subníveis para que possam ser escolhidos os equipamentos a serem chaveados por estação e ao fim da escolha, seja definido apenas um equipamento a ser chaveado por vez, visando minimizar as variações de tensão e reduzir o número de chaveamentos.

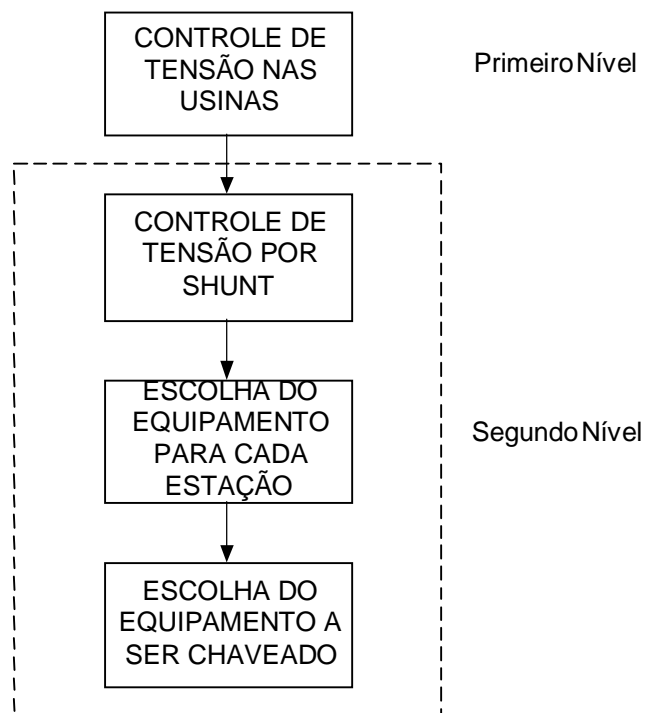


Figura III-2 - Níveis Hierárquicos

A utilização dos recursos de controle tensão das usinas como nível hierárquico superior foi estabelecida de forma a serem alcançados os seguintes objetivos:

- Exploração máxima do “line charging” das linhas de transmissão no caso de cargas altas, que, devido à característica do sistema com longos troncos, é muito significativa.
- Exploração mínima do “line charging” no caso de cargas baixas, já que nestes períodos o fornecimento de potência reativa pelas linhas torna-se prejudicial ao controle de tensão.
- Manter a tensão nas barras controladas, sempre que possível, em valores praticamente constantes, sem grandes variações discretas, como as ocasionadas por inserção de equipamentos shunt.
- Reduzir o número de chaveamentos de equipamentos, já que, enquanto possível, as tensões são controladas pelas usinas.

III.4 Sistema de Inferência Fuzzy

Um Sistema de Inferência Fuzzy (SIF) é um algoritmo de processamento de informação através de regras de produção fuzzy. Na

Figura III-3 temos o diagrama de blocos com os elementos que formam um Sistema de Inferência Fuzzy.

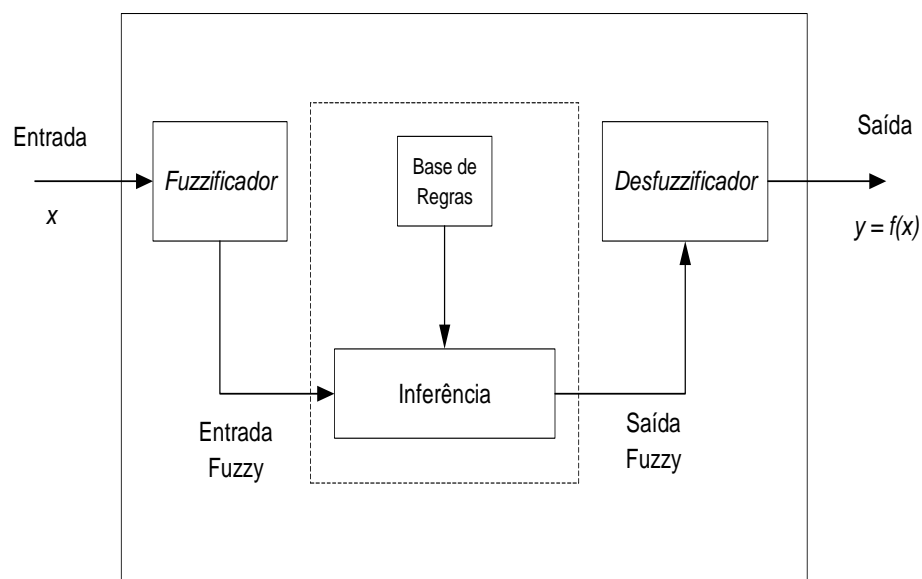


Figura III-3 - Sistema de Inferência Fuzzy

A base de regras caracteriza os objetivos e a estratégia de controle utilizadas no SIF. Estas regras são um conjunto de declarações do tipo:

Se x é A (antecedente), então y é B (conseqüente).

Onde x e y são variáveis numéricas e A e B são variáveis lingüísticas. É importante ressaltar que na base de regras está o conhecimento do operador humano, sendo as estratégias de controle implementadas, as mesmas utilizadas na operação feita por ele.

Uma descrição mais detalhada das funções dos demais blocos que compõem um SIF pode ser observada em [31].

III.5 Integração SIF Sistema de Potência

Como variáveis de entrada, que são as variáveis a serem controladas, foram definidas as tensões das barras de Adrianópolis 138 kV, Jacarepaguá 138 kV e a potência reativa dos compensadores síncronos de Grajaú. As tensões das barras de Adrianópolis 138 kV e Jacarepaguá 138 kV foram escolhidas por serem, junto com a tensão da barra de Grajaú 138 kV, os principais pontos de entrega do sistema de transmissão para a Área Rio e refletirem as condições de tensão em toda a área. A potência reativa dos compensadores síncronos de Grajaú foi escolhida para que seja possível atingir o objetivo de manter geração em torno de zero ou pouco indutiva, de forma a obter uma margem satisfatória de estabilidade de tensão, além de manter a tensão de Grajaú 138 kV no valor desejado, já que, conforme citado anteriormente, este também é um ponto importante para a tensão da área.

Como variáveis de saída ou de controle, conforme já descrito, foram definidas as variações das tensões nos barramentos de alta tensão das usinas de Marimbondo, Furnas e Angra, por serem usinas de grande influência na área e, ao mesmo tempo, de pouca influência nas áreas adjacentes.

A Figura III-4 mostra o SIF, com as suas entradas e saídas, onde:

- ADKV – Tensão de 138 kV do barramento de Adrianópolis;
- JPKV - Tensão de 138 kV do barramento de Jacarepaguá;
- GRCS – Potência reativa dos compensadores síncronos de Grajaú;
- MRKV – Valor da variação de tensão que deve ser feita, no barramento de 500 kV, na usina de Marimbondo;

- FUKV - Valor da variação de tensão que deve ser feita, no barramento de 345 kV, na usina de Furnas;
- ANKV - Valor da variação de tensão que deve ser feita, no barramento de 500 kV, na usina de Angra;

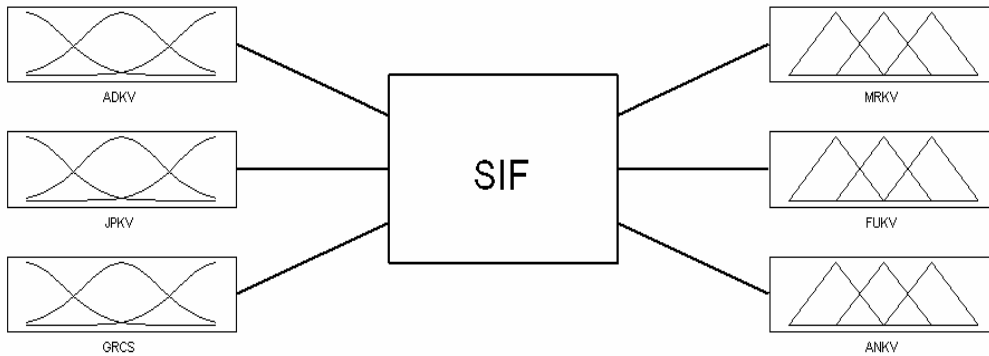


Figura III-4 - Entradas e Saídas do Controlador

A Figura III-5 ilustra a operação em malha fechada do Sistema de Inferência Fuzzy (SIF) com o Sistema da Potência.

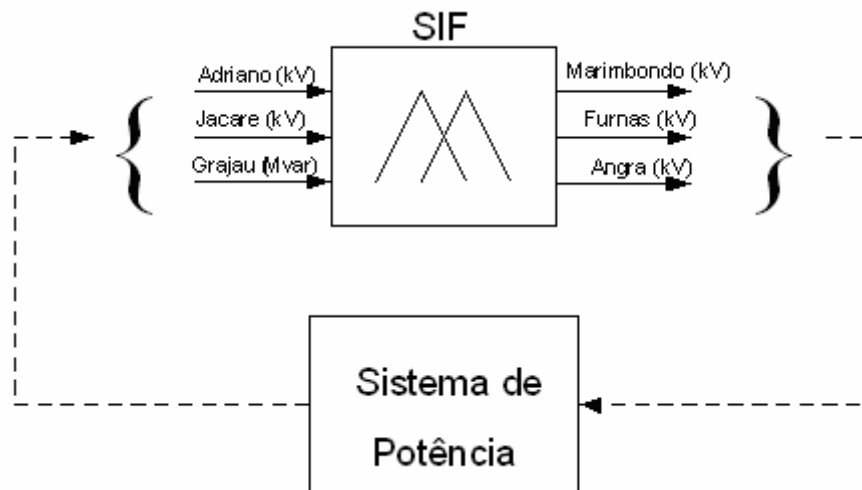


Figura III-5 - Integração SIF - Sistema de Potência

III.5.1 Variáveis Linguísticas e Funções de Pertinência

Cada variável de entrada e saída possui um conjunto de variáveis linguísticas, com suas respectivas funções de pertinência. A Figura III-6 ilustra as funções de pertinência da variável Adrianópolis_138 kV. No eixo horizontal temos o valor de tensão, e no eixo vertical temos os graus de pertinência.

Na Figura III-7 temos, no eixo horizontal, os valores de variação que devem ser feitos na tensão do barramento de 500 kV de Marimbondo para controle dos objetivos. Esses valores estão normalizados, as reduções são valores negativos e os aumentos positivos.

Nesta figura é possível observar que a variável linguística MANTER é o objetivo a ser atingido, uma vez que não deve haver variações caso as entradas estejam dentro dos valores desejados. Além disso, esta variável é também uma banda morta, dado que pequenas variações na entrada não devem causar respostas na saída, para que não haja um grande número de variações desnecessárias.




Figura III-6- Funções de Pertinência da Variável de Entrada ADKV

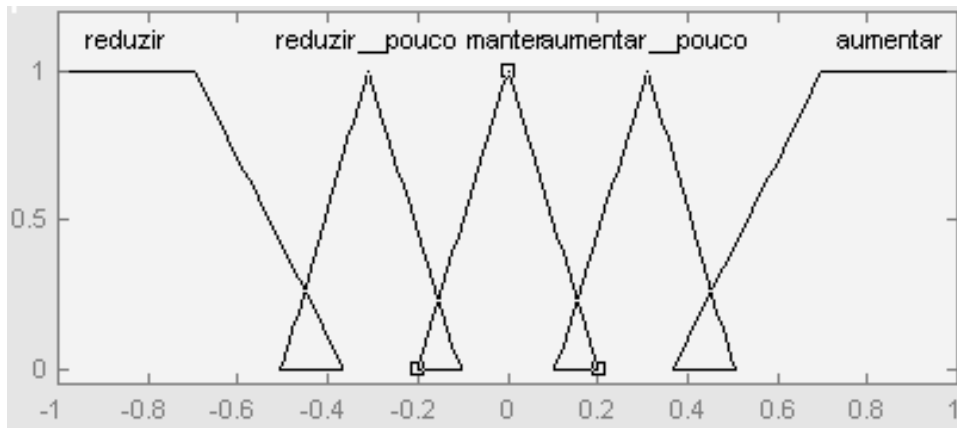


Figura III-7 - Funções de pertinência da Variável de Saída MRKV

Na elaboração das regras, foram estabelecidas as seguintes diretrizes:

- Manter as tensões de entrada, isto é, Jacarepaguá e Adrianópolis, em torno dos valores desejados pelas concessionárias. Isto corresponde a se assumir valores elevados de pertinência dessas tensões ao conjunto fuzzy representando o termo BOA do conjunto de termos das variáveis lingüísticas associadas a essas tensões. Na Figura III-6 é possível observar, como exemplo, que este valor está em torno de 144 kV para a tensão no barramento de 138 kV de Adrianópolis.
- Manter a geração de potência reativa dos compensadores síncronos de Grajaú entre zero e 100 Mvar indutivos, correspondendo a valores elevados da função de pertinência do termo BOM ou do termo POUCO_INDUTIVO, por questões de segurança de tensão na área.

III.5.2 Base de Regras

Com base na experiência dos especialistas de operação do sistema da Área Rio, adquiridas através das entrevistas e do conhecimento das instruções de operação da referida área, foram criadas 32 regras de operação que formam a base de regras. A Tabela III-1 apresenta 10 dessas regras.

Tomando como exemplo a Regra 1, ela traduz a seguinte situação: Se a tensão de Adrianópolis 138kV estiver BOA, a tensão de Jacarepaguá 138kV estiver BOA e a geração de potência reativa dos compensadores síncronos de Grajaú estiver BOM, Então as tensões nos barramentos de alta tensão das usinas de Marimbondo, Furnas e Angra devem ser mantidas nos valores em que se encontram.

A situação definida na regra 1 é o regime permanente, onde todos os objetivos foram atingidos e, por isso, as tensões das variáveis de controle devem permanecer inalteradas. Caso os compensadores síncronos de Grajaú estivessem pouco indutivos, os objetivos também estariam atingidos e seria uma outra situação de regime permanente. Isto ocorre porque a carga da Área Rio é suprida por longas linhas de transmissão e, no caso de uma falha com desligamento automático de uma destas linhas, principalmente em condições de carregamento alto, ocorre uma queda brusca de tensão, já que estas linhas dão um suporte significativo de potência reativa para a área e deve haver margem nos compensadores síncronos para que esta queda seja atenuada, não causando perda de carga.

Tabela III-1 -Exemplos de Regras de Operação

REGRAS	Entradas			Saídas		
	ADRIA	JACAR	GRAJ	MAR	FUR	ANG
1	BOA	BOA	BOM	MAN	MAN	MAN
2	BAI	BAI	CAP	AUM	AUM	AUM
3	BAI	BAI	PCAP	AUM	AUM	AUM
4	BAI	BOA	BOM	MAN	AUMP	AUMP
5	BAI	BOA	PCAP	MAN	AUMP	AUM
6	BOA	BAI	BOM	MAN	AUMP	MAN
7	BOA	BAI	PCAP	MAN	AUMP	AUMP
8	BOA	ALTA	BOM	MAN	DIMP	MAN
9	BOA	ALTA	IND	MAN	MAN	DIMP
10	PBAI	BAI	PCAP	AUM	AUM	AUM

Onde:

- MAN – Manter
- BAI – Baixa

- CAP – Capacitivo
- AUM – Aumentar
- PCAP – Pouco Capacitivo
- AUMP – Aumentar Pouco
- DIM - Diminuir
- DIMP – Diminuir Pouco
- IND – Indutivo
- PBAI – Pouco Baixa

III.6 Limites Operacionais

O controle de tensão deve procurar manter os seus objetivos. Porém, essa operação não pode fazer com que limites de equipamentos sejam violados. Para evitar estes problemas, foram implementados algoritmos que fazem a supervisão da operação destes limites.

A violação de limites não é tolerada de forma alguma, por isso caso haja alguma violação, mesmo com os objetivos não atingidos, o SIF não pode executar ações que resultem em um aumento desta violação.

Todas as violações que podem ocorrer durante a operação do SIF são supervisionadas. São elas:

- Violações de tensão, superior e inferior, em todos os barramentos, inclusive os intermediários dos corredores de transmissão de influência na Área Rio e terminais das unidades geradoras.
- Limite superior de corrente de campo das unidades geradoras, responsáveis pelo controle de tensão da Área.
- Limite superior de corrente de armadura das unidades geradoras, responsáveis pelo controle de tensão da Área.
- Limite inferior de absorção de potência reativa das unidades geradoras, responsáveis pelo controle de tensão da Área.

Para solução deste problema, foi implementado um algoritmo, mostrado na Figura III-8, que faz com que, antes que ocorra a variação da tensão de referência nas usinas sugerida pelo SIF, seja analisada a existência de alguma violação de limite operacional e, caso isto ocorra, seja cancelada a ação.

Todos os limites considerados são os limites operacionais de regime contínuo, sendo as tensões limitadas de acordo com os valores das instruções de operação e os limites de corrente de campo e armadura das máquinas são os limites nominais.

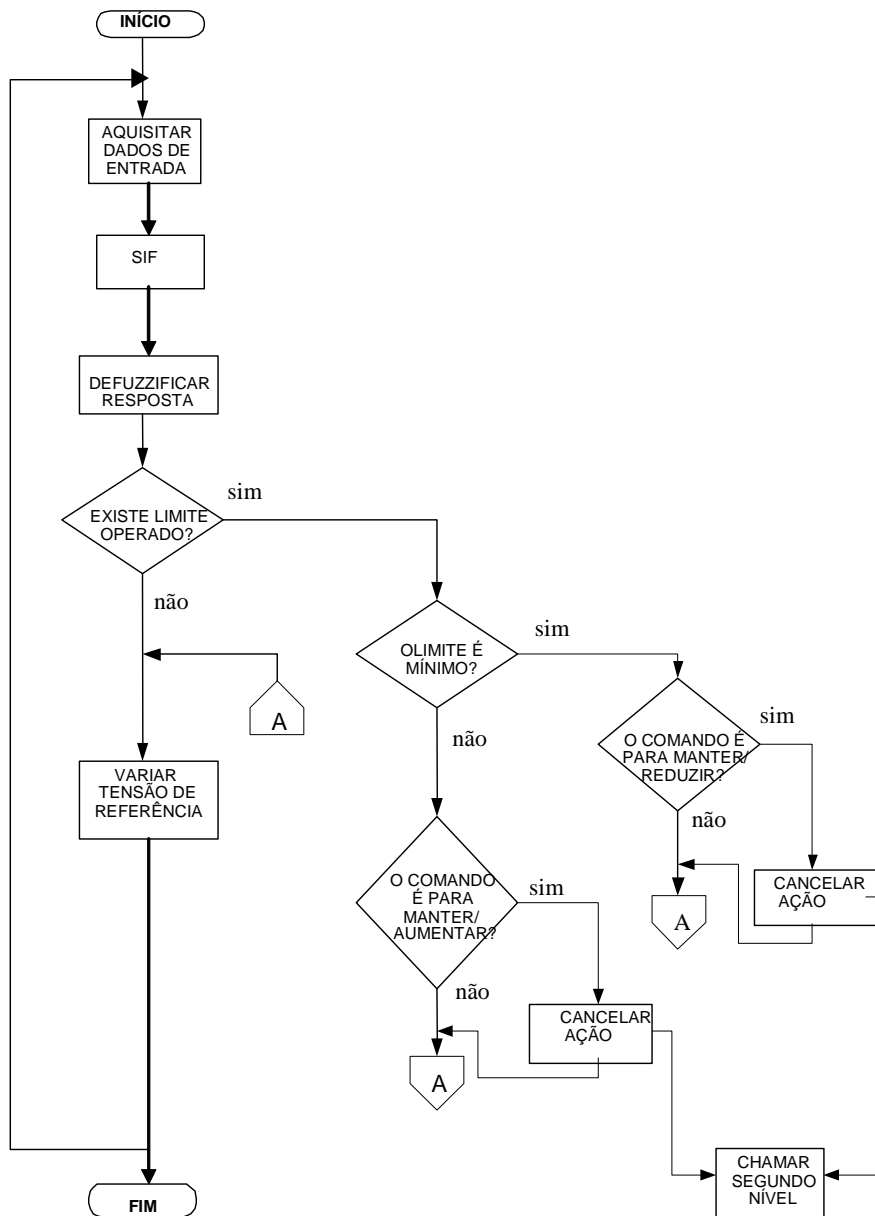


Figura III-8- Supervisão de Violação de Limites

O algoritmo de supervisão é individual para cada variável de controle. Sendo assim, caso haja violação em alguma variável de controle, fica impedida a variação da tensão apenas nesta variável, de forma que todas as outras podem ter a sua tensão variada de acordo com a sugestão do SIF.

III.7 Resultados Obtidos

Os resultados obtidos com esta ferramenta foram bastante positivos, mesmo com simulações envolvendo perdas de linha de transmissão de 500 kV, variações de carga em degrau e variações em rampa. Os resultados de algumas simulações são mostrados a seguir:

III.7.1 Simulação com Variações em Degrau

Durante esta simulação, são considerados os eventos descritos na Tabela III-2. A inserção de capacitores é feita manualmente e o desligamento da LT 500 kV Angra / Cachoeira Paulista simula um distúrbio, com o objetivo de demonstrar a robustez do controle, que é capaz de controlar a tensão mesmo com uma mudança na topologia do sistema.

Tabela III-2 - Eventos considerados

Tempo(s)	Evento
20	Inserção manual de cap. shunt pelo operador, sendo 160 Mvar em Adrianópolis 345 kV, 100 Mvar em Jacarepaguá 138 kV, e 40 Mvar em Adrianópolis 138 kV.
50	Inserção de capacitores shunt, sendo 200 Mvar na área da LIGHT e 300 Mvar nas áreas da CERJ e ESCELSA.
300	Desligamento da LT 500kV Angra / Cachoeira Paulista.

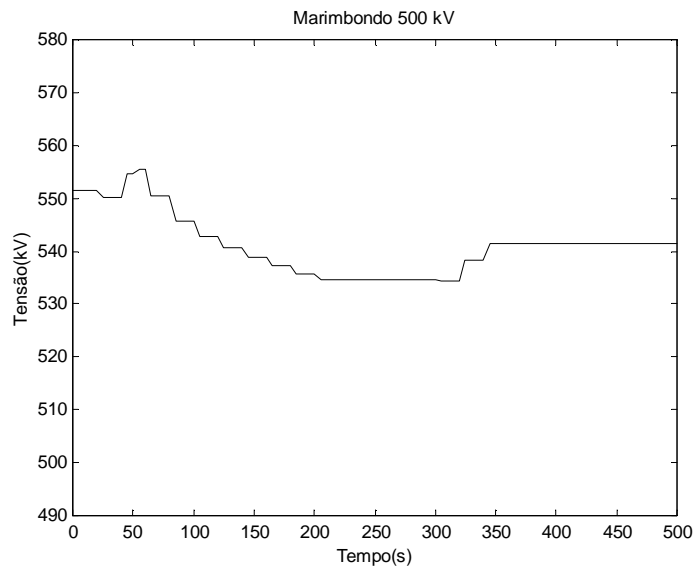


Figura III-9 - Tensão de Marimbondo 500 kV

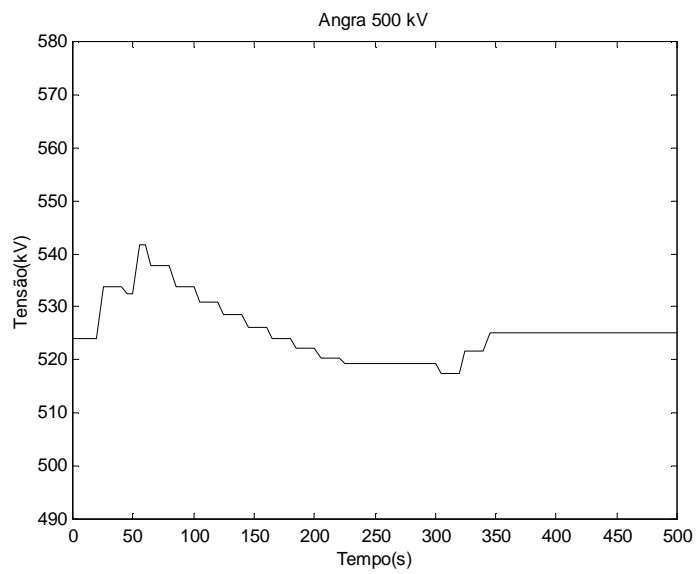


Figura III-10 - Tensão de Angra 500 kV

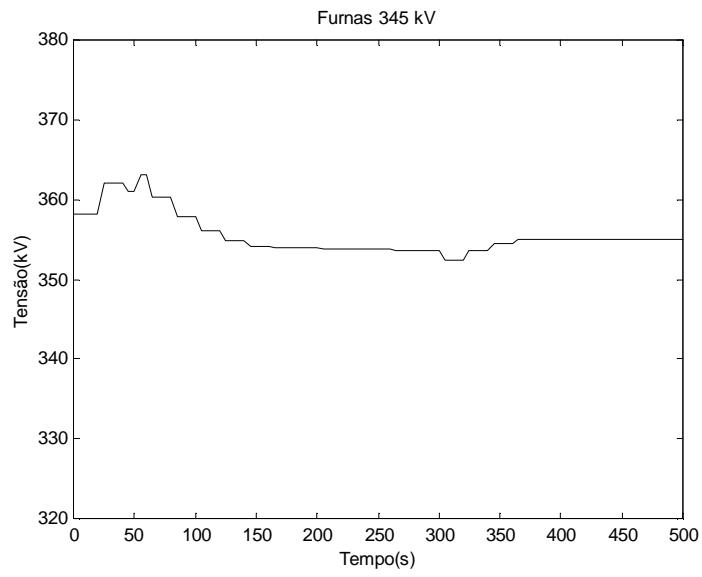


Figura III-11 - Tensão de Furnas 345 kV

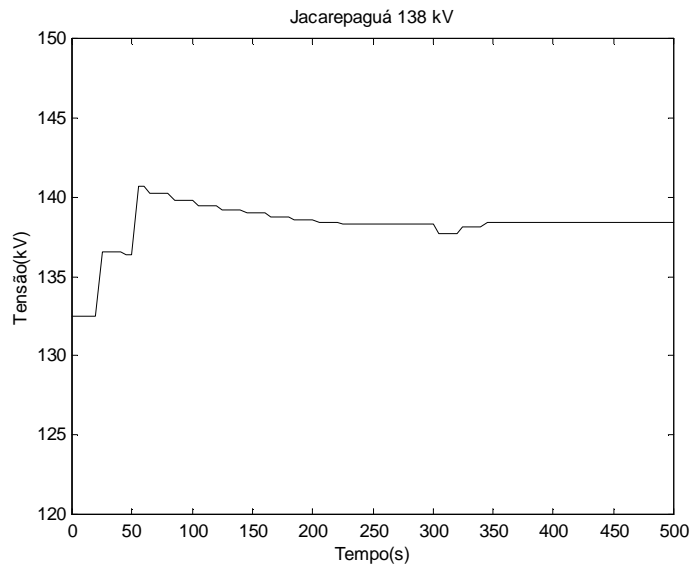


Figura III-12 - Tensão de Jacarepaguá 138 kV

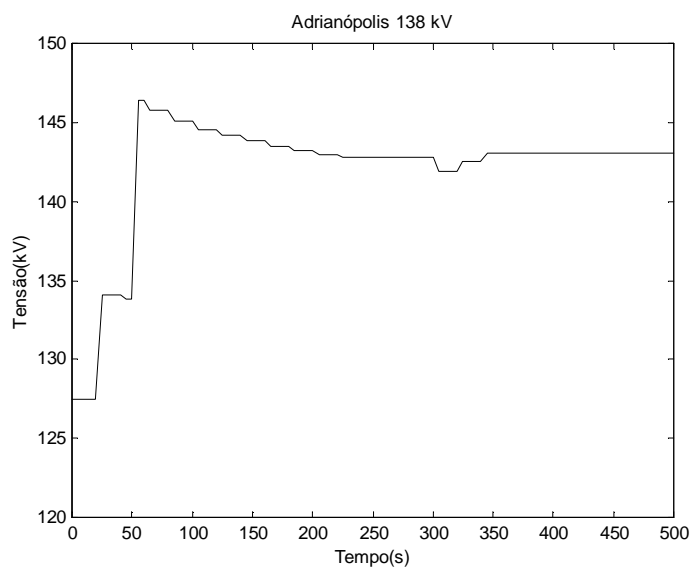


Figura III-13 - Tensão de Adrianópolis 138 kV




Figura III-14 - Geração dos Compensadores Síncronos de Grajaú

Analisando os resultados da simulação, podemos destacar as seguintes observações:

- Marimbondo 500 kV (Figura III-9)→ No início da simulação, a tensão se encontra acima do limite de 550 kV admissível (1,05p.u. na base de 525 kV). Neste instante as tensões na Área Rio, Adrianópolis e Jacarepaguá, se encontram baixas, o que faz com que a lógica do SIF envie ordem para

aumentar a tensão de Marimbondo. Porém o nível de supervisão faz com que a ação seja cancelada. No instante de 50s, todas as tensões monitoradas estão elevadas, devido ao chaveamento dos capacitores manualmente. A ação do SIF inicia a redução da tensão da usina parando por volta de 200s, quando todas as tensões estão em torno dos valores desejados. A perda da LT Angra/ Cachoeira Paulista aos 300s reduz as tensões, fazendo com que o SIF atue novamente, elevando a tensão da usina até o novo regime.

- Angra 500 kV (Figura III-10) → Aos 20s o SIF eleva a tensão da usina no seu primeiro ciclo de atuação, porém após os dois primeiros eventos, a tensão começa a ser reduzida pelo SIF passando a ter um comportamento semelhante à tensão de Marimbondo. A tensão de Furnas 345 kV também teve comportamento semelhante à Angra 500 kV, apenas atingindo o regime permanente mais cedo.
- Jacarepaguá 138 kV (Figura III-12) → A tensão no início da simulação é considerada muito baixa, só melhorando após a inserção dos capacitores. Porém a tensão ultrapassa o valor considerado como bom, que é entre 138 e 140 kV, sendo então reduzida pela ação do SIF nas usinas controladoras. Com a saída da LT, a tensão fica abaixo do valor desejado, sendo novamente corrigida pela ação do SIF.
- Adrianópolis 138 kV (Figura III-13) → A única diferença com relação à tensão de Jacarepaguá é que o valor desejado está entre 143 e 145 kV. O comportamento foi bem semelhante.
- Geração dos Compensadores Síncronos de Grajaú (Figura III-14) → Inicialmente os síncronos estão muito carregados, violando a recomendação das normas de operação, colocando a área susceptível a problemas transitórios de tensão. Após os dois eventos iniciais, a situação se inverte, ocorrendo uma absorção de potência reativa acima do recomendado. O SIF atua no sentido de diminuir a absorção de potência reativa levando os Síncronos a um novo regime, onde passam a absorver aproximadamente 90 Mvar, o que está dentro do objetivo de manter uma reserva de potência reativa girante na Área Rio.

III.7.2 Simulação com Variações em Rampa

A próxima simulação mostra uma situação mais próxima do caso real, onde temos os mesmos eventos da Tabela III-2, porém não há regime permanente, já que é também considerada uma rampa negativa de 10% de redução de carga ativa e reativa, em toda a Área Rio, durante toda a simulação.

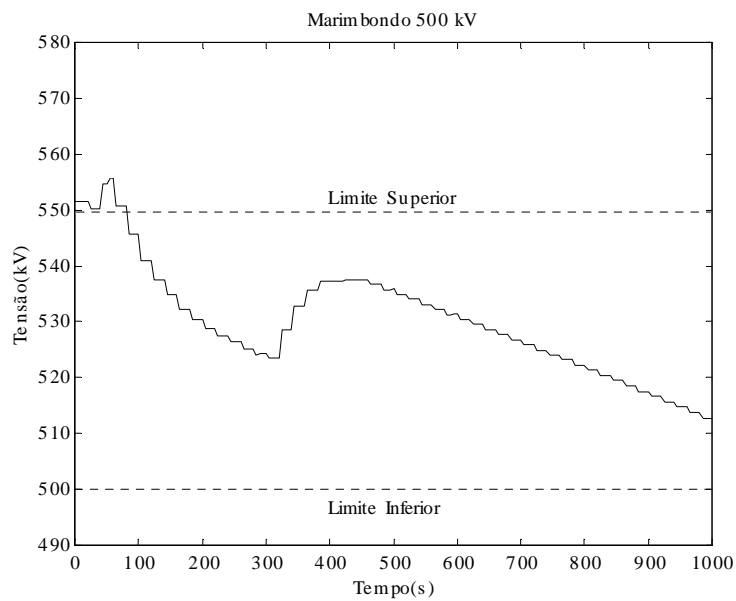


Figura III-15 - Tensão de Marimbondo 500 kV

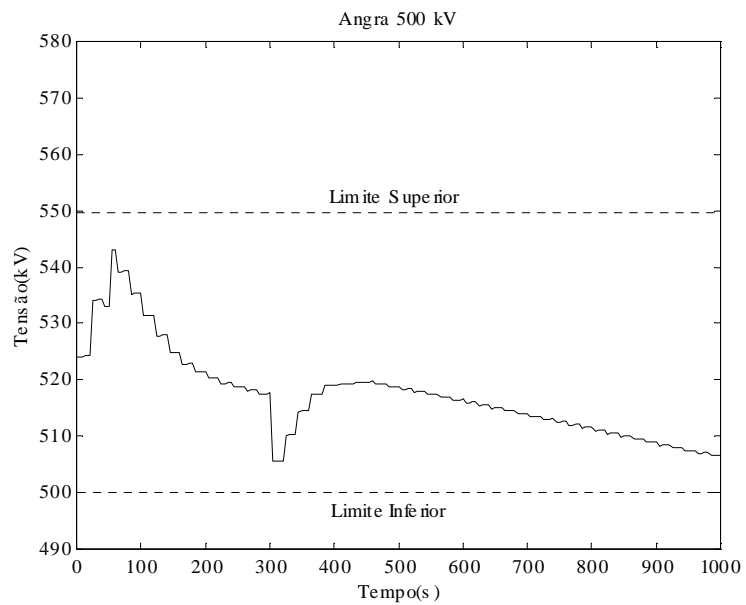


Figura III-16 - Tensão de Angra 500 kV

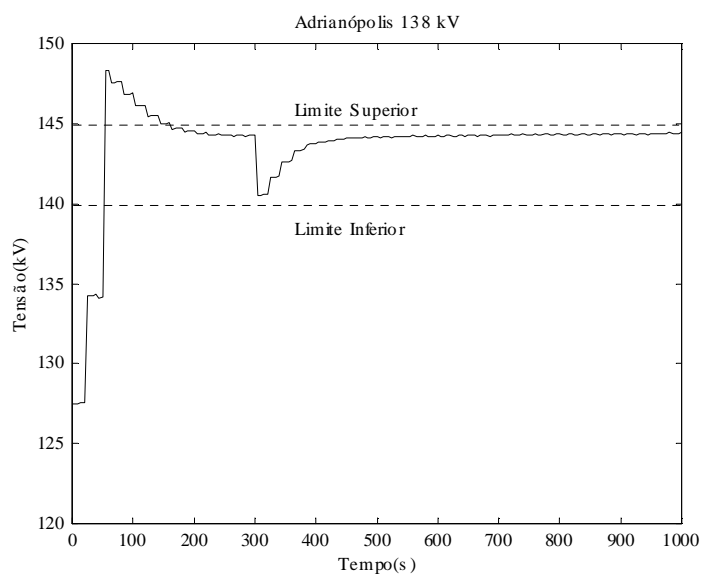


Figura III-17 - Tensão de Adrianópolis 138 kV

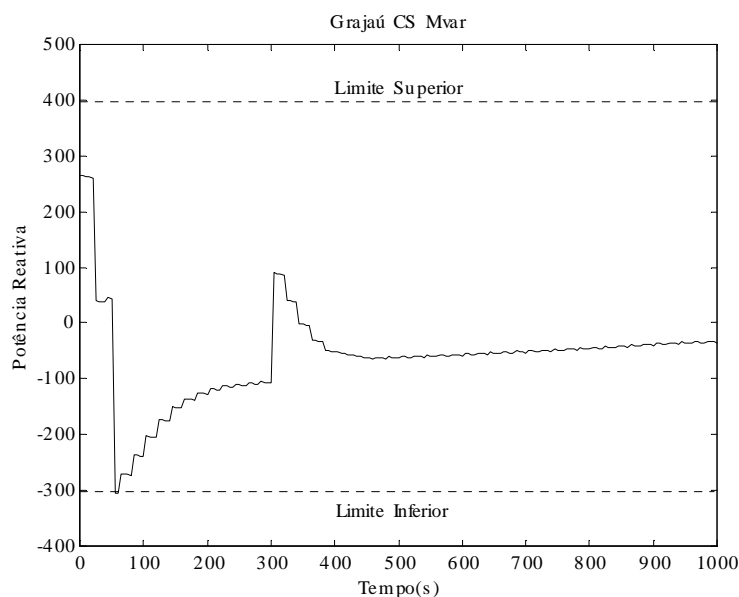


Figura III-18 - Geração dos Compensadores Síncronos de Grajaú

Com base nos gráficos desta simulação podemos destacar os seguintes aspectos:

- Mesmo com a rampa negativa aplicada as tensões controladas permanecem ao redor do valor desejado.
- As tensões das usinas sofrem variação a cada ciclo, de forma a manter os objetivos, independente das variações de carga durante toda a simulação. Apesar de não haver regime permanente, as tensões controladas se comportam de maneira praticamente constante.
- Após o desligamento da LT aos 300 segundos, a tensão de Adrianópolis está dentro dos limites de operação, porém um pouco longe do valor desejado, que é de 144 kV. Por isso, há atuação do SIF para elevar a tensão, até que o valor esteja ao redor do desejado.
- Os compensadores síncronos de Grajaú não permanecem constantes. Porém, a geração varia entre zero e -100 Mvar, isto é, dentro dos objetivos.
- As linhas tracejadas indicam as limites operativos, sendo que, no caso das tensões de controle, Marimbondo e Angra, são os limites mínimo e máximo de operação da tensão do barramento da usina. Porém, no caso das tensões

controladas e dos compensadores síncronos de Grajaú são os limites da faixa de operação e não a faixa de operação desejada. No caso de Adrianópolis, por exemplo, a faixa desejada de operação é entre 143 e 145 kV e os limites operacionais são 140 e 145 kV para o período de carga pesada.

III.8 Resultados Obtidos Com Modificação das Regras

Os resultados obtidos nas simulações anteriores refletem a capacidade da lógica fuzzy de emular o raciocínio humano e obter resultados positivos. Porém, os resultados são tão positivos quanto for a experiência do especialista inserida nas regras de controle. Caso o “especialista” não tenha a experiência e o conhecimento necessários para efetuar a tarefa de forma positiva, a lógica refletirá o seu conhecimento e os resultados serão, igualmente, não tão positivos.

Para demonstrar que a mudança na base de regras afeta diretamente os resultados obtidos, mesmo sendo estas regras aparentemente coerentes, foram executadas as mesmas simulações anteriores, porém com algumas modificações de estratégia de controle. Os resultados de algumas simulações são mostrados a seguir:

III.8.1 Simulação com Variações em Degrau

Durante a simulação são considerados os mesmos eventos descritos na Tabela III-2. Porém, a base de regras simula um operador que opta por utilizar a estratégia de controlar a tensão de Adrianópolis e Jacarepaguá 138 kV priorizando a usina de Marimbondo, de forma a reduzir a geração de potência reativa das grandes linhas de transmissão no tronco de 500 kV.

Desta forma, para uma situação de tensão de Adrianópolis e Jacarepaguá 138 kV altas e geração de potência reativa dos compensadores síncronos de Grajaú absorvendo muita potência reativa, foi inserida uma regra para reduzir muito a tensão do barramento de Marimbondo e manter a tensão nas demais, quando a regra estabelecida era reduzir pouco a tensão nas três usinas.

O resultado da modificação da estratégia está mostrado a seguir.

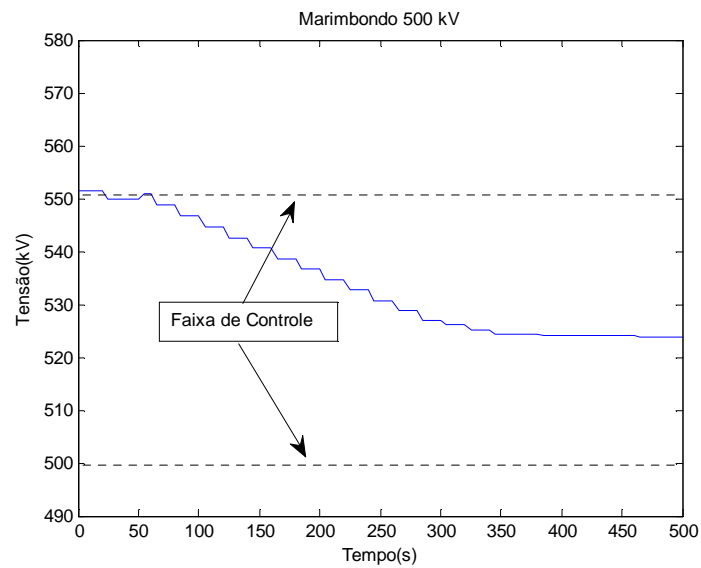


Figura III-19 - Tensão de Marimbondo 500 kV




Figura III-20 - Tensão de Angra 500 kV

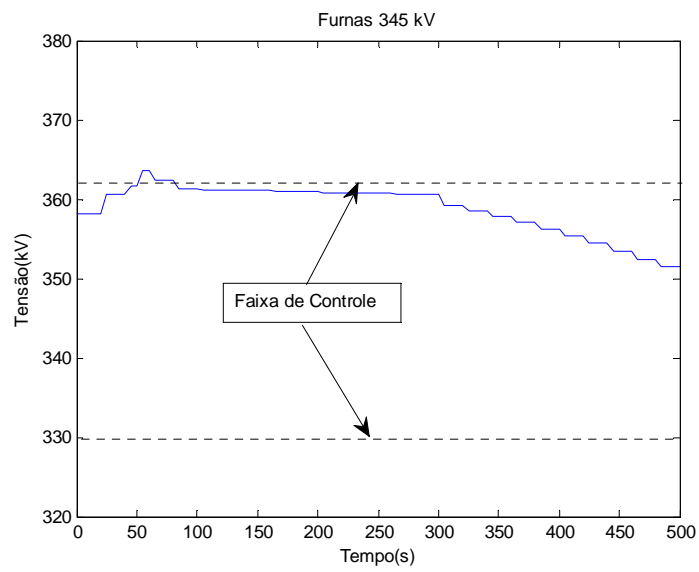


Figura III-21 - Tensão de Furnas 345 kV




Figura III-22 - Tensão de Jacarepaguá 138 kV

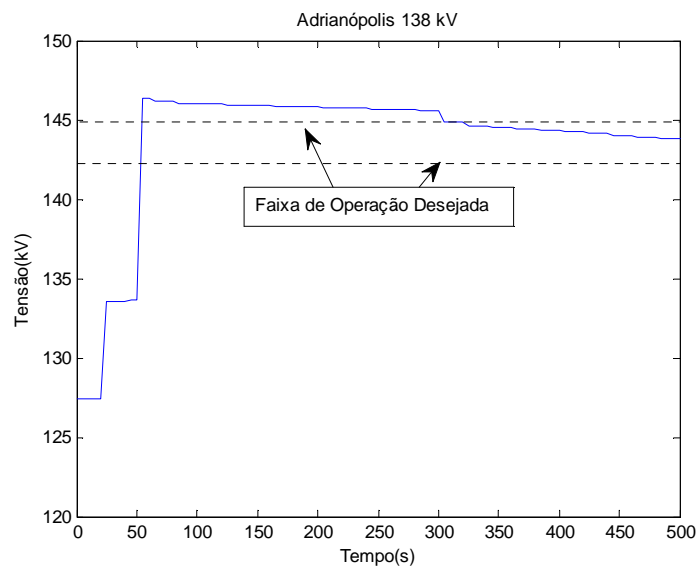


Figura III-23 - Tensão de Adrianópolis 138 kV




Figura III-24 - Geração dos Compensadores Síncronos de Grajaú

Analisando os resultados da simulação, podemos destacar as seguintes observações:

- Marimbondo 500 kV (Figura III-19)→ É possível observar que a tensão de Marimbondo 500 kV é bem mais reduzida do que na simulação com a base de regras correta, refletindo a estratégia de priorizar esta usina quando de tensões altas na Área Rio. A tensão somente pára de ser reduzida após o desligamento da LT Angra/ Cachoeira Paulista aos 300s como consequência do melhor perfil de tensão de Adrianópolis e Jacarepaguá 138 kV.
- Angra 500 kV (Figura III-20) → A tensão de Angra 500 kV permanece praticamente todo o tempo sem receber sinais de controle do SIF, uma vez que a intenção é priorizar a tensão de Marimbondo 500 kV. Com isto, a tensão do barramento de 500 kV de Angra fica muito mais alta do que na simulação com a base correta e, por isso, não influencia no controle das tensões da Área Rio.
- Furnas 345 kV (Figura III-21)→ A tensão de Furnas 345 kV permanece alta no início da simulação sem maiores modificações, também refletindo a priorização da tensão de Marimbondo 500 kV para controle das tensões da Área Rio. Porém, quando as tensões da Área Rio atingem a faixa de

controle desejada, após o desligamento da LT Angra/ Cachoeira Paulista aos 300s, apenas a geração de potência reativa dos compensadores síncronos de Grajaú está fora da faixa desejada. Deste momento em diante a tensão de Furnas 345 kV começa a ser reduzida com a intenção de trazer a geração de potência reativa dos compensadores síncronos de Grajaú para a faixa desejada.

- Jacarepaguá 138 kV (Figura III-22) → A tensão de Jacarepaguá 138 kV permanece durante grande parte da simulação alta, fora da faixa de controle desejada, refletindo a ineficiência da estratégia de priorização das reduções de tensão em Marimbondo 500 kV. Após o desligamento da LT Angra/ Cachoeira Paulista aos 300s, a tensão entra na faixa de controle desejada permanecendo assim até o final da simulação. Este comportamento é completamente diferente do comportamento utilizando a base de regras correta, quando a tensão permanece praticamente todo o tempo dentro da faixa desejada, somente necessitando de regulação no início da simulação e após o desligamento da LT Angra/ Cachoeira Paulista, aos 300s.
- Adrianópolis 138 kV (Figura III-23) → O comportamento de tensão de Adrianópolis 138 kV foi semelhante ao da tensão de Jacarepaguá 138 kV, sendo também bem diferente do comportamento observado, quando utilizada a base de regras correta.
- Geração dos Compensadores Síncronos de Grajaú (Figura III-24) → A geração de potência reativa dos compensadores síncronos de Grajaú permanece durante toda a simulação fora da faixa de operação desejada. Antes do desligamento da LT Angra/ Cachoeira Paulista, que ocorre aos 300s, é possível observar que a estratégia de priorização da tensão de Marimbondo 500 kV não tem influência significativa da geração da potência reativa dos compensadores síncronos de Grajaú, somente após o desligamento da LT há uma modificação significativa na geração da potência reativa dos compensadores síncronos, demonstrando a maior eficiência do controle da potência reativa dos compensadores de Grajaú através da tensão de Furnas 345 kV.

III.8.2 Simulação com Variações em Rampa

Nesta simulação temos os mesmos eventos da Tabela III-2 e também é considerada uma rampa negativa de 10% de redução de carga reativa, em toda a Área Rio, durante toda a simulação. A base de regras utilizada é a mesma da simulação anterior.

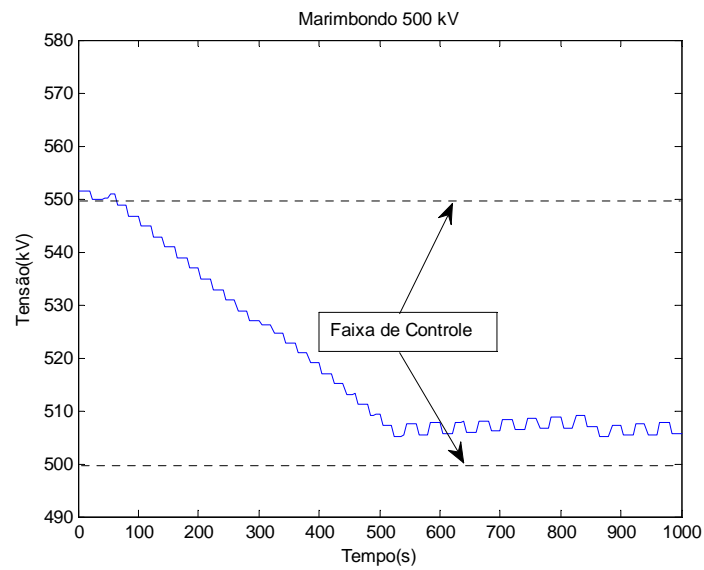


Figura III-25 - Tensão de Marimbondo 500 kV

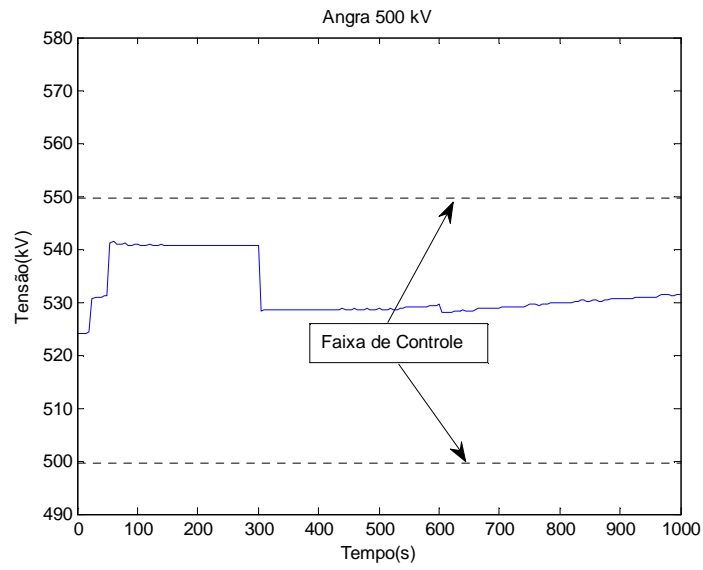


Figura III-26 - Tensão de Angra 500 kV




Figura III-27 - Tensão de Furnas 345 kV




Figura III-28 - Tensão de Adrianópolis 138 kV

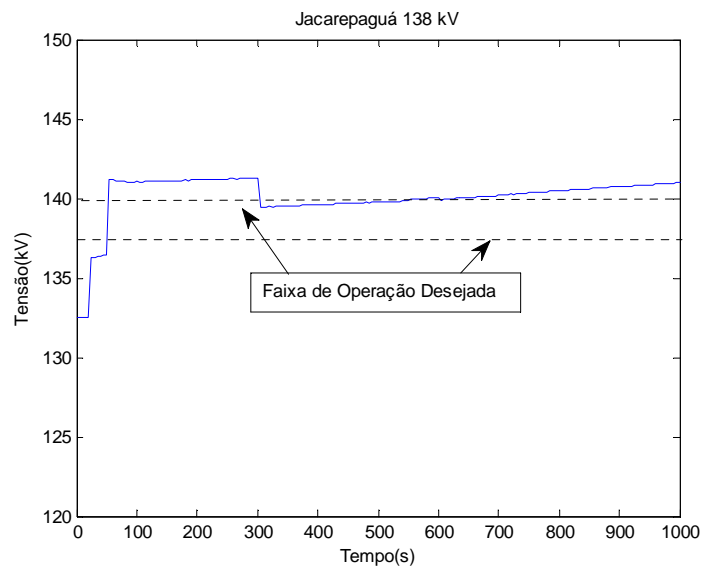


Figura III-29 - Tensão de Jacarepaguá 138 kV

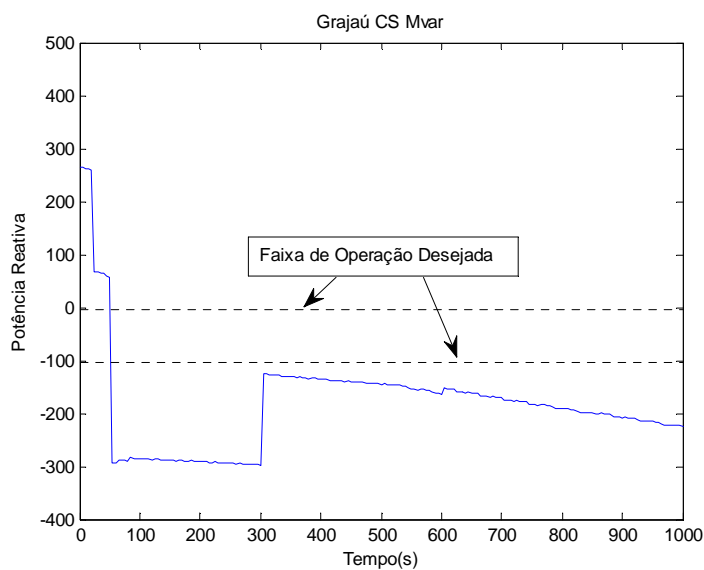


Figura III-30 - Geração dos Compensadores Síncronos de Grajaú

Analisando os resultados da simulação, podemos destacar as seguintes observações:

- Marimbondo 500 kV (Figura III-25)→ É possível observar que a tensão de Marimbondo 500 kV é reduzida durante todo o tempo até atingir valores mínimos, situação bem diferente da simulação com a base de regras correta, também refletindo a estratégia de priorizar esta usina quando de tensões altas na Área Rio. Mesmo após o desligamento da LT Angra/ Cachoeira Paulista aos 300s, as ações de controle não se invertem, uma vez que as tensões de Adrianópolis e Jacarepaguá 138 kV estão acima dos limites máximos.
- Angra 500 kV (Figura III-26) → Como na simulação sem variação em rampa, a tensão de Angra 500 kV permanece praticamente todo o tempo sem receber sinais de controle do SIF, uma vez que a base de regras é a mesma e a intenção é priorizar a tensão de Marimbondo 500 kV. Com isto, a tensão do barramento de 500 kV de Angra fica muito mais alta do que na simulação com a base correta e, por isso, não influencia no controle das tensões da Área Rio.
- Furnas 345 kV (Figura III-27)→ A tensão de Furnas 345 kV permanece alta durante toda a simulação, sem maiores modificações também refletindo

a priorização da tensão de Marimbondo 500 kV para controle das tensões da Área Rio. Como as tensões da área Rio não atingem em nenhum momento a faixa de controle desejada, diferente da simulação anterior, a tensão de Furnas 345 kV não é reduzida.

- Adrianópolis 138 kV (Figura III-28) → A tensão de Adrianópolis 138 kV permanece praticamente todo o tempo acima do limite máximo, confirmando que a estratégia de reduzir muito a tensão de Marimbondo 500 kV não é eficiente durante período de saída de carga.
- Jacarepaguá 138 kV (Figura III-29) → A tensão de Jacarepaguá 138 kV permanece durante grande parte da simulação alta, fora da faixa de controle desejada, refletindo também a ineficiência da estratégia de priorização das reduções de tensão em Marimbondo 500 kV, quando da saída de carga. Após o desligamento da LT Angra/ Cachoeira Paulista aos 300s, a tensão entra na faixa de controle desejada, porém o controle não consegue mantê-la dentro dos valores desejados uma vez que a carga continua sendo reduzida até o final da simulação. Este comportamento também é completamente diferente do comportamento utilizando a base de regras correta, quando a tensão permanece praticamente todo o tempo dentro da faixa desejada, somente necessitando de regulação no início da simulação e após o desligamento da LT Angra/ Cachoeira Paulista, aos 300s.
- Geração dos Compensadores Síncronos de Grajaú (Figura III-30) → A geração de potência reativa dos compensadores síncronos de Grajaú permanece durante toda a simulação fora da faixa de operação desejada.

III.9 Conclusões Finais do Capítulo

Baseado nas simulações anteriores envolvendo duas bases de regras distintas é possível observar claramente a importância do conhecimento do especialista no resultado final do Sistema de Inferência Fuzzy (SIF).

Com a primeira base de regras os resultados foram bastante positivos, mas as simulações com a base de regras modificada não demonstraram a capacidade de controlar o sistema adequadamente.

É importante observar que a mudança de estratégia de controle foi relativamente simples e coerente, não tendo sido feita nenhuma modificação propositadamente equivocada de forma a obter resultados negativos.

Desta forma, podemos observar a necessidade de utilização de uma ferramenta que inclua a capacidade de aprendizado ao (SIF), com o objetivo de obter a política de controle adequada.

Capítulo IV

Implementação e Resultados

A proposta deste trabalho é a inclusão de um algoritmo que dê ao controlador proposto em [9] a característica de aprendizado, de forma que o mesmo possa aprender uma política ótima de controle, dado um universo de ações possíveis. Desta forma, é possível tanto confirmar a eficiência de regras de controle provenientes de entrevistas com especialistas, como descobrir regras com desempenho superior.

O algoritmo proposto é o Q-learning, por sua característica de aprendizado através de interações com o ambiente sem a necessidade de conhecimento do modelo do sistema e por ser o método de aprendizado que apresentou os melhores resultados de convergência, sendo por isso largamente estudado em sistemas de controle.

O Algoritmo Q-learning foi adaptado para trabalhar com a base de regras e as variáveis lingüísticas do sistema de inferência fuzzy aplicados em [9].

Mesmo ciente de que o Sistema Elétrico é um sistema não-estacionário, será assumido que a variação do Sistema Elétrico seja lenta, conforme proposto em [14], e que esta variação não prejudica o aprendizado.

A aplicação do método é feita no SIF contínuo, uma vez que é neste nível que os efeitos não-lineares são mais significativos. Além disso, é considerado que o sistema especialista aplicado ao segundo nível, para chaveamento de bancos de capacitores e reatores, é bastante eficiente.

Para demonstração desta Tese, após o aprendizado do primeiro nível, serão feitas simulações com os dois níveis ativos, sendo utilizado no segundo nível o mesmo sistema especialista utilizado em [9].

O aprendizado é feito inicialmente para o Sistema Completo. Após a determinação da política ótima de controle, será avaliado o comportamento

desta política em sistemas com variações da topologia, isto é, com desligamento de linhas de transmissão, simulando as situações de manutenções programadas com impedimentos de longo período e distúrbios temporários.

O detalhamento da implementação do estudo é mostrado a seguir.

IV.1 Determinação dos Estados do Ambiente

Os estados do ambiente são, na verdade, a situação das variáveis controladas da área, isto é, a determinação do conjunto de estados S consiste em determinar todas as possíveis situações em que se encontrem as variáveis controladas. Para o caso em estudo, são as tensões dos barramentos de Adrianópolis 138 kV, Jacarepaguá 138 kV e a geração de potência reativa dos compensadores síncronos de Grajaú.

Como os estados são variáveis “fuzzy”, é necessário que se faça uma discretização do ambiente para que os estados possam ser tabulados. A discretização será então feita considerando o cenário mais desfavorável. Isto quer dizer que, caso as tensões estejam em situações intermediárias ou “fuzzy”, estas serão consideradas como se estivessem na situação mais adversa. Como exemplo temos a seguir a Figura IV-1, onde a tensão se encontra na interseção dos conjuntos “pouco_baixa” e “boa”. Neste caso a tensão será considerada como pouco baixa.




Figura IV-1 - Determinação do Conjunto de Estados do Sistema

Conforme já descrito anteriormente, deve-se tomar cuidado com a dimensionalidade do sistema; desta forma o conjunto de estados contém apenas situações com maior probabilidade de ocorrerem na prática.

A Tabela IV-1 mostra todos os 60 estados possíveis, que resultam da combinação de 4 funções de pertinência para as tensões de Adrianópolis 138 kV, 3 funções de pertinência para as tensões de Jacarepaguá 138 kV e 5 funções de pertinência para a geração de potência reativa nos compensadores síncronos de Grajaú. Os Estados com maior probabilidade de ocorrer estão sombreados.

O primeiro estado da Tabela IV-1 é um exemplo de situação que deve ser excluído, considerando que não é esperado que ocorra uma situação de tensões baixas na Área Rio e absorção de potência reativa nos compensadores síncronos de Grajaú.

Tabela IV-1 - Total de Estados Possíveis

Adrianópolis 138 kV	Jacarepaguá 138 kV	Síncronos de Grajaú
Baixa	Baixa	Indutivo
Baixa	Baixa	Pouco Indutivo
Baixa	Baixa	Bom
Baixa	Baixa	Pouco Capacitivo
Baixa	Baixa	Capacitivo
Baixa	Boa	Indutivo
Baixa	Boa	Pouco Indutivo
Baixa	Boa	Bom
Baixa	Boa	Pouco Capacitivo
Baixa	Boa	Capacitivo
Baixa	Alta	Indutivo
Baixa	Alta	Pouco Indutivo
Baixa	Alta	Bom
Baixa	Alta	Pouco Capacitivo
Baixa	Alta	Capacitivo
Pouco Baixa	Baixa	Indutivo
Pouco Baixa	Baixa	Pouco Indutivo
Pouco Baixa	Baixa	Bom
Pouco Baixa	Baixa	Pouco Capacitivo
Pouco Baixa	Baixa	Capacitivo
Pouco Baixa	Boa	Indutivo
Pouco Baixa	Boa	Pouco Indutivo
Pouco Baixa	Boa	Bom
Pouco Baixa	Boa	Pouco Capacitivo

Pouco Baixa	Boa	Capacitivo
Pouco Baixa	Alta	Indutivo
Pouco Baixa	Alta	Pouco Indutivo
Pouco Baixa	Alta	Bom
Pouco Baixa	Alta	Pouco Capacitivo
Pouco Baixa	Alta	Capacitivo
Boa	Baixa	Indutivo
Boa	Baixa	Pouco Indutivo
Boa	Baixa	Bom
Boa	Baixa	Pouco Capacitivo
Boa	Baixa	Capacitivo
Boa	Boa	Indutivo
Boa	Boa	Pouco Indutivo
Boa	Boa	Bom
Boa	Boa	Pouco Capacitivo
Boa	Boa	Capacitivo
Boa	Alta	Indutivo
Boa	Alta	Pouco Indutivo
Boa	Alta	Bom
Boa	Alta	Pouco Capacitivo
Boa	Alta	Capacitivo
Alta	Baixa	Indutivo
Alta	Baixa	Pouco Indutivo
Alta	Baixa	Bom
Alta	Baixa	Pouco Capacitivo
Alta	Baixa	Capacitivo
Alta	Boa	Indutivo
Alta	Boa	Pouco Indutivo
Alta	Boa	Bom
Alta	Boa	Pouco Capacitivo
Alta	Boa	Capacitivo
Alta	Alta	Indutivo
Alta	Alta	Pouco Indutivo
Alta	Alta	Bom
Alta	Alta	Pouco Capacitivo
Alta	Alta	Capacitivo

De todos os 60 estados possíveis foram considerados 25 estados com maior probabilidade de ocorrerem na prática. A Tabela IV-2 mostra todos estes eventos.

Tabela IV-2 - Estados Considerados

Adrianópolis 138 kV	Jacarepaguá 138 kV	Síncronos de Grajaú
Baixa	Baixa	Pouco capacitivo
Baixa	Baixa	Bom

Baixa	Boa	Bom
Baixa	Boa	Pouco capacitivo
Baixa	Boa	Pouco indutivo
Pouco Baixa	Baixa	Bom
Pouco Baixa	Baixa	Pouco capacitivo
Pouco Baixa	Alta	Pouco indutivo
Pouco Baixa	Boa	Pouco indutivo
Pouco Baixa	Boa	Bom
Pouco Baixa	Boa	Pouco capacitivo
Pouco Baixa	Boa	Capacitivo
Boa	Baixa	Bom
Boa	Baixa	Pouco capacitivo
Boa	Boa	Pouco indutivo
Boa	Boa	Boa
Boa	Alta	Indutivo
Boa	Alta	Pouco indutivo
Boa	Alta	Boa
Alta	Baixa	Boa
Alta	Boa	Pouco indutivo
Alta	Boa	Boa
Alta	Alta	Indutivo
Alta	Alta	Pouco indutivo
Alta	Alta	Boa

IV.2 Determinação do Conjunto de Ações

O conjunto de ações a é também determinado através da combinação das possíveis ações de controle, isto é, da combinação do número de funções de pertinência das variáveis de controle.

Desta forma, considerando que todas as três variáveis de controle, Marimbondo_500 kV, Furnas_345 kV e Angra_500 kV, têm cada uma 5 funções de pertinência, existem 125 ações possíveis para cada estado.

Da mesma forma como ocorrido na determinação do conjunto de estados, a dimensionalidade é muito reduzida através do conhecimento prévio do sistema. Situações de tensões baixas na Área Rio, por exemplo, não podem ter como ações, redução das tensões de controle.

O resultado da análise estabeleceu um conjunto de 8 ações para cada estado do sistema; este resultado está demonstrado na Tabela IV-3.

Apesar de parecer uma redução drástica no número de ações, isto é justificado pelo fato de as ações serem invertidas, isto é, além da ação MANTER, temos duas ações do tipo AUMENTAR e duas do tipo DIMINUIR.

Desta forma, situações de tensões baixas na Área Rio sugerem ações de manutenção ou elevação apenas, sendo o inverso também verdadeiro.

Sendo assim, é possível cobrir as principais ações possíveis com apenas oito ações para cada estado.

Os estados-objetivo estão sombreados na Tabela IV-3 e, naturalmente, para estes dois estados, todos os SIFs tem a ação de MANTER.

Tabela IV-3 - Ações Consideradas

Adrianópolis 138 kV	Jacarepaguá 138 kV	Síncronos de Grajaú	Marimbondo 500 kV	Furnas 345 kV	Angra 500 kV
Baixa	Baixa	Pouco capacitivo	Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Aumentar
			Aumentar pouco	Aumentar	Aumentar pouco
			Aumentar pouco	Aumentar	Aumentar
			Aumentar	Aumentar pouco	Aumentar pouco
			Aumentar	Aumentar pouco	Aumentar
			Aumentar	Aumentar	Aumentar pouco
			Aumentar	Aumentar	Aumentar
Baixa	Baixa	Bom	Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Aumentar
			Aumentar pouco	Aumentar	Aumentar pouco
			Aumentar pouco	Aumentar	Aumentar
			Aumentar	Aumentar pouco	Aumentar pouco
			Aumentar	Aumentar pouco	Aumentar
			Aumentar	Aumentar	Aumentar pouco

			Aumentar	Aumentar	Aumentar
Baixa	Boa	Bom	Aumentar pouco	Manter	Manter
			Aumentar pouco	Manter	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Manter
			Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar	Manter	Manter
			Aumentar	Manter	Aumentar pouco
			Aumentar	Aumentar pouco	Manter
			Aumentar	Aumentar pouco	Aumentar pouco
Baixa	Boa	Pouco capacitivo	Aumentar pouco	Manter	Aumentar pouco
			Aumentar pouco	Manter	Aumentar
			Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Aumentar
			Aumentar	Manter	Aumentar pouco
			Aumentar	Manter	Aumentar
			Aumentar	Aumentar pouco	Aumentar pouco
			Aumentar	Aumentar pouco	Aumentar
Baixa	Boa	Pouco indutivo	Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Manter
			Aumentar pouco	Aumentar	Aumentar pouco
			Aumentar pouco	Aumentar	Manter
			Aumentar	Aumentar pouco	Aumentar pouco
			Aumentar	Aumentar pouco	Manter
			Aumentar	Aumentar	Aumentar pouco
			Aumentar	Aumentar	Manter
Pouco Baixa	Baixa	Bom	Manter	Manter	Aumentar pouco
			Manter	Aumentar	Manter

				pouco	
			Manter	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Manter	Manter
			Aumentar pouco	Manter	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Manter
			Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Aumentar	Aumentar pouco
Pouco Baixa	Baixa	Pouco capacitivo	Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Aumentar
			Aumentar pouco	Aumentar	Aumentar pouco
			Aumentar pouco	Aumentar	Aumentar
			Aumentar	Aumentar pouco	Aumentar pouco
			Aumentar	Aumentar pouco	Aumentar
			Aumentar	Aumentar	Aumentar pouco
			Aumentar	Aumentar	Aumentar
Pouco Baixa	Boa	Pouco indutivo	Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Aumentar
			Aumentar pouco	Aumentar	Aumentar pouco
			Aumentar pouco	Aumentar	Aumentar
			Aumentar	Aumentar pouco	Aumentar pouco
			Aumentar	Aumentar pouco	Aumentar
			Aumentar	Aumentar	Aumentar pouco
			Aumentar	Aumentar	Aumentar
Pouco Baixa	Boa	Pouco indutivo	Reduzir pouco	Manter	Reduzir pouco
			Reduzir pouco	Manter	Manter
			Reduzir pouco	Aumentar pouco	Reduzir pouco

			Reduzir pouco	Aumentar pouco	Manter
			Manter	Manter	Reduzir pouco
			Manter	Aumentar pouco	Manter
			Manter	Aumentar pouco	Reduzir pouco
			Reduzir	Aumentar pouco	Manter
Pouco Baixa	Boa	Bom	Manter	Reduzir pouco	Aumentar pouco
			Manter	Reduzir pouco	Aumentar
			Manter	Manter	Aumentar pouco
			Manter	Manter	Aumentar
			Aumentar pouco	Reduzir pouco	Aumentar pouco
			Aumentar pouco	Reduzir pouco	Aumentar
			Aumentar pouco	Manter	Aumentar pouco
			Aumentar pouco	Manter	Aumentar
Pouco Baixa	Boa	Pouco capacitivo	Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Aumentar
			Aumentar pouco	Aumentar	Aumentar pouco
			Aumentar pouco	Aumentar	Aumentar
			Aumentar	Aumentar pouco	Aumentar pouco
			Aumentar	Aumentar pouco	Aumentar
			Aumentar	Aumentar	Aumentar pouco
			Aumentar	Aumentar	Aumentar
Pouco Baixa	Boa	Capacitivo	Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Aumentar
			Aumentar pouco	Aumentar	Aumentar pouco
			Aumentar pouco	Aumentar	Aumentar
			Aumentar	Aumentar	Aumentar

				pouco	pouco
			Aumentar	Aumentar pouco	Aumentar
			Aumentar	Aumentar	Aumentar pouco
			Aumentar	Aumentar	Aumentar
Boa	Baixa	Bom	Reduzir pouco	Aumentar pouco	Reduzir pouco
			Reduzir pouco	Aumentar pouco	Manter
			Reduzir pouco	Aumentar	Reduzir pouco
			Reduzir pouco	Aumentar	Manter
			Manter	Aumentar pouco	Reduzir pouco
			Manter	Aumentar pouco	Manter
			Manter	Aumentar	Reduzir pouco
			Manter	Aumentar	Manter
Boa	Baixa	Pouco capacitivo	Manter	Aumentar pouco	Reduzir pouco
			Manter	Aumentar pouco	Manter
			Manter	Aumentar	Reduzir pouco
			Manter	Aumentar	Manter
			Aumentar pouco	Aumentar pouco	Reduzir pouco
			Aumentar pouco	Aumentar pouco	Manter
			Aumentar pouco	Aumentar	Reduzir pouco
			Aumentar pouco	Aumentar	Manter
Boa	Boa	Pouco indutivo	Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter
Boa	Boa	Bom	Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter

			Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter
Boa	Alta	Indutivo	Reduzir pouco	Reduzir	Reduzir pouco
			Reduzir pouco	Reduzir	Manter
			Reduzir pouco	Reduzir pouco	Reduzir pouco
			Reduzir pouco	Reduzir pouco	Manter
			Manter	Reduzir	Reduzir pouco
			Manter	Reduzir	Manter
			Manter	Reduzir pouco	Reduzir pouco
			Manter	Reduzir pouco	Manter
Boa	Alta	Pouco indutivo	Manter	Reduzir	Reduzir pouco
			Manter	Reduzir	Manter
			Manter	Reduzir pouco	Reduzir pouco
			Manter	Reduzir pouco	Manter
			Aumentar pouco	Reduzir	Reduzir pouco
			Aumentar pouco	Reduzir	Manter
			Aumentar pouco	Reduzir pouco	Reduzir pouco
			Aumentar pouco	Reduzir pouco	Manter
Boa	Alta	Bom	Reduzir pouco	Reduzir	Manter
			Reduzir pouco	Reduzir	Aumentar pouco
			Reduzir pouco	Reduzir pouco	Manter
			Reduzir pouco	Reduzir pouco	Aumentar pouco
			Manter	Reduzir	Manter
			Manter	Reduzir	Aumentar pouco
			Manter	Reduzir pouco	Manter
			Manter	Reduzir pouco	Aumentar pouco
Alta	Baixa	Bom	Reduzir	Reduzir	Reduzir

			pouco	pouco	
			Reduzir pouco	Reduzir pouco	Reduzir pouco
			Reduzir pouco	Manter	Reduzir
			Reduzir pouco	Manter	Reduzir pouco
			Manter	Reduzir pouco	Reduzir
			Manter	Reduzir pouco	Reduzir pouco
			Manter	Manter	Reduzir
			Manter	Manter	Reduzir pouco
Alta	Boa	Pouco indutivo	Reduzir pouco	Manter	Reduzir
			Reduzir pouco	Manter	Reduzir pouco
			Reduzir pouco	Aumentar pouco	Reduzir
			Reduzir pouco	Aumentar pouco	Reduzir pouco
			Manter	Manter	Reduzir
			Manter	Manter	Reduzir pouco
			Manter	Aumentar pouco	Reduzir
			Manter	Aumentar pouco	Reduzir pouco
Alta	Boa	Bom	Reduzir pouco	Manter	Reduzir
			Reduzir pouco	Manter	Reduzir pouco
			Reduzir pouco	Aumentar pouco	Reduzir
			Reduzir pouco	Aumentar pouco	Reduzir pouco
			Manter	Manter	Reduzir
			Manter	Manter	Reduzir pouco
			Manter	Aumentar pouco	Reduzir
			Manter	Aumentar pouco	Reduzir pouco
Alta	Alta	Indutivo	Reduzir	Reduzir	Reduzir
			Reduzir	Reduzir	Reduzir pouco
			Reduzir	Reduzir pouco	Reduzir

			Reduzir	Reduzir pouco	Reduzir pouco
			Reduzir pouco	Reduzir	Reduzir
			Reduzir pouco	Reduzir	Reduzir pouco
			Reduzir pouco	Reduzir pouco	Reduzir
			Reduzir pouco	Reduzir pouco	Reduzir pouco
Alta	Alta	Pouco indutivo	Reduzir	Reduzir	Reduzir
			Reduzir	Reduzir	Reduzir pouco
			Reduzir	Reduzir pouco	Reduzir
			Reduzir	Reduzir pouco	Reduzir pouco
			Reduzir pouco	Reduzir	Reduzir
			Reduzir pouco	Reduzir	Reduzir pouco
			Reduzir pouco	Reduzir pouco	Reduzir
			Reduzir pouco	Reduzir pouco	Reduzir pouco
Alta	Alta	Bom	Reduzir pouco	Reduzir pouco	Reduzir
			Reduzir pouco	Reduzir pouco	Reduzir pouco
			Reduzir pouco	Manter	Reduzir
			Reduzir pouco	Manter	Reduzir pouco
			Manter	Reduzir pouco	Reduzir
			Manter	Reduzir pouco	Reduzir pouco
			Manter	Manter	Reduzir
			Manter	Manter	Reduzir pouco

Sendo assim, utilizando o conhecimento prévio do sistema, a dimensionalidade dos pares estado-ação da tabela do *Q-Learning* fica reduzida de 7500 (60 x 125) para 200 (25 x 8).

IV.3 Definição da Política de Reforços

A política de reforços estabelecida, a exemplo da política utilizada em [16], é proporcional à aproximação com a função de pertinência-objetivo, isto é, se após a ação executada, a tensão controlada se aproxima do objetivo, será recebida uma recompensa diretamente proporcional à aproximação. Da mesma forma, caso a ação resulte em um distanciamento do objetivo, esta ação receberá uma punição diretamente proporcional ao distanciamento.

Exceção à regra anterior é feita para os casos em que o deslocamento seja em torno dos valores de pertinência próximos a 1, na função de pertinência-objetivo, isto é, caso a tensão esteja com valores de pertinência próximos a 1 na função-objetivo e se desloque para um valor de pertinência menor, porém ainda de pertinência alta, esta não receberá nem punição, nem recompensa. Esta estratégia tem como objetivo evitar que pequenos deslocamentos, que ainda mantenham as variáveis próximas aos valores desejados, resultem em punições e dificultem o aprendizado.

O valor do reforço total é a soma aritmética dos reforços individuais de cada variável de controle.

A Figura IV-2 ilustra o descrito anteriormente. Na hipótese de a tensão estar em A e, após a ação, deslocar-se para B, será recebida uma recompensa proporcional ao deslocamento. Porém, na hipótese de a tensão estar na posição B e, após uma determinada ação, deslocar-se para posição C, ainda dentro dos valores de tensão BOA, esta não receberá nem punição, nem recompensa. Desta forma, ela não influenciará na soma do reforço total.




Figura IV-2 - Exemplo de Política de Reforço

Os valores de recompensa e punição têm a mesma ordem de grandeza, para evitar a ocorrência relatada em [26], onde uma punição muito grande na implementação na navegação de robôs causou uma espécie de “trauma”, dificultando o aprendizado por falta de exploração de determinadas ações que recebiam punições muito altas.

IV.4 Estratégia de Exploração

Conforme descrito anteriormente é bastante importante a estratégia de exploração para evitar mínimos locais e, ao mesmo tempo, não prejudicar o aprendizado.

A estratégia proposta é um valor intermediário entre o utilizado em [14] e [26], em que, no primeiro caso, a busca foi feita 90% das vezes através do reforço máximo e 10% por exploração aleatória, a fim de acelerar o processo de convergência. No segundo caso a relação foi de 70% para 30%.

Desta forma, a política de exploração é de 80% para busca pela máxima recompensa e 20% para busca aleatória. Isto significa dizer que será aplicada a política semelhante ao $\epsilon - Greedy$, com $\epsilon = 0.2$.

IV.5 Definição do Parâmetro γ

A definição do parâmetro γ traduz a importância relativa das escolhas mais recentes em relação as mais antigas no aprendizado, isto é, valores altos de γ valorizam as recompensas mais recentes.

Devido à característica não-estacionária do Sistema Elétrico, foi utilizado um valor alto de γ , conforme proposto em [14]. Esta estratégia tem como objetivo aumentar a velocidade de convergência e valorizar as mais recentes recompensas, em detrimento das mais antigas, recebidas em um Sistema Elétrico que já sofreu mudanças. O valor ajustado é de $\gamma = 0,9$.

IV.6 Operacionalização do Aprendizado

O sistema utilizado nas simulações para o aprendizado é um Caso Base do SIN de carga pesada de dezembro de 2005 e contém 3437 barras AC, 5019 linhas de transmissão e transformadores e 168 geradores e compensadores síncronos. A área de interesse continua sendo a Área Rio, constituída pelas Concessionárias de Serviços Públicos de Distribuição Light, Ampla, Escelsa e parte do sistema Furnas.

O Sistema estudado é mais atual e difere do sistema da Figura III-1 principalmente pelas seguintes modificações de topologia:

- Criação da LT Angra / São José 500 kV;
- Criação de LT Angra / Grajaú 500 kV;
- Criação da LT Adrianópolis / Cachoeira Paulista circuito 3.

O aprendizado é feito através de simulações utilizando o programa FASTSIM e funciona da seguinte forma:

- Após o início da simulação o sistema identifica o estado do sistema, isto é, quais as condições das tensões de Adrianópolis e Jacarepaguá

138 kV e da geração de potência reativa dos compensadores síncronos de Grajaú e escolhe uma ação a ser tomada para aquele estado. Como no início da simulação os valores da *Q-Learning* estão em zero, haverá uma escolha aleatória;

- Na próxima iteração o sistema identifica o novo estado do sistema, obtido com a ação que foi definida anteriormente, e calcula a recompensa ou punição.
- Com as informações do novo estado atingido, do estado anterior e também da recompensa recebida, a matriz *Q-Learning* é atualizada.
- O processo é contínuo até que o critério de convergência seja atingido. Como critério de convergência ficou definido que, se após 10.000 iterações, não houver mudança nos valores máximos das linhas da *Q-Learning*, o que significa dizer que não houve modificação na ação a ser tomada em cada estado, esta será considerada a política de controle ótima.

Para que o aprendizado seja contínuo e que seja possível atingir todos os 25 estados estabelecidos, foram definidos ao todo 91 impactos, 47 capacitivos e 44 indutivos, que variam de 30 a 350 Mvar e são inseridos na simulação para os seguintes casos:

- Objetivo Atingido – Caso durante a simulação seja atingido o objetivo de tensão em Adrianópolis_138 kV boa, tensão de Jacarepaguá_138 kV boa e geração de potência reativa dos compensadores síncronos de_Grajaú bom ou pouco indutivo, o programa escolhe aleatoriamente uma das 91 variações de potência reativa no sistema com o objetivo de conduzir o sistema para um estado não desejado e iniciar uma nova tentativa de controle;
- Limite superior de tensão atingido - Caso durante a simulação seja atingido algum limite superior das variáveis de controle, ou nos seus troncos de transmissão, o que indica que as tensões na Área Rio estão

baixas, um dos 47 impactos capacitivos é escolhido aleatoriamente e este impacto é executado na simulação. Neste caso, como foi atingido um limite, não haverá recebimento de recompensa.

- Limite inferior de tensão atingido - Caso durante a simulação seja atingido algum limite inferior das variáveis de controle, ou nos seus troncos de transmissão, o que indica que as tensões na Área Rio estão altas, um dos 44 impactos indutivos é escolhido aleatoriamente e este impacto é executado na simulação. Também neste caso, como foi atingido um limite, não haverá recebimento de recompensa.

A Tabela IV-4 mostra alguns dos 91 impactos inseridos durante as simulações para os casos de o estado ser o objetivo e também para os casos de limites operacionais nas variáveis de controle atingidos.

Tabela IV-4 - Exemplos dos Impactos nas Simulações

Subestação	Impacto Capacitivo	Impacto Indutivo
Adrianópolis 138 kV	300 Mvar	200 Mvar
Grajaú 138 kV	200 Mvar	250 Mvar
São José 138 kV	150 Mvar	100 Mvar
Campos 138 kV	100 Mvar	150 Mvar
Imbariê	50 Mvar	30 Mvar
Jacarepaguá 138 kV	30 Mvar	50 Mvar

O algoritmo implantado está resumidamente descrito a seguir:

Inicia FASTSIM

Inicializar $Q(s, a)$ arbitrariamente (normalmente 0)

-Repete (para cada episódio):

-Verifica estado

-Verifica existência de limite operado

-Verifica se o estado é o objetivo

- Caso haja limite operado ou o objetivo atingido:

-Inserir impacto aleatório

- Retorna para verificação do novo estado

-Repete (para cada passo episódio):

-Escolher a ação a para s utilizando a estratégia escolhida

-Executar a ação a

-Observar r, s'

$Q_{t+1}(s_t, a_t) \leftarrow (1 - \alpha) Q(s_t, a_t) + \alpha[r(s_t, a_t) + \gamma \max_{a_{t+1}} Q_{t+1}(s_{t+1}, a_{t+1})]$

$s \leftarrow s'$

-Até s ser o estado final

Depois de atingida a convergência, as regras de controle para cada estado são inseridas no controlador fuzzy e são feitas simulações para verificação do aprendizado.

É importante ressaltar que, assim como descrito na literatura, foi observado que a convergência do algoritmo de Aprendizado por Reforço é extremamente lenta, não podendo por isso, ser implantada para aprendizado em tempo real.

No nosso caso, a convergência exigida de 10.000 iterações sem modificação da tabela Q-learning, isto é, da ação escolhida para cada estado, levou 1 semana para ser atingida.

Apesar da lentidão na convergência, é importante ressaltar que, para o caso da utilização de Programação Dinâmica, considerando os 25 estados do sistema, com 8 ações para cada estado e estimando 10 estágios até o objetivo final, haveriam $(25 \times 8)^{10}$ possibilidades que necessitariam ser analisadas para determinação da política ótima de controle, o que, mesmo para o desenvolvimento atual dos computadores, seria inviável.

Porém, existem algumas propostas de abordagens heurísticas para aceleração do aprendizado [36] e uso de técnicas de aprendizado distribuído [35] que, caso demonstrem resultados positivos, podem ser implantadas neste algoritmo como trabalho futuro, com a finalidade de propor um aprendizado contínuo durante a operação do Sistema Elétrico.

Para que seja possível uma comparação da eficiência da ferramenta, inicialmente serão mostrados os resultados das simulações com uma base de regras escolhida aleatoriamente, dentre as regras possíveis da Tabela IV-3, e depois os resultados obtidos após o aprendizado.

Ao final será mostrado o alto potencial do controlador através da simulação de múltiplos eventos, inclusive com desligamentos múltiplos de linhas de transmissão e posterior religamento.

Será também simulado o controle hierárquico através da utilização do sistema especialista proposto em [41] em conjunto com o sistema contínuo utilizando as regras provenientes do Aprendizado por Reforço.

IV.7 Resultados Obtidos Antes do Aprendizado

Os resultados a seguir são provenientes de simulações com o controlador utilizando uma base de regras aleatória escolhida dentre as regras coerentes descritas na Tabela IV-3. Serão feitas simulações com variações em degrau e, posteriormente com variação também em rampa.

IV.7.1 Simulação com Variações em Degrau

Durante a simulação, são considerados os eventos descritos na Tabela IV-5. É possível observar que a estratégia da base de regras inserida é de priorização da redução de tensão em Furnas 345 kV para o caso de tensões altas em Jacarepaguá e Adrianópolis 138 kV e geração de potência reativa dos compensadores síncronos de Grajaú dentro dos valores desejados.

Tabela IV-5 - Eventos considerados

Tempo(s)	Evento
50	Inserção manual de capacitor shunt de 100 Mvar em Jacarepaguá 138 kV
300	Desligamento da LT 500kV Angra / Cachoeira Paulista.




Figura IV-3 - Tensão de Angra 500 kV




Figura IV-4 - Tensão de Furnas 345 kV




Figura IV-5 - Tensão de Jacarepaguá 138 kV




Figura IV-6 - Tensão de Adrianópolis 138 kV




Figura IV-7 - Geração dos Compensadores Síncronos de Grajaú

Analisando os resultados da simulação, podemos destacar as seguintes observações:

- Angra 500 kV (Figura IV-3) → Confirmando a priorização da usina de Furnas 345 kV, a tensão permanece alta até o desligamento da LT Angra / Cachoeira Paulista, recebendo apenas pequenos comandos de redução de tensão. Após o desligamento da LT, Angra 500 kV recebe sinal do SIF de aumento da tensão devido à redução das tensões de Adrianópolis e Jacarepaguá 138 kV. A tensão de Marimbondo 500 kV permanece todo o tempo de simulação alta, não recebendo por isso comando do SIF para elevação após o desligamento da LT Angra / Cachoeira Paulista.
- Furnas 345 kV (Figura IV-4) → No início da simulação Furnas 345 kV recebe comando para redução maior de tensão refletindo a estratégia. Após o desligamento da LT Angra / Cachoeira Paulista a tensão passa a ser elevada na mesma proporção que Angra, uma vez que as tensões na Área Rio passam a estar baixas.
- Jacarepaguá 138 kV (Figura IV-5) → A tensão no início da simulação é considerada boa, mas ultrapassa o valor máximo de operação após a inserção do banco de capacitores de 100 Mvar. Deste momento até a saída da LT Angra / Cachoeira Paulista a tensão é reduzida, mas não de forma

suficiente, refletindo a ineficiência da estratégia de priorização de Furnas 345 kV. Após o desligamento da referida LT a tensão fica baixa, permanecendo assim até o fim da simulação, refletindo também a ineficiência das pequenas elevações do SIF em Angra 500 kV e Furnas 345 kV.

- Adrianópolis 138 kV (Figura IV-6) → Conforme podemos analisar na figura, o comportamento foi bem semelhante ao da tensão de Jacarepaguá 138 kV.
- Geração dos Compensadores Síncronos de Grajaú (Figura IV-7) → O SIF não atua no sentido de variar a geração de potência reativa dos compensadores síncronos de Grajaú, uma vez que a geração já está dentro do objetivo de manter uma reserva de potência reativa girante na Área Rio.

IV.7.2 Simulação com Variações em Rampa

A próxima simulação mostra uma situação mais próxima do caso real, onde temos os mesmos eventos da Tabela IV-5, porém não há regime permanente, já que é também considerada uma rampa negativa de 40% de redução de carga reativa em toda a Área Rio, durante toda a simulação.




Figura IV-8 - Tensão de Marimbondo 500 kV




Figura IV-9 - Tensão de Furnas 345 kV




Figura IV-10 - Tensão de Jacarepaguá 138 kV




Figura IV-11 - Tensão de Adrianópolis 138 kV




Figura IV-12 - Geração dos Compensadores Síncronos de Grajaú

Com base nos gráficos desta simulação podemos destacar os seguintes aspectos:

- Marimbondo 500 kV (Figura IV-8) → A tensão de Marimbondo 500 kV é reduzida pelo SIF durante toda a simulação na tentativa de redução das tensões da área Rio que estão com valores muito altos e com a geração de potência reativa dos compensadores síncronos de Grajaú próximo dos limites operacionais. Para esta situação a tensão de Angra 500 kV não é comandada pelo SIF.
- Furnas 345 kV (Figura IV-9) → No início da simulação Furnas 345 kV não recebe comando do SIF para redução de tensão, sendo somente utilizada após 700 segundos, quando as tensões da Área Rio estão ainda altas, mas em valores menores que no início da simulação.
- Jacarepaguá 138 kV (Figura IV-10) → Após o chaveamento do banco de capacitores de 100 Mvar a tensão fica alta e a estratégia de redução através da usina de Marimbondo 500 kV não é suficiente para ajustá-la. Somente após o início de redução também na usina de Furnas 345 kV a tensão passa a ser reduzida, mesmo com a saída da carga reativa, chegando a ficar boa no final da simulação.

- Adrianópolis 138 kV (Figura IV-11) → O comportamento foi bem semelhante ao da tensão de Jacarepaguá 138 kV, porém as tensões ficam bem acima do valor limite e, por isso, as reduções em Marimbondo 500 kV e Furnas 345 kV não são suficientes para trazê-la para os valores desejados..
- Geração dos Compensadores Síncronos de Grajaú (Figura IV-12) → A geração de potência reativa está próxima ao valor mínimo desejado, só sendo observada melhoria após o início da redução de tensão pelo SIF também na usina de Furnas 345 kV .

IV.8 Resultados Obtidos Após o Aprendizado

Os resultados obtidos nas simulações anteriores demonstram que a base de regras deve ser muito bem ajustada e as estratégias de controle devem conter toda a experiência dos especialistas para que os resultados sejam bem sucedidos. Caso não seja possível adquirir este ajuste e estas estratégias através das entrevistas com os especialistas há que se buscar uma ferramenta capaz de identificar a melhor política de controle para o sistema em questão.

As regras de controle sombreadas na Tabela IV-6 são provenientes da convergência do aprendizado através do algoritmo *Q-learning*.

Tabela IV-6 - Base de Regras Aprendida

Adrianópolis 138 kV	Jacarepaguá 138 kV	Síncronos de Grajaú	Marimbondo 500 kV	Furnas 345 kV	Angra 500 kV
Baixa	Baixa	Pouco capacitivo	Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Aumentar
			Aumentar pouco	Aumentar	Aumentar pouco
			Aumentar pouco	Aumentar	Aumentar
			Aumentar	Aumentar pouco	Aumentar pouco
			Aumentar	Aumentar	Aumentar

				pouco	
			Aumentar	Aumentar	Aumentar pouco
			Aumentar	Aumentar	Aumentar
Baixa	Baixa	Boa	Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Aumentar
			Aumentar pouco	Aumentar	Aumentar pouco
			Aumentar pouco	Aumentar	Aumentar
			Aumentar	Aumentar pouco	Aumentar pouco
			Aumentar	Aumentar pouco	Aumentar
			Aumentar	Aumentar	Aumentar pouco
			Aumentar	Aumentar	Aumentar
Baixa	Boa	Boa	Aumentar pouco	Manter	Manter
			Aumentar pouco	Manter	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Manter
			Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar	Manter	Manter
			Aumentar	Manter	Aumentar pouco
			Aumentar	Aumentar pouco	Manter
			Aumentar	Aumentar pouco	Aumentar pouco
Baixa	Boa	Pouco capacitivo	Aumentar pouco	Manter	Aumentar pouco
			Aumentar pouco	Manter	Aumentar
			Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Aumentar
			Aumentar	Manter	Aumentar pouco
			Aumentar	Manter	Aumentar
			Aumentar	Aumentar pouco	Aumentar pouco
			Aumentar	Aumentar pouco	Aumentar

Baixa	Boa	Pouco indutivo	Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Manter
			Aumentar pouco	Aumentar	Aumentar pouco
			Aumentar pouco	Aumentar	Manter
			Aumentar	Aumentar pouco	Aumentar pouco
			Aumentar	Aumentar pouco	Manter
			Aumentar	Aumentar	Aumentar pouco
			Aumentar	Aumentar	Manter
Pouco Baixa	Baixa	Boa	Manter	Manter	Aumentar pouco
			Manter	Aumentar pouco	Manter
			Manter	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Manter	Manter
			Aumentar pouco	Manter	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Manter
			Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Aumentar	Aumentar pouco
Pouco Baixa	Baixa	Pouco capacitivo	Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Aumentar
			Aumentar pouco	Aumentar	Aumentar pouco
			Aumentar pouco	Aumentar	Aumentar
			Aumentar	Aumentar pouco	Aumentar pouco
			Aumentar	Aumentar pouco	Aumentar
			Aumentar	Aumentar	Aumentar pouco
			Aumentar	Aumentar	Aumentar
Pouco Baixa	Alta	Pouco indutivo	Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar	Aumentar	Aumentar

			pouco	pouco	
			Aumentar pouco	Aumentar	Aumentar pouco
			Aumentar pouco	Aumentar	Aumentar
			Aumentar	Aumentar pouco	Aumentar pouco
			Aumentar	Aumentar pouco	Aumentar
			Aumentar	Aumentar	Aumentar pouco
			Aumentar	Aumentar	Aumentar
Pouco Baixa	Boa	Pouco indutivo	Reduzir pouco	Manter	Reduzir pouco
			Reduzir pouco	Manter	Manter
			Reduzir pouco	Aumentar pouco	Reduzir pouco
			Reduzir pouco	Aumentar pouco	Manter
			Manter	Manter	Reduzir pouco
			Manter	Aumentar pouco	Manter
			Manter	Aumentar pouco	Reduzir pouco
			Reduzir	Aumentar pouco	Manter
Pouco Baixa	Boa	Boa	Manter	Reduzir pouco	Aumentar pouco
			Manter	Reduzir pouco	Aumentar
			Manter	Manter	Aumentar pouco
			Manter	Manter	Aumentar
			Aumentar pouco	Reduzir pouco	Aumentar pouco
			Aumentar pouco	Reduzir pouco	Aumentar
			Aumentar pouco	Manter	Aumentar pouco
			Aumentar pouco	Manter	Aumentar
Pouco Baixa	Boa	Pouco capacitivo	Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Aumentar
			Aumentar pouco	Aumentar	Aumentar pouco

			Aumentar pouco	Aumentar	Aumentar
			Aumentar	Aumentar pouco	Aumentar pouco
			Aumentar	Aumentar pouco	Aumentar
			Aumentar	Aumentar	Aumentar pouco
			Aumentar	Aumentar	Aumentar
Pouco Baixa	Boa	Capacitivo	Aumentar pouco	Aumentar pouco	Aumentar pouco
			Aumentar pouco	Aumentar pouco	Aumentar
			Aumentar pouco	Aumentar	Aumentar pouco
			Aumentar pouco	Aumentar	Aumentar
			Aumentar	Aumentar pouco	Aumentar pouco
			Aumentar	Aumentar pouco	Aumentar
			Aumentar	Aumentar	Aumentar pouco
			Aumentar	Aumentar	Aumentar
Boa	Baixa	Boa	Reduzir pouco	Aumentar pouco	Reduzir pouco
			Reduzir pouco	Aumentar pouco	Manter
			Reduzir pouco	Aumentar	Reduzir pouco
			Reduzir pouco	Aumentar	Manter
			Manter	Aumentar pouco	Reduzir pouco
			Manter	Aumentar pouco	Manter
			Manter	Aumentar	Reduzir pouco
			Manter	Aumentar	Manter
Boa	Baixa	Pouco capacitivo	Manter	Aumentar pouco	Reduzir pouco
			Manter	Aumentar pouco	Manter
			Manter	Aumentar	Reduzir pouco
			Manter	Aumentar	Manter
			Aumentar pouco	Aumentar pouco	Reduzir pouco
			Aumentar	Aumentar	Manter

			pouco	pouco	
			Aumentar pouco	Aumentar	Reduzir pouco
			Aumentar pouco	Aumentar	Manter
Boa	Boa	Pouco indutivo	Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter
Boa	Boa	Boa	Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter
			Manter	Manter	Manter
Boa	Alta	Indutivo	Reduzir pouco	Reduzir	Reduzir pouco
			Reduzir pouco	Reduzir	Manter
			Reduzir pouco	Reduzir pouco	Reduzir pouco
			Reduzir pouco	Reduzir pouco	Manter
			Manter	Reduzir	Reduzir pouco
			Manter	Reduzir	Manter
			Manter	Reduzir pouco	Reduzir pouco
Boa	Alta	Pouco indutivo	Manter	Reduzir	Reduzir pouco
			Manter	Reduzir	Manter
			Manter	Reduzir pouco	Reduzir pouco
			Manter	Reduzir pouco	Manter
			Aumentar pouco	Reduzir	Reduzir pouco
			Aumentar pouco	Reduzir	Manter
			Aumentar pouco	Reduzir pouco	Reduzir pouco

			Aumentar pouco	Reduzir pouco	Manter
Boa	Alta	Boa	Reduzir pouco	Reduzir	Manter
			Reduzir pouco	Reduzir	Aumentar pouco
			Reduzir pouco	Reduzir pouco	Manter
			Reduzir pouco	Reduzir pouco	Aumentar pouco
			Manter	Reduzir	Manter
			Manter	Reduzir	Aumentar pouco
			Manter	Reduzir pouco	Manter
			Manter	Reduzir pouco	Aumentar pouco
Alta	Baixa	Boa	Reduzir pouco	Reduzir pouco	Reduzir
			Reduzir pouco	Reduzir pouco	Reduzir pouco
			Reduzir pouco	Manter	Reduzir
			Reduzir pouco	Manter	Reduzir pouco
			Manter	Reduzir pouco	Reduzir
			Manter	Reduzir pouco	Reduzir pouco
			Manter	Manter	Reduzir
			Manter	Manter	Reduzir pouco
Alta	Boa	Pouco indutivo	Reduzir pouco	Manter	Reduzir
			Reduzir pouco	Manter	Reduzir pouco
			Reduzir pouco	Aumentar pouco	Reduzir
			Reduzir pouco	Aumentar pouco	Reduzir pouco
			Manter	Manter	Reduzir
			Manter	Manter	Reduzir pouco
			Manter	Aumentar pouco	Reduzir
			Manter	Aumentar pouco	Reduzir pouco
Alta	Boa	Boa	Reduzir pouco	Manter	Reduzir

			Reduzir pouco	Manter	Reduzir pouco
			Reduzir pouco	Aumentar pouco	Reduzir
			Reduzir pouco	Aumentar pouco	Reduzir pouco
			Manter	Manter	Reduzir
			Manter	Manter	Reduzir pouco
			Manter	Aumentar pouco	Reduzir
			Manter	Aumentar pouco	Reduzir pouco
Alta	Alta	Indutivo	Reduzir	Reduzir	Reduzir
			Reduzir	Reduzir	Reduzir pouco
			Reduzir	Reduzir pouco	Reduzir
			Reduzir	Reduzir pouco	Reduzir pouco
			Reduzir pouco	Reduzir	Reduzir
			Reduzir pouco	Reduzir	Reduzir pouco
			Reduzir pouco	Reduzir pouco	Reduzir
			Reduzir pouco	Reduzir pouco	Reduzir pouco
Alta	Alta	Pouco indutivo	Reduzir	Reduzir	Reduzir
			Reduzir	Reduzir	Reduzir pouco
			Reduzir	Reduzir pouco	Reduzir
			Reduzir	Reduzir pouco	Reduzir pouco
			Reduzir pouco	Reduzir	Reduzir
			Reduzir pouco	Reduzir	Reduzir pouco
			Reduzir pouco	Reduzir pouco	Reduzir
			Reduzir pouco	Reduzir pouco	Reduzir pouco
Alta	Alta	Boa	Reduzir pouco	Reduzir pouco	Reduzir
			Reduzir pouco	Reduzir pouco	Reduzir pouco
			Reduzir pouco	Manter	Reduzir

			Reduzir pouco	Manter	Reduzir pouco
			Manter	Reduzir pouco	Reduzir
			Manter	Reduzir pouco	Reduzir pouco
			Manter	Manter	Reduzir
			Manter	Manter	Reduzir pouco

IV.8.1 Simulação com Variações em Degrau

Durante a simulação, são considerados os mesmos eventos descritos na Tabela IV-5. Porém, a base de regras é a política de controle proveniente do algoritmo *Q-Learning*.




Figura IV-13 - Tensão de Angra 500 kV




Figura IV-14 - Tensão de Furnas 345 kV




Figura IV-15 - Tensão de Jacarepaguá 138 kV




Figura IV-16 - Tensão de Adrianópolis 138 kV




Figura IV-17 - Geração dos Compensadores Síncronos de Grajaú

Analisando os resultados da simulação, podemos destacar as seguintes observações:

- Angra 500 kV (Figura IV-13) → A tensão de Angra 500 kV recebe comando do SIF para redução, com o objetivo de trazer a tensão de Adrianópolis 138 kV para os valores desejados. Após o alcance dos objetivos ocorre um período de regime permanente que é quebrado pelo

desligamento da LT Angra / Cachoeira Paulista, quando então a tensão de Angra 500 kV é elevada pelo SIF, de forma a corrigir as tensões da Área Rio que estão baixas.

- Furnas 345 kV (Figura IV-14)→ A tensão de Furnas 345 kV tem o comportamento semelhante a tensão de Angra 500. Porém, para redução da tensão de Adrianópolis 138 kV, as maiores reduções do SIF são feitas em Angra 500 kV e o inverso ocorre quando ambas as tensões da área Rio estão baixas.
- Jacarepaguá 138 kV (Figura IV-15) → A tensão de Jacarepaguá 138 kV ultrapassa o seu valor máximo após a inserção do banco de capacitores de 100 Mvar aos 50s, sendo corrigida pela ação eficiente do SIF. Após o período de regime permanente o desligamento da LT Angra / Cachoeira Paulista aos 300s faz com que a tensão de Jacarepaguá 138 kV fique baixa, sendo novamente corrigida eficientemente pelo SIF.
- Adrianópolis 138 kV (Figura IV-16) → A tensão de Adrianópolis 138 kV está alta desde o início da simulação, situação agravada pelo chaveamento do banco de capacitores de 100 Mvar em Jacarepaguá. Porém, a estratégia de controle inserida no SIF é capaz de corrigir a tensão, mesmo após o desligamento da LT Angra / Cachoeira Paulista.
- Geração dos Compensadores Síncronos de Grajaú (Figura IV-17) → A geração de potência reativa dos compensadores síncronos de Grajaú permanece durante toda a simulação dentro da faixa de operação desejada, mesmo depois do desligamento da LT Angra/ Cachoeira Paulista.

IV.8.2 Simulação com Variações em Rampa

Nesta simulação há uma redução de carga em rampa de 40% de potência reativa na área Rio. Os eventos considerados estão na Tabela IV-7.

Tabela IV-7 - Eventos considerados

Tempo(s)	Evento
10 a 700	Rampa de redução de carga de 40% de potência reativa na Área Rio
50	Inserção manual de capacitor shunt de 100 Mvar em Jacarepaguá 138 kV
300	Desligamento da LT 500kV Angra / Cachoeira Paulista.




Figura IV-18 - Tensão de Angra 500 kV




Figura IV-19 - Tensão de Furnas 345 kV




Figura IV-20 - Tensão de Jacarepaguá 138 kV




Figura IV-21 - Tensão de Adrianópolis 138 kV




Figura IV-22 - Geração dos Compensadores Síncronos de Grajaú

Analisando os resultados da simulação, podemos destacar as seguintes observações:

- Angra 500 kV (Figura IV-18) → No início da simulação as tensões de Adrianópolis e Jacarepaguá 138 kV estão altas e por isso há uma redução da tensão de angra 500 kV. Após o desligamento da LT Angra Cachoeira Paulista há uma pequena elevação da tensão de Angra 500 kV, que logo depois é invertida para uma redução de tensão, devido a continuidade das saídas de carga. Após a interrupção da variação de carga, que ocorre aos 700s, aproximadamente aos 800s é atingido o regime permanente.
- Furnas 345 kV (Figura IV-19) → A tensão de Furnas 345 kV é reduzida no início da simulação pelo mesmo motivo que Angra 500 kV. Porém, após o desligamento da LT Angra / Cachoeira Paulista, a tensão de Furnas passa a ser elevada e não inverte a trajetória como ocorre com Angra 500 kV. O regime permanente é atingido antes da interrupção de variação de carga no sistema. É importante observar que esta política de redução e elevação simultâneas em usinas, como ocorre com Furnas e Angra não é uma ação utilizada na prática, mas que mostrou-se bastante eficiente.
- Jacarepaguá 138 kV (Figura IV-20) → A tensão de Jacarepaguá 138 kV ultrapassa o seu valor máximo após a inserção do banco de capacitores de

100 Mvar aos 50s, sendo corrigida pela ação eficiente do SIF. Como há uma rampa de carga não ocorre o regime permanente, porém a tensão é controlada dentro dos valores desejados da mesma forma. Após o desligamento da LT Angra / Cachoeira Paulista aos 300s a tensão é elevada por estar abaixo do valor mínimo desejado. Aproximadamente aos 800s o regime permanente é atingido, após a finalização da rampa que ocorre aos 700s.

- Adrianópolis 138 kV (Figura IV-21) → A tensão de Adrianópolis 138 kV está alta no início da simulação e é corrigida eficientemente, permanecendo dentro dos valores desejados até o final da simulação. Porém, após o desligamento da LT Angra / Cachoeira Paulista a tensão sofre uma variação e fica próxima ao valor mínimo da faixa de operação desejada. Como a tensão de Jacarepaguá 138 kV está baixa após este evento, a correção desta influencia na tensão de Adrianópolis 138 kV, que sofre variação, mas dentro da faixa de operação.
- Geração dos Compensadores Síncronos de Grajaú (Figura IV-22) → A geração de potência reativa dos compensadores síncronos de Grajaú permanece durante toda a simulação dentro da faixa de operação desejada, não influenciando as regras do SIF.

IV.9 Confirmação da Eficiência do Controlador Após o Aprendizado

Os resultados obtidos com as simulações após a inserção das regras obtidas da convergência do algoritmo de Aprendizado por Reforço demonstram que a ferramenta é eficiente na descoberta de uma base de regras que conduza a uma boa política de controle.

Com o objetivo de demonstrar também que a política obtida através do algoritmo de Aprendizado por Reforço tem alta capacidade de controle para várias situações, são feitas simulações com múltiplos eventos de perda de linha

de transmissão e também de religamento de linhas de transmissão após a atuação de controle, o que se traduz em três eventos diferentes em uma mesma simulação.

Em seguida são feitas simulações utilizando também o segundo nível na hierarquia de controle, que é responsável pelo chaveamento de bancos de capacitores e reatores na Área Rio, quando são atingidos limites operacionais no SIF contínuo.

O segundo nível utilizado é o mesmo proposto em [41], com o objetivo de demonstrar que não há necessidade de modificações no sistema especialista desenvolvido naquela ocasião, sendo apenas necessária a busca por uma política de controle ótima no SIF contínuo, dado que é no controle contínuo que as não-linearidades entre o fluxo de potência e os módulos de tensão são mais significativos. Os resultados são mostrados a seguir:

IV.9.1 Simulação com Perda de Duas Linhas de Transmissão

Durante a simulação são considerados múltiplos eventos, conforme descrito na Tabela IV-8.

Tabela IV-8 - Eventos considerados

Tempo(s)	Evento
10 a 700	Rampa de redução de carga de 40% de potência reativa na Área Rio
50	Inserção manual de capacitor shunt de 100 Mvar em Jacarepaguá 138 kV
300	Desligamento da LT 500kV Angra / Cachoeira Paulista.
500	Desligamento da LT 345kV Adrianópolis / Itutinga Circuito 1.




Figura IV-23 - Tensão de Angra 500 kV




Figura IV-24 - Tensão de Furnas 345 kV




Figura IV-25 - Tensão de Jacarepaguá 138 kV

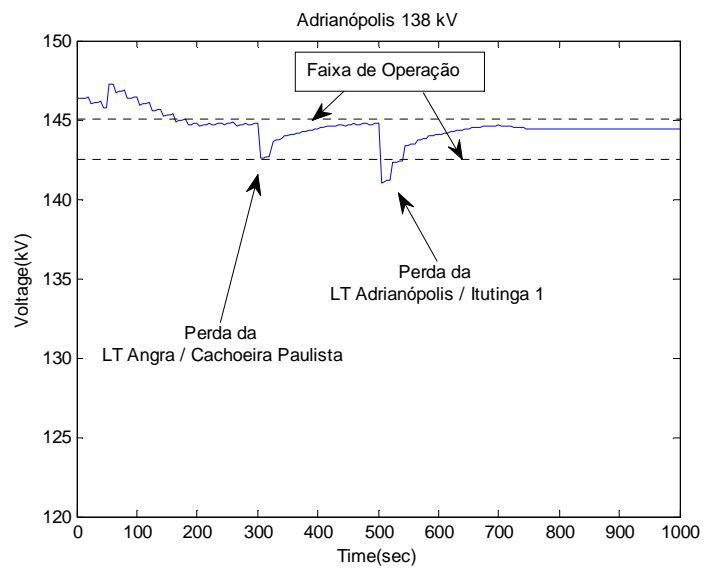


Figura IV-26 - Tensão de Adrianópolis 138 kV




Figura IV-27 - Geração dos Compensadores Síncronos de Grajaú

Analisando os resultados da simulação, podemos destacar as seguintes observações:

- Angra 500 kV (Figura IV-23) → No início da simulação, após o impacto do banco de capacitores aos 50s, as tensões de Adrianópolis e Jacarepaguá 138 kV estão altas e por isso há uma redução da tensão de Angra 500 kV. Após o desligamento da LT Angra / Cachoeira Paulista há uma pequena elevação da tensão de Angra 500 kV, que logo depois é invertida para uma redução de tensão, devido a continuidade das saídas de carga, o mesmo ocorre após o desligamento da LT Adrianópolis / Itutinga circuito 1. Aproximadamente aos 750s é atingido o regime permanente, após término da rampa de carga, que ocorre aos 700s.
- Furnas 345 kV (Figura IV-24)→ A tensão de Furnas 345 kV é reduzida no início da simulação pelo mesmo motivo que Angra 500 kV. Porém, após o desligamento da LT Angra / Cachoeira Paulista, a tensão de Furnas passa a ser elevada e a elevação aumenta após o desligamento da LT Adrianópolis / Itutinga Circuito 1. A tensão de Furnas 345 kV para de ser elevada devido ao alcance do limite máximo de operação.
- Jacarepaguá 138 kV (Figura IV-25) → A tensão de Jacarepaguá 138 kV ultrapassa o seu valor máximo após a inserção do banco de capacitores de

100 Mvar aos 50s, sendo corrigida pela ação eficiente do SIF. Como há uma rampa de carga não ocorre o regime permanente, porém a tensão é controlada dentro dos valores desejados da mesma forma. Após o desligamento da LT Angra / Cachoeira Paulista aos 300s a tensão é elevada por estar abaixo do valor mínimo desejado, o mesmo ocorrendo aos 500s com o desligamento da LT Adrianópolis / Itutinga circuito 1.

- Adrianópolis 138 kV (Figura IV-26) → A tensão de Adrianópolis 138 kV está alta no início da simulação e é corrigida eficientemente, permanecendo dentro dos valores desejados durante grande parte da simulação. Porém, após o desligamento da LT Adrianópolis / Itutinga circuito 1 a tensão fica abaixo do limite mínimo desejado, sendo também corrigida de forma eficiente.
- Geração dos Compensadores Síncronos de Grajaú (Figura IV-27) → Semelhante ao ocorrido na simulação anterior, a geração de potência reativa dos compensadores síncronos de Grajaú permanece durante toda a simulação dentro da faixa de operação desejada, não influenciando as regras do SIF.

IV.9.2 Simulação com Perda e Retorno de Linhas de Transmissão

Tabela IV-9 - Eventos considerados

Tempo(s)	Evento
10 a 700	Rampa de redução de carga de 40% de potência reativa na Área Rio
50	Inserção manual de capacitor shunt de 100 Mvar em Jacarepaguá 138 kV
300	Desligamento da LT 500kV Angra / Cachoeira Paulista.
500	Desligamento da LT 345kV Adrianópolis / Itutinga Circuito 1.
700	Religamento da LT 500kV Angra / Cachoeira Paulista.




Figura IV-28 - Tensão de Angra 500 kV




Figura IV-29 - Tensão de Furnas 345 kV

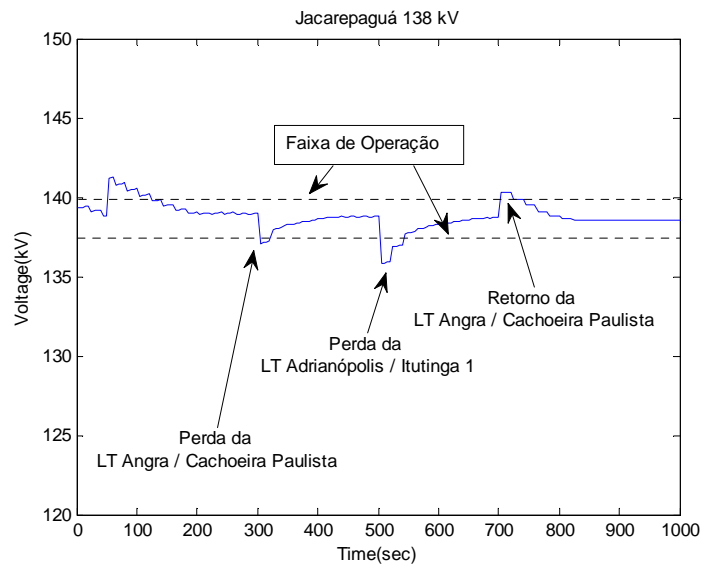


Figura IV-30 - Tensão de Jacarepaguá 138 kV




Figura IV-31 - Tensão de Adrianópolis 138 kV




Figura IV-32 - Geração dos Compensadores Síncronos de Grajaú

Analisando os resultados da simulação, podemos destacar as seguintes observações:

- O comportamento do sistema é semelhante ao da simulação anterior só apresentando modificações após o religamento da LT Angra / Cachoeira Paulista aos 700s, quando as tensões da Área Rio ultrapassam os valores superiores da faixa de operação desejada.
- Mesmo após este evento, que ocorre depois de o SIF ter corrigido as tensões da Área Rio afetadas pelos impactos das perdas das LTs Adrianópolis / Itutinga 1 e Angra / Cachoeira Paulista, a tensão é corrigida de forma rápida e eficiente.

IV.9.3 Simulações com Utilização do Segundo Nível, Contendo Variação de Carga e Perdas de Linhas de Transmissão.

As duas simulações abaixo demonstram a efetividade das regras de controle aprendidas mesmo quando é utilizado o sistema especialista no segundo nível da hierarquia de controle.

Tabela IV-10 - Eventos considerados

Tempo(s)	Evento
10 a 1000	Rampa de redução de carga de 30% de potência reativa na Área Rio
50	Inserção manual de capacitor shunt de 100 Mvar em Jacarepaguá 138 kV
300	Desligamento da LT 500kV Angra / Cachoeira Paulista.
500	Desligamento da LT 345kV Adrianópolis / Itutinga Circuito 1.




Figura IV-33 - Tensão de Marimbondo 500 kV




Figura IV-34 - Tensão de Angra 500 kV




Figura IV-35 - Tensão de Furnas 345 kV




Figura IV-36 - Tensão de Jacarepaguá 138 kV




Figura IV-37 - Tensão de Adrianópolis 138 kV

Analisando os resultados da simulação, podemos destacar as seguintes observações:

- Marimbondo 500 kV (Figura IV-33) → Durante toda a simulação há apenas pequenas variações na tensão de Marimbondo 500 kV, sendo esta apenas variada significativamente durante os distúrbios de desligamento das Linhas de Transmissão. Isto mostra que após a convergência do aprendizado, as regras de controle tem como objetivo a manutenção das

tensões de Marimbondo, de forma a explorar melhor a geração de potência reativa dos troncos de transmissão.

- Angra 500 kV (Figura IV-34) → A tensão de Angra 500 kV é bastante variada para controlar as tensões da Área Rio, demonstrando a política de controle priorizando a usina mais próxima, sem prejudicar a geração de potência reativa das linhas de Transmissão.
- Furnas 345 kV (Figura IV-35)→ A tensão de Furnas 345 kV é mais utilizada para o controle de tensão da área Rio que a tensão de Marimbondo 500 kV, recebendo mais solicitações de variação, mas menos utilizada que a tensão de Angra 500 kV, confirmando a política já explicitada.
- Jacarepaguá 138 kV (Figura IV-36) → A tensão de Jacarepaguá 138 kV ultrapassa o seu valor máximo após a inserção do banco de capacitores de 100 Mvar aos 50s, sendo corrigida pela ação eficiente do SIF. Como há uma rampa de carga não ocorre o regime permanente, porém a tensão é controlada dentro dos valores desejados da mesma forma. Após o desligamento da LT Angra / Cachoeira Paulista aos 300s a tensão vai para um valor abaixo do valor mínimo desejado. Neste momento, como há um limite de tensão no tronco de Marimbondo, o segundo nível é acionado e decide ligar um dos dois capacitores grandes disponíveis em Adrianópolis. Após o chaveamento do capacitor a tensão ultrapassa o valor máximo desejado e é controlada pelo SIF contínuo. Aos 500s, com o desligamento da LT Adrianópolis / Itutinga circuito 1, ocorre evento semelhante ao anterior e novamente o segundo nível decide por ligar outro capacitor grande de Adrianópolis. Após este evento a tensão é novamente controlada pelo SIF, mas como a tensão de Adrianópolis 138 kV está em um valor alto, a tentativa de redução desta tensão faz com que a tensão de Jacarepaguá 138 kV fique próxima do seu valor desejado mínimo, neste momento o segundo nível é acionado e é chaveado um banco de capacitores em Jacarepaguá.
- Adrianópolis 138 kV (Figura IV-37) → A tensão de Adrianópolis 138 kV está alta no início da simulação e é corrigida eficientemente, permanecendo

dentro dos valores desejados durante grande parte da simulação. Porém, após o desligamento da LT Adrianópolis / Itutinga circuito 1 a tensão fica abaixo do limite mínimo desejado, sendo também corrigida de forma eficiente.

A Geração dos Compensadores Síncronos de Grajaú permanece dentro dos valores desejados, entre 0 e -100 Mvar, durante toda a simulação.

A simulação seguinte tem o objetivo de aproximar ao máximo as situações que ocorrem na realidade, de forma a demonstrar a robustez do sistema de controle. Para tal, foram considerados em uma simulação de 5400s (1 hora e 30 minutos) os eventos: aumento de carga, redução de carga, desligamento de Linhas de Transmissão e Retorno de Linhas de Transmissão após o sistema estar novamente com suas tensões controladas. Todos os eventos estão descritos na Tabela IV-11.

Tabela IV-11 - Eventos considerados

Tempo(s)	Evento
10 a 2000	Rampa de redução de carga de 40% de potência reativa na Área Rio
2500 a 4500	Rampa de aumento de carga de 30% de potência reativa na Área Rio
300	Desligamento da LT 500kV Angra / Cachoeira Paulista.
500	Retorno da LT 500kV Angra / Cachoeira Paulista.
800	Desligamento da LT 345kV Adrianópolis / Itutinga Circuito 1.
1000	Retorno da LT 345kV Adrianópolis / Itutinga Circuito 1.
3500	Desligamento da LT 345kV Adrianópolis / Itutinga Circuito 2.
4200	Retorno da LT 345kV Adrianópolis / Itutinga Circuito 2.




Figura IV-38 - Tensão de Marimbondo 500 kV




Figura IV-39 - Tensão de Angra 500 kV




Figura IV-40 - Tensão de Furnas 345 kV




Figura IV-41 - Geração dos Compensadores Síncronos de Grajaú




Figura IV-42 - Tensão de Adrianópolis 138 kV




Figura IV-43 - Tensão de Jacarepaguá 138 kV

Analisando os resultados da simulação, podemos destacar as seguintes observações:

- Marimbondo 500 kV (Figura IV-38) → Assim como na simulação anterior a tensão de Marimbondo 500 kV é mantida sempre próximo aos seus valores máximos, de forma a explorar o “line-charging”. Cabe ressaltar

nesta simulação os dois períodos de regime permanente em que a estabilidade é rapidamente atingida após o término das variações de carga, que ocorrem aos 2000s e aos 4500s.

- Angra 500 kV (Figura IV-39) → Também com comportamento semelhante a simulação anterior a tensão de Angra 500 kV é a base da política de controle proveniente do algoritmo. Desta forma, as maiores variações para controlar as tensões da Área Rio são enviadas para esta usina.
- Furnas 345 kV (Figura IV-40) → A tensão de Furnas 345 kV é bastante solicitada a controlar a tensão da Área Rio nesta simulação. Uma observação importante é que entre o período de 1200 a 1800s as tensões de Furnas 345 kV e Marimbondo 500 kV estão sendo elevadas, enquanto a tensão de Angra 500 kV está sendo reduzida.
- Geração dos Compensadores Síncronos de Grajaú (Figura IV-41) → A geração de potência reativa dos compensadores síncronos de Grajaú permanece a maioria do tempo dentro dos valores operacionais desejados.
- Adrianópolis 138 kV (Figura IV-42) → A tensão de Adrianópolis 138 kV permanece praticamente todo o tempo dentro dos valores operacionais desejados, entre 143 e 145 kV, mesmo com as variações de carga, mostrando a eficiência das regras de controle. Apenas durante os distúrbios a tensão de Adrianópolis 138 kV sai da região de operação desejada, sendo corrigida rapidamente, quer seja pela atuação do SIF contínuo, quer seja pela atuação do SIF discreto, nos casos em que o segundo nível foi acionado por atuação de limites operacionais.
- Jacarepaguá 138 kV (Figura IV-43) → A tensão de Jacarepaguá 138 kV também permanece a maioria do tempo controlada entre os valores operacionais desejados. É importante observar que praticamente ao mesmo tempo em que cessa a variação de carga, o sistema estabiliza as tensões tanto de Adrianópolis 138 kV, quanto de Jacarepaguá 138 kV.

IV.10 Análise de Sensibilidade

De forma a enfatizar a importância da utilização de uma ferramenta capaz de identificar uma boa política de controle, na simulação seguinte são feitas modificações na base de regras que representam uma mudança na política. Na Tabela IV-12 estão as regras aprendidas pelo aprendizado por reforço e na Tabela IV-13 há modificações em três regras, que representam uma maior priorização da tensão de Furnas 345 kV em detrimento da tensão de Angra 500 kV. Os eventos considerados são os mesmos eventos da Tabela IV-11

Tabela IV-12 - Regras Aprendidas

Adrianópolis 138 kV	Jacarepaguá 138 kV	Síncronos de Grajaú	Marimbondo 500 kV	Furnas 345 kV	Angra 500 kV
Alta	Baixa	Bom	Reduzir pouco	Aumentar pouco	Reduzir pouco
Alta	Boa	Pouco Indutivo	Manter	Manter	Reduzir Pouco
Alta	Boa	Bom	Reduzir pouco	Manter	Reduzir

Tabela IV-13 - Regras Modificadas

Adrianópolis 138 kV	Jacarepaguá 138 kV	Síncronos de Grajaú	Marimbondo 500 kV	Furnas 345 kV	Angra 500 kV
Alta	Baixa	Bom	Reduzir pouco	Aumentar pouco	Manter
Alta	Boa	Pouco Indutivo	Manter	Reduzir Pouco	Manter
Alta	Boa	Bom	Manter	Reduzir Pouco	Manter




Figura IV-44 - Tensão de Marimbondo 500 kV




Figura IV-45 - Tensão de Angra 500 kV

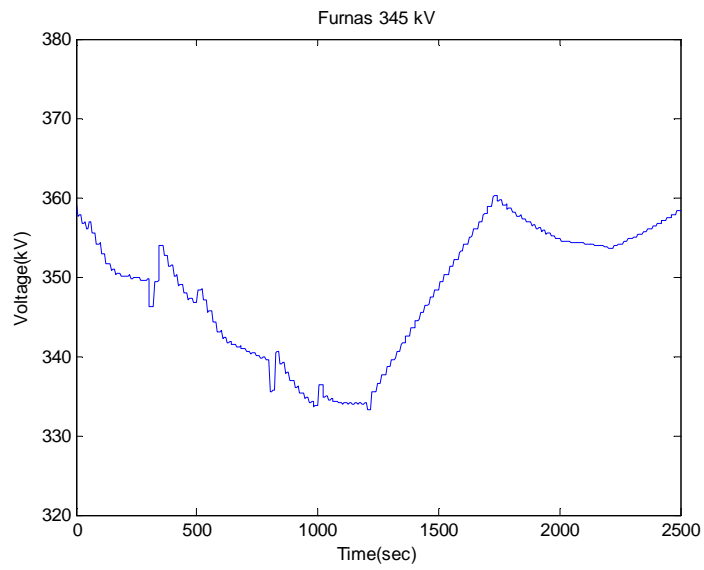


Figura IV-46 - Tensão de Furnas 345 kV

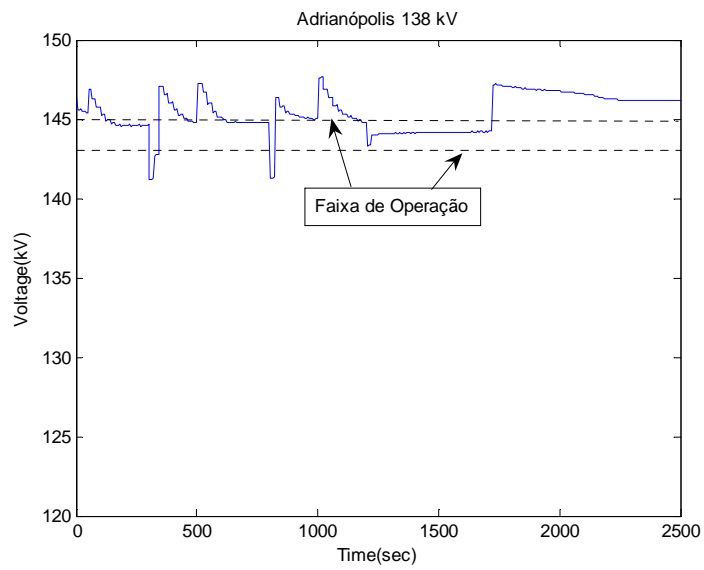


Figura IV-47 - Tensão de Adrianópolis 138 kV




Figura IV-48 - Tensão de Jacarepaguá 138 kV

Analisando os resultados da simulação, é possível observar que com esta mudança na política, além de uma maior variação nas tensões das usinas de controle, não é possível controlar as tensões da área Rio de forma eficiente.

Capítulo V

Conclusões

Neste trabalho foi apresentada uma proposta de controle regional de tensão baseado em Lógica Fuzzy, tendo como base de regras o resultado proveniente da convergência de um algoritmo de Aprendizado por Reforço.

O controle regional de tensão utilizando lógica fuzzy já havia sido proposto anteriormente. Porém, sem a inserção do Aprendizado por Reforço, o sucesso da implantação fica completamente dependente do conhecimento do especialista.

Com a utilização do algoritmo de Aprendizado por Reforço proposto nesta Tese é possível tanto confirmar a eficiência do controle implantado pelo especialista, como eventualmente melhorar a política de controle.

Foi mostrado através das simulações com base de regras com modificações de estratégias que estas são de extrema importância para o sucesso da implantação e eficiência do controlador.

Da mesma forma, ficou claro nas simulações que a base de regras extraída da convergência do algoritmo de Aprendizado por Reforço foi eficiente para controlar as tensões da Área Rio, inclusive com ações de controle não comumente utilizadas.

Além disso, com as simulações com múltiplos eventos foi possível observar a alta capacidade do controlador quando utilizada a base de regras proveniente do algoritmo de Aprendizado por Reforço.

Durante as simulações com o SIF discreto ativo foi possível observar a eficiência da hierarquia de controle e comprovar que um sistema especialista aplicado para chaveamento de equipamentos para controle de tensão é eficiente, independente da política de controle adotada para o primeiro nível.

A política adotada após a convergência do algoritmo foi a de priorizar o controle pelas tensões das usinas mais próximas da Área Rio, mantendo, sempre que possível, as tensões nos troncos de transmissão em níveis elevados, para melhor aproveitamento da geração de potência reativa das Linhas de Transmissão.

Conforme previsto desde o período de pesquisa de Tese, devido à lentidão na convergência do algoritmo de aprendizado por reforço, não é possível propor um algoritmo de aprendizado em tempo real.

Porém, existem algumas propostas de abordagens heurísticas para aceleração do aprendizado e de aprendizado distribuído que, caso demonstrem resultados positivos, podem ser implantadas neste algoritmo como trabalho futuro, com a finalidade de propor um aprendizado contínuo durante a operação do Sistema Elétrico.

Além disso, existem algumas técnicas recentes, da família dos ACD (“ Adaptive Critcs Design ”) que evitam a discretização do ambiente, atuando apenas nas funções de pertinência e também podem ser pesquisadas em trabalhos futuros.

Referências Bibliográficas

- [1] TARANTO, G.N., MARTINS, N., MARTINS, A.C.B., FALCÃO, D.M., dos SANTOS, M.G., 2000, “Benefits of Applying Secondary Voltage Control Schemes to the Brazilian System”. In: Proceedings of the IEEE/PES Summer Meeting, Seattle, USA.
- [2] TARANTO, G. N., MARTINS, N., FALCÃO, D. M., MARTINS, A. C. B., “Controle Secundário de Tensão, suas Vantagens e Limitações. Resultados Hipotéticos de sua Utilização na Área Rio,” In: *Anais do XV SNPTEE, Foz do Iguaçu*, PR, Outubro 1999.
- [3] PAUL, J. P., LÉOST, J. Y, TESSERON, J. M., “Survey of the Secondary Voltage Control in France: Present Realization and Investigations”, *IEEE Transactions on Power Systems*, Vol. 2, No. 2, pp. 505-511, May 1987.
- [4] VU, H., PRUVOT, P., LAUNAY, C., HARMAND, Y., “An Improved Voltage Control on Large-Scale Power System”, *IEEE Transactions on Power System*, Vol. 11, No. 3, pp. 1295-1303, August 1996.
- [5] LEFEBVRE, H., FRAGNIER, D., BOUSSION, J. Y., MALLET, P., BULOT, M., “Secondary Coordinated Voltage Control System: Feedback of EdF”. In: *Proceedings of the IEEE PES Summer Meeting*, Seattle, WA, July 2000.
- [6] CORSI, S., MARANNINO, P., LOSIGNORE, N., MORESCHINI, G., PICCINI, G., “Coordination between the Reactive Power Scheduling Function and the Hierarchical Voltage Control of the EHV ENEL System,” *IEEE Transactions on Power Systems*, Vol. 10, No. 2, pp. 686-694, May 1995.
- [7] CORSI, S., “The Secondary Voltage Regulation in Italy”. In: *Proceedings of the IEEE PES Summer Meeting*, Seattle, WA, July 2000.
- [8] VAN HECKE, J., JANSSENS, N., DEUSE, J., PROMEL, F., “Coordinated Voltage Control, Experience in Belgium,” *CIGRE Session, report 38-111*, Paris, September 2000.

- [9] MARQUES, A.B., TARANTO, G.N., FALCÃO, D.M., “A Knowledge-Based System for Supervision and Control of Regional Voltage Profile and Security”, 2004, IEEE Transactions on Power Systems, USA, v. 20, n. 1, p. 400-407, 2005.
- [10] TAYLOR, C. W., VENKATASUBRAMANIAN, M. V., CHEN, Y., “Wide-Area Stability and Voltage Control,” Anais do VII SEPOPE, Curitiba, PR, Maio de 2000.
- [11] FERREIRA, L.C.A., *Análise a Longo-Termo da Estabilidade de Tensão Utilizando Métodos Estáticos e um Sistema Especialista Fuzzy para Representação de Ações de Controle*. Tese de D.Sc., UNIFEI, Itajubá, MG, Brasil, 2008.
- [12] WATKINS, C., “Learning from Delayed Rewards”, PhD Thesis, University of Cambridge, England, 1989.
- [13] MITCHELL, T., “Machine Learning”. New York: McGraw Hill, 1997.
- [14] ERNST, D., GLAVIC, M., WEHENKEL, L., “Power System Stability Control: Reinforcement Learning Framework”, IEEE Transactions on Power Systems, Vol. 19, No. 1, pp. 427-435, Feb 2004.
- [15] MOHAGHEGHI, S., VENAYAGAMOORTHY, G. K., HARLEY, R. G., “Adaptive Critic Design Based Neuro-Fuzzy Controller for a Static Compensator in a Multimachine Power System”, IEEE Transactions on Power Systems, Vol. 21, No. 4, pp.1744-1754, Nov 2006.
- [16] SEO, H. S., YOUN, S. J., OH, K. W., “A Fuzzy Reinforcement Function for Intelligent Agent to Process Vague Goals”, 19th International Conference of the North American, Atlanta, GA, USA, 2000.
- [17] GLORENNEC, P. Y., JOUFFE, L., “Fuzzy Q-learning”, Proceedings of the Sixth IEEE International Conference, Spain, 1997.
- [18] LI, B. H., WU, Q. H., “Learning Coordinated Fuzzy Logic Control of Dynamic Quadrature Booster in Multimachine Power Systems”, IEE Part C-Generation, Transmission and Distribution, v. 146, n. 6, p. 577-585, 1999.

- [19] CHAN, K. H., JIANG, L., TILLOSTON, P., WU, Q. H., “Reinforcement Learning for the Control of Large-Scale Power Systems”, Proceedings of EIS2000, Paisley, UK, 2000.
- [20] KAELBLING, L. P., LITTMAN, M. L. and MOORE A. W., “Reinforcement Learning: A Survey”, Journal of Artificial Intelligence Research, v. 4, p. 237-285, 1996.
- [21] R. BELLMAN. “Dynamic Programming.”, Princeton University Press, Princeton, N.J., 1957.
- [22] A.SCHWARTZ.“A reinforcement Learning Method for Maximizing Undiscounted Rewards.” In Machine Learning: Proceedings of the Tenth International Conference, SanMateo, CA, 1993. Morgan Kaufmann.
- [23] P. TADEPALLI and D. OK. “A reinforcement learning method for optimizing undiscounted average reward.” Technical Report 94-30-01, Department of Computer Science, OregonState University, 1994.
- [24] SUTTON, R. S. “Learning to Predict by the Methods of Temporal Differences.” Machine Learning, v.3, n.1, 1988.
- [25] HARMON, M. E.,“Reinforcement Learning: A Tutorial”, Centerville,OH:Wright State University.
- [26] FARIA, G., ROMERO, R. F., “Explorando o Potencial de Algoritmos de Aprendizado com Reforço em Robôs Móveis”, IV Congresso Brasileiro de Redes Neurais, pp. 237-242, São José dos Campos, SP, BRASIL, 1999.
- [27] Internet,“www-anw.cs.umass.edu/rlr/”.
- [28] MARTINS, N. “The New Cigre Task Force on Coordinated Voltage Control in Transmission Networks, Proceedings of the IEEE PES Summer Meeting, Seattle, WA, July 2000.
- [29] CAUSARANO, W. J., FALCÃO, D. M., TARANTO, G. N., “A Fast Domain Simulation Method for Voltage Stability Assessment,” Anais do VI SEPOPE, Salvador, BA, Maio 1998.

- [30] MARTINS, N., FERRAZ, J.C.R., GOMES JR., S, QUINTÃO, P.E.M., PASSOS FILHO, J.A., “A Demonstration Example of Secondary Voltage Regulation: Dynamic Simulation and Continuation Power Flow Results”, *IEEE/PES Summer Meeting 2001*, Vancouver, Canada, July 2001.
- [31] DRIANKOV, D., HELLENDORRN, H., REINFRANK, M., “ An Introduction to Fuzzy Control ”, Springer-Verlag, 1993.
- [32] ZADEH, L. A., “ Fuzzy Sets”, In: *Proceedings of the IEEE (Information and Control)*, No. 8, pp. 338-353, 1965.
- [33] MAMDANI, E. H. “Application of fuzzy algorithms for control of simple dynamic plant” In: *Proceedings of the IEEE (Control and Science)*, No.121, pp. 298-316, 1974.
- [34] BERTSEKAS, D. P. “Dynamic Programming: Deterministic and Stochastic Models.” Pentice-Hall, Englewood Cliffs, NJ, 1987.
- [35] BIANCHI, R. A. C., COSTA, A. H. R. “Comparing Distributed Reinforcement Learning Approaches to Learn Agent Coordination” In: *Ibero-American Coinference on AI*, Berlin, 2002.
- [36] BIANCHI, R. A. C. “Uso de Heurísticas para a Aceleração do Aprendizado por Reforço” Tese de D.Sc., USP, São Paulo, SP, Brasil, 2004..
- [37] TAYLOR, C. W., *Power System Voltage Stability*. 1 ed. New York, McGraw-Hill Inc, 1994.
- [38] KUNDUR, P., *Power System Stability and Control*. 1 ed. New York, McGraw-Hill Inc, 1994.
- [39] BARBIER C., BARRET, J. P., “An Analysis of Phenomena of Voltage Collapse on Transmission System”, *Rev. Gen. Elect.*, pp. 672-690, 1980.
- [40] CAUSARANO, W. J., *Método de Simulação Rápida no Tempo para Avaliação da Estabilidade de Tensão*. Tese de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 1997.

- [41] MARQUES, A. B., *Utilização de um Sistema Hierárquico para Controle de Tensão na Área Rio Baseado em Lógica Fuzzy*. Dissertação de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 2002.
- [42] BARRET, J. P., et al., “Power System Voltage Regulation”, *Rev. Gen. Elect.*, pp. 37-38, 1980.
- [43] KUO, B. C., *Sistemas de Controle Automático*. 4 ed. Rio de Janeiro, Prentice – Hall do Brasil, 1985.
- [44] THORP, J. S., ILIC-SPONG, M., VERGHESE, M., “An Optimal Secondary Voltage – VAR Control Technique”, *Automatica*, Vol. 22, No. 2, pp. 217-221, 1986.
- [45] SILVA, R. J. G. C., SILVA, F. M. DUARTE, H. A. L., CHAPARRO, J. C. R., JUSTINO, R., “Modelagem e Ajuste do Controle Conjunto de Tensão de Itaipu 50 z e 60 Hz”, *SNPTE*, Foz do Iguaçu, PR, 1997.
- [46] SUTTON, R. S., BARTO, A. G. “Reinforcement Learning: An Introduction”, Cambridge, MA, MIT Press, 1998.

Apêndice A -Implementação dos Sistemas Fuzzy no MATLAB

A.1 Sistema Fuzzy 1

```
[System]
Name='Doutorado-fuzzy1'
Type='mamdani'
Version=2.0
NumInputs=3
NumOutputs=3
NumRules=25
AndMethod='min'
OrMethod='max'
ImpMethod='min'
AggMethod='max'
DefuzzMethod='centroid'
```

```
[Input1]
Name='ADKV'
Range=[135 150]
NumMFs=4
MF1='Low': 'zmf',[139.679365079365 142.679365079365]
MF2='NTL': 'gaussmf',[0.57 142.357142857143]
MF3='OK': 'gaussmf',[0.516 144.198412698413]
MF4='High': 'smf',[144.15873015873 146.15873015873]
```

```
[Input2]
Name='JPKV'
Range=[132 145]
NumMFs=3
MF1='Low': 'zmf',[135.403174603175 139.403174603175]
MF2='OK': 'gaussmf',[0.585 138.793650793651]
MF3='High': 'smf',[138.275132275133 142.275132275133]
```

```
[Input3]
Name='GRCS'
Range=[-300 400]
NumMFs=5
MF1='Inductive': 'zmf',[-166.52962962963 -52.7796296296296]
```

MF2='LI':'gaussmf',[15.1 -76.16]
MF3='OK':'gaussmf',[15.3 -31.86]
MF4='LC':'gaussmf',[25.4 26.6]
MF5='Capacitive':'smf',[36.09 106.6]

[Output1]

Name='MRKV'
Range=[-1 1]
NumMFs=5
MF1='Down':'trapmf',[-1.89 -1.05 -0.698 -0.365]
MF2='SD':'trimf',[-0.503 -0.312 -0.106]
MF3='Remain':'trimf',[-0.201 0 0.201]
MF4='SU':'trimf',[0.106 0.312 0.503]
MF5='Up':'trapmf',[0.365 0.698 1.01 1.82]

[Output2]

Name='FUKV'
Range=[-1 1]
NumMFs=5
MF1='Down':'trapmf',[-1.89 -1.05 -0.698 -0.365]
MF2='SD':'trimf',[-0.503 -0.312 -0.106]
MF3='Remain':'trimf',[-0.201 0 0.201]
MF4='SU':'trimf',[0.106 0.312 0.503]
MF5='Up':'trapmf',[0.365 0.698 1.01 1.82]

[Output3]

Name='ANKV'
Range=[-1 1]
NumMFs=5
MF1='Down':'trapmf',[-1.89 -1.05 -0.698 -0.365]
MF2='SD':'trimf',[-0.503 -0.312 -0.106]
MF3='Remain':'trimf',[-0.201 0 0.201]
MF4='SU':'trimf',[0.106 0.312 0.503]
MF5='Up':'trapmf',[0.365 0.698 1.01 1.82]

[Rules]

1 1 4, 4 4 4 (1) : 1
1 1 3, 4 4 4 (1) : 1
1 2 3, 4 3 3 (1) : 1
1 2 4, 4 3 4 (1) : 1
1 2 2, 4 4 4 (1) : 1
2 1 3, 3 3 4 (1) : 1
2 1 4, 4 4 4 (1) : 1
2 3 2, 4 1 4 (1) : 1
2 2 2, 2 3 2 (1) : 1
2 2 3, 3 2 4 (1) : 1
2 2 4, 4 4 4 (1) : 1
2 2 5, 4 4 4 (1) : 1
3 1 3, 2 4 2 (1) : 1
3 1 4, 3 4 2 (1) : 1

3 2 2, 3 3 3 (1) : 1
3 2 3, 3 3 3 (1) : 1
3 3 1, 2 1 2 (1) : 1
3 3 2, 3 1 2 (1) : 1
3 3 3, 2 2 4 (1) : 1
4 1 3, 2 4 1 (1) : 1
4 2 2, 2 3 1 (1) : 1
4 2 3, 2 3 1 (1) : 1
4 3 1, 1 1 1 (1) : 1
4 3 2, 1 1 1 (1) : 1
4 3 3, 2 2 1 (1) : 1

A.2 Sistema Fuzzy 2

```
[System]
Name='Doutorado-fuzzy2'
Type='mamdani'
Version=2.0
NumInputs=3
NumOutputs=3
NumRules=25
AndMethod='min'
OrMethod='max'
ImpMethod='min'
AggMethod='max'
DefuzzMethod='centroid'
```

```
[Input1]
Name='ADKV'
Range=[135 150]
NumMFs=4
MF1='Low': 'zmf', [139.679365079365 142.679365079365]
MF2='NTL': 'gaussmf', [0.57 142.357142857143]
MF3='OK': 'gaussmf', [0.516 144.198412698413]
MF4='High': 'smf', [144.15873015873 146.15873015873]
```

```
[Input2]
Name='JPKV'
Range=[132 145]
NumMFs=3
MF1='Low': 'zmf', [135.403174603175 139.403174603175]
MF2='OK': 'gaussmf', [0.585 138.793650793651]
MF3='High': 'smf', [138.275132275133 142.275132275133]
```

```
[Input3]
Name='GRCS'
Range=[-300 400]
```

NumMFs=5
MF1='Inductive': 'zmf', [-166.52962962963 -52.7796296296296]
MF2='LI': 'gaussmf', [15.1 -76.16]
MF3='OK': 'gaussmf', [15.3 -31.86]
MF4='LC': 'gaussmf', [25.4 26.6]
MF5='Capacitive': 'smf', [36.09 106.6]

[Output1]
Name='MRKV'
Range=[-1 1]
NumMFs=5
MF1='Down': 'trapmf', [-1.89 -1.05 -0.698 -0.365]
MF2='SD': 'trimf', [-0.503 -0.312 -0.106]
MF3='Remain': 'trimf', [-0.201 0 0.201]
MF4='SU': 'trimf', [0.106 0.312 0.503]
MF5='Up': 'trapmf', [0.365 0.698 1.01 1.82]

[Output2]
Name='FUKV'
Range=[-1 1]
NumMFs=5
MF1='Down': 'trapmf', [-1.89 -1.05 -0.698 -0.365]
MF2='SD': 'trimf', [-0.503 -0.312 -0.106]
MF3='Remain': 'trimf', [-0.201 0 0.201]
MF4='SU': 'trimf', [0.106 0.312 0.503]
MF5='Up': 'trapmf', [0.365 0.698 1.01 1.82]

[Output3]
Name='ANKV'
Range=[-1 1]
NumMFs=5
MF1='Down': 'trapmf', [-1.89 -1.05 -0.698 -0.365]
MF2='SD': 'trimf', [-0.503 -0.312 -0.106]
MF3='Remain': 'trimf', [-0.201 0 0.201]
MF4='SU': 'trimf', [0.106 0.312 0.503]
MF5='Up': 'trapmf', [0.365 0.698 1.01 1.82]

[Rules]
1 1 4, 4 4 5 (1) : 1
1 1 3, 4 4 5 (1) : 1
1 2 3, 4 3 4 (1) : 1
1 2 4, 4 3 5 (1) : 1
1 2 2, 4 4 3 (1) : 1
2 1 3, 3 4 3 (1) : 1
2 1 4, 4 4 3 (1) : 1
2 3 2, 4 1 5 (1) : 1
2 2 2, 2 3 3 (1) : 1
2 2 3, 3 2 5 (1) : 1
2 2 4, 4 4 5 (1) : 1
2 3 3, 3 1 5 (1) : 1

3 1 3, 2 4 3 (1) : 1
3 1 4, 3 4 3 (1) : 1
3 2 2, 3 3 3 (1) : 1
3 2 3, 3 3 3 (1) : 1
3 3 1, 2 1 3 (1) : 1
3 3 2, 3 1 3 (1) : 1
3 3 3, 2 1 4 (1) : 1
4 1 3, 2 4 2 (1) : 1
4 2 2, 2 3 2 (1) : 1
4 2 3, 2 3 2 (1) : 1
4 3 1, 1 1 2 (1) : 1
4 3 2, 1 1 2 (1) : 1
4 3 3, 2 2 2 (1) : 1

A.3 Sistema Fuzzy 3

[System]

Name='Doutorado-fuzzy3'

Type='mamdani'

Version=2.0

NumInputs=3

NumOutputs=3

NumRules=25

AndMethod='min'

OrMethod='max'

ImpMethod='min'

AggMethod='max'

DefuzzMethod='centroid'

[Input1]

Name='ADKV'

Range=[135 150]

NumMFs=4

MF1='Low': 'zmf', [139.679365079365 142.679365079365]

MF2='NTL': 'gaussmf', [0.57 142.357142857143]

MF3='OK': 'gaussmf', [0.516 144.198412698413]

MF4='High': 'smf', [144.15873015873 146.15873015873]

[Input2]

Name='JPKV'

Range=[132 145]

NumMFs=3

MF1='Low': 'zmf', [135.403174603175 139.403174603175]

MF2='OK': 'gaussmf', [0.585 138.793650793651]

MF3='High': 'smf', [138.275132275133 142.275132275133]

[Input3]
Name='GRCS'
Range=[-300 400]
NumMFs=5
MF1='Inductive':'zmf',[-166.52962962963 -52.7796296296296]
MF2='LI':'gaussmf',[15.1 -76.16]
MF3='OK':'gaussmf',[15.3 -31.86]
MF4='LC':'gaussmf',[25.4 26.6]
MF5='Capacitive':'smf',[36.09 106.6]

[Output1]
Name='MRKV'
Range=[-1 1]
NumMFs=5
MF1='Down':'trapmf',[-1.89 -1.05 -0.698 -0.365]
MF2='SD':'trimf',[-0.503 -0.312 -0.106]
MF3='Remain':'trimf',[-0.201 0 0.201]
MF4='SU':'trimf',[0.106 0.312 0.503]
MF5='Up':'trapmf',[0.365 0.698 1.01 1.82]

[Output2]
Name='FUKV'
Range=[-1 1]
NumMFs=5
MF1='Down':'trapmf',[-1.89 -1.05 -0.698 -0.365]
MF2='SD':'trimf',[-0.503 -0.312 -0.106]
MF3='Remain':'trimf',[-0.201 0 0.201]
MF4='SU':'trimf',[0.106 0.312 0.503]
MF5='Up':'trapmf',[0.365 0.698 1.01 1.82]

[Output3]
Name='ANKV'
Range=[-1 1]
NumMFs=5
MF1='Down':'trapmf',[-1.89 -1.05 -0.698 -0.365]
MF2='SD':'trimf',[-0.503 -0.312 -0.106]
MF3='Remain':'trimf',[-0.201 0 0.201]
MF4='SU':'trimf',[0.106 0.312 0.503]
MF5='Up':'trapmf',[0.365 0.698 1.01 1.82]

[Rules]
1 1 4, 4 5 4 (1) : 1
1 1 3, 4 5 4 (1) : 1
1 2 3, 4 4 3 (1) : 1
1 2 4, 4 4 4 (1) : 1
1 2 2, 4 5 4 (1) : 1
2 1 3, 3 4 4 (1) : 1
2 1 4, 4 5 4 (1) : 1
2 3 2, 4 2 4 (1) : 1

2 2 2, 2 4 2 (1) : 1
 2 2 3, 3 3 4 (1) : 1
 2 2 4, 4 5 4 (1) : 1
 2 3 3, 3 2 4 (1) : 1
 3 1 3, 2 5 2 (1) : 1
 3 1 4, 3 5 2 (1) : 1
 3 2 2, 3 3 3 (1) : 1
 3 2 3, 3 3 3 (1) : 1
 3 3 1, 2 2 2 (1) : 1
 3 3 2, 3 2 2 (1) : 1
 3 3 3, 2 2 3 (1) : 1
 4 1 3, 2 5 1 (1) : 1
 4 2 2, 2 4 1 (1) : 1
 4 2 3, 2 4 1 (1) : 1
 4 3 1, 1 2 1 (1) : 1
 4 3 2, 1 2 1 (1) : 1
 4 3 3, 2 3 1 (1) : 1

A.4 Sistema Fuzzy 4

[System]

Name='Doutorado-fuzzy4'

Type='mamdani'

Version=2.0

NumInputs=3

NumOutputs=3

NumRules=25

AndMethod='min'

OrMethod='max'

ImpMethod='min'

AggMethod='max'

DefuzzMethod='centroid'

[Input1]

Name='ADKV'

Range=[135 150]

NumMFs=4

MF1='Low': 'zmf', [139.679365079365 142.679365079365]

MF2='NTL': 'gaussmf', [0.57 142.357142857143]

MF3='OK': 'gaussmf', [0.516 144.198412698413]

MF4='High': 'smf', [144.15873015873 146.15873015873]

[Input2]

Name='JPKV'

Range=[132 145]

NumMFs=3
MF1='Low': 'zmf', [135.403174603175 139.403174603175]
MF2='OK': 'gaussmf', [0.585 138.793650793651]
MF3='High': 'smf', [138.275132275133 142.275132275133]

[Input3]
Name='GRCS'
Range=[-300 400]
NumMFs=5
MF1='Inductive': 'zmf', [-166.52962962963 -52.7796296296296]
MF2='LI': 'gaussmf', [15.1 -76.16]
MF3='OK': 'gaussmf', [15.3 -31.86]
MF4='LC': 'gaussmf', [25.4 26.6]
MF5='Capacitive': 'smf', [36.09 106.6]

[Output1]
Name='MRKV'
Range=[-1 1]
NumMFs=5
MF1='Down': 'trapmf', [-1.89 -1.05 -0.698 -0.365]
MF2='SD': 'trimf', [-0.503 -0.312 -0.106]
MF3='Remain': 'trimf', [-0.201 0 0.201]
MF4='SU': 'trimf', [0.106 0.312 0.503]
MF5='Up': 'trapmf', [0.365 0.698 1.01 1.82]

[Output2]
Name='FUKV'
Range=[-1 1]
NumMFs=5
MF1='Down': 'trapmf', [-1.89 -1.05 -0.698 -0.365]
MF2='SD': 'trimf', [-0.503 -0.312 -0.106]
MF3='Remain': 'trimf', [-0.201 0 0.201]
MF4='SU': 'trimf', [0.106 0.312 0.503]
MF5='Up': 'trapmf', [0.365 0.698 1.01 1.82]

[Output3]
Name='ANKV'
Range=[-1 1]
NumMFs=5
MF1='Down': 'trapmf', [-1.89 -1.05 -0.698 -0.365]
MF2='SD': 'trimf', [-0.503 -0.312 -0.106]
MF3='Remain': 'trimf', [-0.201 0 0.201]
MF4='SU': 'trimf', [0.106 0.312 0.503]
MF5='Up': 'trapmf', [0.365 0.698 1.01 1.82]

[Rules]
1 1 4, 4 5 5 (1) : 1
1 1 3, 4 5 5 (1) : 1
1 2 3, 4 4 4 (1) : 1
1 2 4, 4 4 5 (1) : 1
1 2 2, 4 5 3 (1) : 1

2 1 3, 4 3 3 (1) : 1
 2 1 4, 4 5 5 (1) : 1
 2 3 2, 4 2 5 (1) : 1
 2 2 2, 2 4 3 (1) : 1
 2 2 3, 3 3 5 (1) : 1
 2 2 4, 4 5 5 (1) : 1
 2 3 3, 3 2 5 (1) : 1
 3 1 3, 2 5 3 (1) : 1
 3 1 4, 3 5 3 (1) : 1
 3 2 2, 3 3 3 (1) : 1
 3 2 3, 3 3 3 (1) : 1
 3 3 1, 2 2 3 (1) : 1
 3 3 2, 3 2 3 (1) : 1
 3 3 3, 2 2 4 (1) : 1
 4 1 3, 2 5 2 (1) : 1
 4 2 2, 2 4 2 (1) : 1
 4 2 3, 2 4 2 (1) : 1
 4 3 1, 1 2 2 (1) : 1
 4 3 2, 1 2 2 (1) : 1
 4 3 3, 2 3 2 (1) : 1

A.5 Sistema Fuzzy 5

```

[System]
Name='Doutorado-fuzzy5'
Type='mamdani'
Version=2.0
NumInputs=3
NumOutputs=3
NumRules=25
AndMethod='min'
OrMethod='max'
ImpMethod='min'
AggMethod='max'
DefuzzMethod='centroid'

[Input1]
Name='ADKV'
Range=[135 150]
NumMFs=4
MF1='Low': 'zmf', [139.679365079365 142.679365079365]
MF2='NTL': 'gaussmf', [0.57 142.357142857143]
MF3='OK': 'gaussmf', [0.516 144.198412698413]
MF4='High': 'smf', [144.15873015873 146.15873015873]
  
```

[Input2]
Name='JPKV'
Range=[132 145]
NumMFs=3
MF1='Low': 'zmf', [135.403174603175 139.403174603175]
MF2='OK': 'gaussmf', [0.585 138.793650793651]
MF3='High': 'smf', [138.275132275133 142.275132275133]

[Input3]
Name='GRCS'
Range=[-300 400]
NumMFs=5
MF1='Inductive': 'zmf', [-166.52962962963 -52.7796296296296]
MF2='LI': 'gaussmf', [15.1 -76.16]
MF3='OK': 'gaussmf', [15.3 -31.86]
MF4='LC': 'gaussmf', [25.4 26.6]
MF5='Capacitive': 'smf', [36.09 106.6]

[Output1]
Name='MRKV'
Range=[-1 1]
NumMFs=5
MF1='Down': 'trapmf', [-1.89 -1.05 -0.698 -0.365]
MF2='SD': 'trimf', [-0.503 -0.312 -0.106]
MF3='Remain': 'trimf', [-0.201 0 0.201]
MF4='SU': 'trimf', [0.106 0.312 0.503]
MF5='Up': 'trapmf', [0.365 0.698 1.01 1.82]

[Output2]
Name='FUKV'
Range=[-1 1]
NumMFs=5
MF1='Down': 'trapmf', [-1.89 -1.05 -0.698 -0.365]
MF2='SD': 'trimf', [-0.503 -0.312 -0.106]
MF3='Remain': 'trimf', [-0.201 0 0.201]
MF4='SU': 'trimf', [0.106 0.312 0.503]
MF5='Up': 'trapmf', [0.365 0.698 1.01 1.82]

[Output3]
Name='ANKV'
Range=[-1 1]
NumMFs=5
MF1='Down': 'trapmf', [-1.89 -1.05 -0.698 -0.365]
MF2='SD': 'trimf', [-0.503 -0.312 -0.106]
MF3='Remain': 'trimf', [-0.201 0 0.201]
MF4='SU': 'trimf', [0.106 0.312 0.503]
MF5='Up': 'trapmf', [0.365 0.698 1.01 1.82]

[Rules]
1 1 4, 5 4 4 (1) : 1
1 1 3, 5 4 4 (1) : 1

1 2 3, 5 3 3 (1) : 1
 1 2 4, 5 3 4 (1) : 1
 1 2 2, 5 4 4 (1) : 1
 2 1 3, 4 3 4 (1) : 1
 2 1 4, 5 4 4 (1) : 1
 2 3 2, 5 1 4 (1) : 1
 2 2 2, 3 3 4 (1) : 1
 2 2 3, 4 2 4 (1) : 1
 2 2 4, 5 4 4 (1) : 1
 2 3 3, 4 1 4 (1) : 1
 3 1 3, 3 4 2 (1) : 1
 3 1 4, 4 4 2 (1) : 1
 3 2 2, 3 3 3 (1) : 1
 3 2 3, 3 3 3 (1) : 1
 3 3 1, 3 1 2 (1) : 1
 3 3 2, 4 1 2 (1) : 1
 3 3 3, 3 1 3 (1) : 1
 4 1 3, 3 4 1 (1) : 1
 4 2 2, 3 3 1 (1) : 1
 4 2 3, 3 3 1 (1) : 1
 4 3 1, 2 1 1 (1) : 1
 4 3 2, 2 1 1 (1) : 1
 4 3 3, 3 2 1 (1) : 1

A.6 Sistema Fuzzy 6

```

[System]
Name='Doutorado-fuzzy6'
Type='mamdani'
Version=2.0
NumInputs=3
NumOutputs=3
NumRules=25
AndMethod='min'
OrMethod='max'
ImpMethod='min'
AggMethod='max'
DefuzzMethod='centroid'
  
```

```

[Input1]
Name='ADKV'
Range=[135 150]
NumMFs=4
MF1='Low': 'zmf', [139.679365079365 142.679365079365]
MF2='NTL': 'gaussmf', [0.57 142.357142857143]
  
```

MF3='OK':'gaussmf',[0.516 144.198412698413]
MF4='High':'smf',[144.15873015873 146.15873015873]

[Input2]

Name='JPKV'

Range=[132 145]

NumMFs=3

MF1='Low':'zmf',[135.403174603175 139.403174603175]

MF2='OK':'gaussmf',[0.585 138.793650793651]

MF3='High':'smf',[138.275132275133 142.275132275133]

[Input3]

Name='GRCS'

Range=[-300 400]

NumMFs=5

MF1='Inductive':'zmf',[-166.52962962963 -52.7796296296296]

MF2='LI':'gaussmf',[15.1 -76.16]

MF3='OK':'gaussmf',[15.3 -31.86]

MF4='LC':'gaussmf',[25.4 26.6]

MF5='Capacitive':'smf',[36.09 106.6]

[Output1]

Name='MRKV'

Range=[-1 1]

NumMFs=5

MF1='Down':'trapmf',[-1.89 -1.05 -0.698 -0.365]

MF2='SD':'trimf',[-0.503 -0.312 -0.106]

MF3='Remain':'trimf',[-0.201 0 0.201]

MF4='SU':'trimf',[0.106 0.312 0.503]

MF5='Up':'trapmf',[0.365 0.698 1.01 1.82]

[Output2]

Name='FUKV'

Range=[-1 1]

NumMFs=5

MF1='Down':'trapmf',[-1.89 -1.05 -0.698 -0.365]

MF2='SD':'trimf',[-0.503 -0.312 -0.106]

MF3='Remain':'trimf',[-0.201 0 0.201]

MF4='SU':'trimf',[0.106 0.312 0.503]

MF5='Up':'trapmf',[0.365 0.698 1.01 1.82]

[Output3]

Name='ANKV'

Range=[-1 1]

NumMFs=5

MF1='Down':'trapmf',[-1.89 -1.05 -0.698 -0.365]

MF2='SD':'trimf',[-0.503 -0.312 -0.106]

MF3='Remain':'trimf',[-0.201 0 0.201]

MF4='SU':'trimf',[0.106 0.312 0.503]

MF5='Up':'trapmf',[0.365 0.698 1.01 1.82]

[Rules]

1 1 4, 5 4 5 (1) : 1
1 1 3, 5 4 5 (1) : 1
1 2 3, 5 3 4 (1) : 1
1 2 4, 5 3 5 (1) : 1
1 2 2, 5 4 3 (1) : 1
2 1 3, 4 4 3 (1) : 1
2 1 4, 5 4 5 (1) : 1
2 3 2, 5 1 5 (1) : 1
2 2 2, 3 4 3 (1) : 1
2 2 3, 4 2 5 (1) : 1
2 2 4, 5 4 5 (1) : 1
2 3 3, 4 1 5 (1) : 1
3 1 3, 3 4 3 (1) : 1
3 1 4, 4 4 3 (1) : 1
3 2 2, 3 3 3 (1) : 1
3 2 3, 3 3 3 (1) : 1
3 3 1, 3 1 3 (1) : 1
3 3 2, 4 1 3 (1) : 1
3 3 3, 3 1 4 (1) : 1
4 1 3, 3 4 2 (1) : 1
4 2 2, 3 3 2 (1) : 1
4 2 3, 3 3 2 (1) : 1
4 3 1, 2 1 2 (1) : 1
4 3 2, 2 1 2 (1) : 1
4 3 3, 3 2 2 (1) : 1

A.7 Sistema Fuzzy 7

[System]

Name='Doutorado-fuzzy7'

Type='mamdani'

Version=2.0

NumInputs=3

NumOutputs=3

NumRules=25

AndMethod='min'

OrMethod='max'

ImpMethod='min'

AggMethod='max'

DefuzzMethod='centroid'

[Input1]

Name='ADKV'

Range=[135 150]
NumMFs=4
MF1='Low': 'zmf', [139.679365079365 142.679365079365]
MF2='NTL': 'gaussmf', [0.57 142.357142857143]
MF3='OK': 'gaussmf', [0.516 144.198412698413]
MF4='High': 'smf', [144.15873015873 146.15873015873]

[Input2]
Name='JPKV'
Range=[132 145]
NumMFs=3
MF1='Low': 'zmf', [135.403174603175 139.403174603175]
MF2='OK': 'gaussmf', [0.585 138.793650793651]
MF3='High': 'smf', [138.275132275133 142.275132275133]

[Input3]
Name='GRCS'
Range=[-300 400]
NumMFs=5
MF1='Inductive': 'zmf', [-166.52962962963 -52.7796296296296]
MF2='LI': 'gaussmf', [15.1 -76.16]
MF3='OK': 'gaussmf', [15.3 -31.86]
MF4='LC': 'gaussmf', [25.4 26.6]
MF5='Capacitive': 'smf', [36.09 106.6]

[Output1]
Name='MRKV'
Range=[-1 1]
NumMFs=5
MF1='Down': 'trapmf', [-1.89 -1.05 -0.698 -0.365]
MF2='SD': 'trimf', [-0.503 -0.312 -0.106]
MF3='Remain': 'trimf', [-0.201 0 0.201]
MF4='SU': 'trimf', [0.106 0.312 0.503]
MF5='Up': 'trapmf', [0.365 0.698 1.01 1.82]

[Output2]
Name='FUKV'
Range=[-1 1]
NumMFs=5
MF1='Down': 'trapmf', [-1.89 -1.05 -0.698 -0.365]
MF2='SD': 'trimf', [-0.503 -0.312 -0.106]
MF3='Remain': 'trimf', [-0.201 0 0.201]
MF4='SU': 'trimf', [0.106 0.312 0.503]
MF5='Up': 'trapmf', [0.365 0.698 1.01 1.82]

[Output3]
Name='ANKV'
Range=[-1 1]
NumMFs=5
MF1='Down': 'trapmf', [-1.89 -1.05 -0.698 -0.365]

```

MF2='SD':'trimf',[-0.503 -0.312 -0.106]
MF3='Remain':'trimf',[-0.201 0 0.201]
MF4='SU':'trimf',[0.106 0.312 0.503]
MF5='Up':'trapmf',[0.365 0.698 1.01 1.82]
[Rules]
1 1 4, 5 5 4 (1) : 1
1 1 3, 5 5 4 (1) : 1
1 2 3, 5 4 3 (1) : 1
1 2 4, 5 4 4 (1) : 1
1 2 2, 5 5 4 (1) : 1
2 1 3, 4 4 4 (1) : 1
2 1 4, 5 5 4 (1) : 1
2 3 2, 5 2 4 (1) : 1
2 2 2, 3 4 2 (1) : 1
2 2 3, 4 3 4 (1) : 1
2 2 4, 5 5 4 (1) : 1
2 3 3, 4 2 4 (1) : 1
3 1 3, 3 5 2 (1) : 1
3 1 4, 4 5 2 (1) : 1
3 2 2, 3 3 3 (1) : 1
3 2 3, 3 3 3 (1) : 1
3 3 1, 3 2 2 (1) : 1
3 3 2, 4 2 2 (1) : 1
3 3 3, 3 2 3 (1) : 1
4 1 3, 3 5 1 (1) : 1
4 2 2, 3 4 1 (1) : 1
4 2 3, 3 4 1 (1) : 1
4 3 1, 2 2 1 (1) : 1
4 3 2, 2 2 1 (1) : 1
4 3 3, 3 3 1 (1) : 1

```

A.8 Sistema Fuzzy 8

```

[System]
Name='Doutorado-fuzzy8'
Type='mamdani'
Version=2.0
NumInputs=3
NumOutputs=3
NumRules=25
AndMethod='min'
OrMethod='max'
ImpMethod='min'
AggMethod='max'
DefuzzMethod='centroid'

```

[Input1]
Name='ADKV'
Range=[135 150]
NumMFs=4
MF1='Low': 'zmf', [139.679365079365 142.679365079365]
MF2='NTL': 'gaussmf', [0.57 142.357142857143]
MF3='OK': 'gaussmf', [0.516 144.198412698413]
MF4='High': 'smf', [144.15873015873 146.15873015873]

[Input2]
Name='JPKV'
Range=[132 145]
NumMFs=3
MF1='Low': 'zmf', [135.403174603175 139.403174603175]
MF2='OK': 'gaussmf', [0.585 138.793650793651]
MF3='High': 'smf', [138.275132275133 142.275132275133]

[Input3]
Name='GRCS'
Range=[-300 400]
NumMFs=5
MF1='Inductive': 'zmf', [-166.52962962963 -52.7796296296296]
MF2='LI': 'gaussmf', [15.1 -76.16]
MF3='OK': 'gaussmf', [15.3 -31.86]
MF4='LC': 'gaussmf', [25.4 26.6]
MF5='Capacitive': 'smf', [36.09 106.6]

[Output1]
Name='MRKV'
Range=[-1 1]
NumMFs=5
MF1='Down': 'trapmf', [-1.89 -1.05 -0.698 -0.365]
MF2='SD': 'trimf', [-0.503 -0.312 -0.106]
MF3='Remain': 'trimf', [-0.201 0 0.201]
MF4='SU': 'trimf', [0.106 0.312 0.503]
MF5='Up': 'trapmf', [0.365 0.698 1.01 1.82]

[Output2]
Name='FUKV'
Range=[-1 1]
NumMFs=5
MF1='Down': 'trapmf', [-1.89 -1.05 -0.698 -0.365]
MF2='SD': 'trimf', [-0.503 -0.312 -0.106]
MF3='Remain': 'trimf', [-0.201 0 0.201]
MF4='SU': 'trimf', [0.106 0.312 0.503]
MF5='Up': 'trapmf', [0.365 0.698 1.01 1.82]

[Output3]
Name='ANKV'

```
Range=[-1 1]
NumMFs=5
MF1='Down': 'trapmf',[-1.89 -1.05 -0.698 -0.365]
MF2='SD': 'trimf',[-0.503 -0.312 -0.106]
MF3='Remain': 'trimf',[-0.201 0 0.201]
MF4='SU': 'trimf',[0.106 0.312 0.503]
MF5='Up': 'trapmf',[0.365 0.698 1.01 1.82]
```

```
[Rules]
```

```
1 1 4, 5 5 5 (1) : 1
1 1 3, 5 5 5 (1) : 1
1 2 3, 5 4 4 (1) : 1
1 2 4, 5 4 5 (1) : 1
1 2 2, 5 5 3 (1) : 1
2 1 3, 4 5 4 (1) : 1
2 1 4, 5 5 5 (1) : 1
2 3 2, 5 2 5 (1) : 1
2 2 2, 5 5 5 (1) : 1
2 2 3, 5 5 5 (1) : 1
2 2 4, 5 5 5 (1) : 1
2 3 3, 4 2 5 (1) : 1
3 1 3, 5 5 5 (1) : 1
3 1 4, 5 5 5 (1) : 1
3 2 2, 3 3 3 (1) : 1
3 2 3, 3 3 3 (1) : 1
3 3 1, 3 2 3 (1) : 1
3 3 2, 1 1 1 (1) : 1
3 3 3, 1 1 1 (1) : 1
4 1 3, 3 5 2 (1) : 1
4 2 2, 1 1 1 (1) : 1
4 2 3, 2 2 2 (1) : 1
4 3 1, 2 2 2 (1) : 1
4 3 2, 2 2 2 (1) : 1
4 3 3, 3 3 2 (1) : 1
```

A.9 Sistema Fuzzy Após Aprendizado

```
[System]
Name='Doutorado-fuzzy learned'
Type='mamdani'
Version=2.0
NumInputs=3
NumOutputs=3
NumRules=25
AndMethod='min'
```

OrMethod='max'
ImpMethod='min'
AggMethod='max'
DefuzzMethod='centroid'

[Input1]

Name='ADKV'
Range=[135 150]
NumMFs=4
MF1='Low': 'zmf',[139.679365079365 142.679365079365]
MF2='NTL': 'gaussmf',[0.57 142.357142857143]
MF3='OK': 'gaussmf',[0.516 144.198412698413]
MF4='High': 'smf',[144.15873015873 146.15873015873]

[Input2]

Name='JPKV'
Range=[132 145]
NumMFs=3
MF1='Low': 'zmf',[135.403174603175 139.403174603175]
MF2='OK': 'gaussmf',[0.585 138.793650793651]
MF3='High': 'smf',[138.275132275133 142.275132275133]

[Input3]

Name='GRCS'
Range=[-300 400]
NumMFs=5
MF1='Inductive': 'zmf',[-166.52962962963 -52.7796296296296]
MF2='LI': 'gaussmf',[15.1 -76.16]
MF3='OK': 'gaussmf',[15.3 -31.86]
MF4='LC': 'gaussmf',[25.4 26.6]
MF5='Capacitive': 'smf',[36.09 106.6]

[Output1]

Name='MRKV'
Range=[-1 1]
NumMFs=5
MF1='Down': 'trapmf',[-1.89 -1.05 -0.698 -0.365]
MF2='SD': 'trimf',[-0.503 -0.312 -0.106]
MF3='Remain': 'trimf',[-0.201 0 0.201]
MF4='SU': 'trimf',[0.106 0.312 0.503]
MF5='Up': 'trapmf',[0.365 0.698 1.01 1.82]

[Output2]

Name='FUKV'
Range=[-1 1]
NumMFs=5
MF1='Down': 'trapmf',[-1.89 -1.05 -0.698 -0.365]
MF2='SD': 'trimf',[-0.503 -0.312 -0.106]
MF3='Remain': 'trimf',[-0.201 0 0.201]
MF4='SU': 'trimf',[0.106 0.312 0.503]

MF5='Up':'trapmf',[0.365 0.698 1.01 1.82]

[Output3]

Name='ANKV'

Range=[-1 1]

NumMFs=5

MF1='Down':'trapmf',[-1.89 -1.05 -0.698 -0.365]

MF2='SD':'trimf',[-0.503 -0.312 -0.106]

MF3='Remain':'trimf',[-0.201 0 0.201]

MF4='SU':'trimf',[0.106 0.312 0.503]

MF5='Up':'trapmf',[0.365 0.698 1.01 1.82]

[Rules]

1 1 4, 5 5 5 (1) : 1

1 1 3, 5 4 5 (1) : 1

1 2 3, 4 3 3 (1) : 1

1 2 4, 5 4 4 (1) : 1

1 2 2, 5 5 3 (1) : 1

2 1 3, 4 5 4 (1) : 1

2 1 4, 5 5 5 (1) : 1

2 3 2, 5 2 4 (1) : 1

2 2 2, 3 3 4 (1) : 1

2 2 3, 4 3 4 (1) : 1

2 2 4, 4 4 4 (1) : 1

2 2 5, 4 2 4 (1) : 1

3 1 3, 2 4 2 (1) : 1

3 1 4, 4 4 3 (1) : 1

3 2 2, 3 3 3 (1) : 1

3 2 3, 3 3 3 (1) : 1

3 3 1, 2 1 2 (1) : 1

3 3 2, 3 1 2 (1) : 1

3 3 3, 2 2 4 (1) : 1

4 1 3, 2 4 2 (1) : 1

4 2 2, 3 3 2 (1) : 1

4 2 3, 2 3 1 (1) : 1

4 3 1, 1 1 1 (1) : 1

4 3 2, 2 2 1 (1) : 1

4 3 3, 3 2 1 (1) : 1