



COPPE/UFRJ

COMPUTAÇÃO QUÂNTICA E INTELIGÊNCIA DE ENXAMES
APLICADOS NA IDENTIFICAÇÃO DE ACIDENTES DE UMA USINA
NUCLEAR PWR

Andressa dos Santos Nicolau

Dissertação de Mestrado apresentada ao
Programa de Pós-graduação de
Engenharia Nuclear, COPPE, da
Universidade Federal do Rio de Janeiro,
como parte dos requisitos necessários à
obtenção do título de Mestre em
Ciências em Engenharia Nuclear.

Orientador:
Roberto Schirru

Rio de Janeiro
Fevereiro de 2010

COMPUTAÇÃO QUÂNTICA E INTELIGÊNCIA DE ENXAMES
APLICADOS NA IDENTIFICAÇÃO DE ACIDENTES DE UMA USINA
NUCLEAR PWR

Andressa dos Santos Nicolau

DISSERTAÇÃO 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 MESTRE EM CIÊNCIAS EM ENGENHARIA
NUCLEAR.

Examinada por:

Prof. Roberto Schirru, D. Sc.

Prof. Eduardo Gomes Dutra do Carmo, D. Sc.

Prof. Antonio Carlos Abreu Mol, D.Sc.

Dr. Marco Antonio Bayout Alvarenga D. Sc.

RIO DE JANEIRO, RJ -BRASIL
FEVEREIRO DE 2010

Nicolau, Andressa dos Santos

Computação Quântica e Inteligência de Enxames aplicados na Identificação de Acidentes de uma Usina Nuclear PWR / Andressa dos Santos Nicolau - Rio de Janeiro:UFRJ/COPPE, 2010.

XIV, 91 p.: il.; 29,7 cm

Orientador: Roberto Schirru

Dissertação (mestrado) – UFRJ/COPPE/Programa de Engenharia Nuclear, 2010.

Referências Bibliográficas: p.86-91

1. Computação Quântica. 2. Algoritmos Evolucionários e Inteligência de Enxames. 3. Algoritmos com Inspiração Quântica 4. Identificação de acidentes/transientes de uma Usina Nuclear PWR. I. Schirru, Roberto. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Nuclear.

III. Título.

“A mecânica quântica é realmente impressionante. Mas uma voz interior me diz que a ainda não é o que buscamos. A teoria faz muito, mas pouco nos aproxima do segredo do grande Ancião. Em todo o caso, estou convencido de que Ele não joga aos dados.”

Albert Einstein

AGRADECIMENTOS

Primeiramente agradeço a minha família, porque sem ela não teria conseguido nenhuma de minhas vitórias.

A Deus por estar comigo, dia após dia, me dando forças e abrindo meus caminhos para que eu possa realizar meus objetivos.

Ao professor e amigo Roberto Schirru, pelo apoio, dedicação e ensinamentos que contribuíram de forma incontável para minha formação.

Aos amigos de hoje e sempre, Babi, Paty, Joy, Rafinha, Rafa e Max, agradeço o apoio nos momentos difíceis, as belas tardes de Itaquá e a tolerância aos meus dias de mal humor.

Aos amigos que conheci no Laboratório de Monitoração de Processos (LMP): Simone, Magali, Alan, Serginho, Vinícius, Anderson, Tony, Carlão e todos os outros que participaram dos meus dias no LMP.

A todos aqueles que de uma forma ou outra contribuíram para que eu possa ter subido mais um degrau de minha escada.

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

COMPUTAÇÃO QUÂNTICA E INTELIGÊNCIA DE ENXAMES APLICADOS NA IDENTIFICAÇÃO DE ACIDENTES DE UMA USINA NUCLEAR - PWR

Andressa dos Santos Nicolau

Fevereiro/2010

Orientador: Roberto Schirru.

Programa: Engenharia Nuclear

Este trabalho apresenta os resultados do estudo que avaliou o comportamento dos algoritmos de inspiração quântica, QEA (*Quantum Inspired Evolutionary Algorithm*) e QSE (*Quantum Swarm Evolutionary*), como ferramentas de otimização em espaços de busca contínuos e discretos de alta dimensão. Além disso, apresenta um Método de Identificação de acidentes/transientes de uma Usina Nuclear PWR, otimizado pelo algoritmo QEA. O método proposto, tem como idéia básica classificar um evento anômalo, dentro da assinatura de três acidentes de base de projeto postulados para a usina nuclear de Angra 2. O QEA foi usado para encontrar a melhor posição dos centróides protótipos, de cada um dos três acidentes/transientes, com um número máximo de acertos. Os resultados obtidos pelo método proposto foram compatíveis e até superiores aos resultados encontrados na literatura, na solução do problema de identificação de acidentes, permitindo uma solução que se aproxima da solução ideal, ou seja, dos Vetores de Voronoi. Sendo assim, este trabalho mostra a viabilidade do uso da ferramenta de inspiração quântica QEA nos problemas da área nuclear.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfilment of the requirements for the degree of Master of Science (M.Sc.).

QUANTUM COMPUTATION AND SWARM INTELIGENCIA APPLIED IN THE
IDENTIFICATION OF ACCIDENTS OF A PWR NUCLEAR POWER PLANT

Andressa dos Santos Nicolau

February/2010

Advisor: Roberto Schirru.

Department: Engenharia Nuclear

This work presents the results of the evaluated study the behavior the quantum-inspired algorithms, QEA (Quantum Inspired Evolutionary Algorithm) and QSE (Quantum Swarm Evolutionary) as optimization tools the search continuous spaces and discrete high-dimensional. It also presents a method for identification of accident / transient in a PWR Nuclear Power Plant, optimized by the algorithm QEA. In the proposed method, the basic idea is to classify an anomalous event, within in signing of three accidents/transients of the design basis list of the nuclear power plant Angra 2. The QEA was used to find the best position of the centroids prototypes, of each of a three accidents/transient of the design basis, that maximize the number of correct classifications. The results obtained by the proposed method were consistent and even higher than, that found in the literature, for the problem of identification of accidents, providing a solution that approximates the ideal solution, of the Voronoi Vectors. This work enables the use of the tool of inspiration quantum QEA, in problems in a nuclear area. Thus, this work shows the feasibility of using the tool of inspiration quantum QEA, problems in the nuclear area.

ÍNDICE

| | |
|---|----|
| 1. INTRODUÇÃO | 1 |
| 2. FUNDAMENTAÇÃO TEÓRICA | 7 |
| 2.1. Mecânica Quântica | 7 |
| 2.2. Computação Quântica | 9 |
| 2.3. Algoritmos Evolucionários | 13 |
| 2.4. Inteligência de Enxames | 19 |
| 3. ALGORITMOS DE OTIMIZAÇÃO COM INSPIRAÇÃO QUÂNTICA | 25 |
| 3.1. Introdução | 25 |
| 3.2. Quantum Evolutionary Algorithm (QEA) | 27 |
| 3.3. Quantum Inspired Evolutionary (QSE) | 33 |
| 4. OTIMIZAÇÃO DE FUNÇÕES CONTÍNUAS E DISCRETAS | 37 |
| 4.1. Introdução | 37 |
| 4.2. Funções Contínuas | 37 |
| 4.3. Função Discreta. | 39 |
| 4.4. Modelagem dos algoritmos de inspiração quântica | 40 |
| 4.5. Análise e Resultados | 42 |
| 4.6. Escolha do algoritmo de inspiração quântica | 47 |
| 5. IDENTIFICAÇÃO DE ACIDENTES NUCLEARES | 48 |
| 5.1. Introdução | 48 |
| 5.2. Principais Acidentes de base de projeto de uma Usina Nuclear – PWR | 51 |
| 5.3. Sistemas de Identificação de Acidentes de Usinas Nucleares, baseados e, Técnicas de Inteligência Artificial. | 54 |

| | |
|---|----|
| 6. OTIMIZAÇÃO DO PROBLEMA DE IDENTIFICAÇÃO DE ACIDENTES NUCLEARES | 58 |
| 6.1. Introdução | 58 |
| 6.2. Modelo de um Sistema Protótipo de Identificação de Acidentes/Transientes | 59 |
| 6.3. Acidentes/Transientes de base de projeto selecionados para a implementação do sistema proposto | 60 |
| 6.4. Configuração do QEA | 67 |
| 6.5. Análise e Resultados | 69 |
| 7. CONCLUSÕES E PROPOSTAS DE TRABALHOS FUTUROS | 83 |
| 7.1. Conclusões | 83 |
| 7.2. Propostas de Trabalhos Futuros | 84 |
| 8. REFERÊNCIAS BIBLIOGRÁFICAS | 86 |

LISTA DE FIGURAS

| | |
|--|----|
| Figura 2.1. Esfera de Bloch | 12 |
| Figura 2.2. Pseudocódigo de um AG simples | 16 |
| Figura 2.3. Atualização de uma partícula no PSO simples | 22 |
| Figura 2.4. Atualização das partículas no PSO simples | 23 |
| Figura 2.5. Pseudocódigo de um PSO simples | 24 |
| Figura 3.1. Representação gráfica de um círculo unitário com as amplitudes de probabilidade de se observar os valores 0 e 1 para um Q-bit qualquer, no caso em que α e β são reais | 27 |
| Figura 3.2. Pseudocódigo do QEA simples | 29 |
| Figura 3.3. Pseudocódigo de geração de $P(t)$ no QEA simples | 30 |
| Figura 3.4. Pseudocódigo de atualização do Q-bit no QEA simples | 31 |
| Figura 3.5. Rotação do portão quântico no QEA simples | 33 |
| Figura 3.6. Pseudocódigo de um QSE simples | 34 |
| Figura 3.7. Pseudocódigo de produção de $P(t)$, no QSE simples | 35 |
| Figura 4.1. Função Rosenbrock F2 D'Jong | 38 |
| Figura 4.2. Função Esfera para $n=2$ | 39 |
| Figura 4.3. Novo Pseudocódigo de geração de $P(t)$ | 41 |

Figura 4.4. Gráfico de convergência do QEA do melhor resultado encontrado pelo QEA para a função esfera de dimensão $n=10$ no intervalo de $-100 < x < 100$, para uma população de 20 indivíduos 45

Figura 4.5. Gráfico de convergência do melhor resultado encontrado pelo QEA para a função esfera de dimensão $n=30$ no intervalo de $-100 < x < 100$, para uma população de 100 indivíduos 46

Figura 6.1. Exemplo de classificação de uma amostra, onde os pontos c_1 , c_2 , c_3 são os centróides dos acidentes 1, 2 e 3, respectivamente e d_1 , d_2 e d_3 as respectivas distâncias entre os centróides dos acidentes e a amostra a ser classificada 60

Figura 6.2. Assinatura das variáveis de estado 1, 2 e 3 para cada um dos 3 acidentes/transientes postulados considerando a usina operando a 100% de potência nominal 65

Figura 6.3. Assinatura das variáveis de estado 4, 5 e 6 para cada um dos 3 acidentes/transientes postulados considerando a usina operando a 100% de potência nominal 65

Figura 6.4. Assinatura das variáveis de estado 7, 8 e 9 para cada um dos 3 acidentes/transientes postulados considerando a usina operando a 100% de potência nominal 66

Figura 6.5. Assinatura das variáveis de estado 10, 11 e 13 para cada um dos 3 acidentes/transientes postulados considerando a usina operando a 100% de potência nominal 66

Figura 6.6. Assinatura das variáveis de estado 14, 15 e 16 para cada um dos 3 acidentes/transientes postulados considerando a usina operando a 100% de potência nominal 67

| | |
|--|----|
| Figura 6.7. Assinatura das variáveis de estado 17 e 18 para cada um dos 3 acidentes/transientes postulados considerando a usina operando a 100% de potência nominal | 67 |
| Figura 6.8. Portão quântico <i>He</i> baseado no portão quântico do QEA simples | 69 |
| Figura 6.9. Representação dos protótipos de cada acidente | 71 |
| Figura 6.10. Convergência do QEA | 72 |
| Figura 6.11. Representação dos protótipos de cada acidente com o $t=1s$ | 74 |
| Figura 6.12. Representação dos protótipos de cada acidente com o $t=30s$ | 75 |
| Figura 6.13. Representação dos protótipos de cada acidente com o $t=50s$ | 76 |
| Figura 6.14. Representação dos protótipos de cada acidente com o $t=60s$ | 77 |

LISTA DE TABELAS

| | |
|---|----|
| Tabela 3.1. Probabilidades de observação de cada um dos possíveis estados do indivíduo Q-bit | 12 |
| Tabela 3.2. Mudança do ângulo de rotação do QEA simples | 32 |
| Tabela 4.1. Mudança do ângulo de rotação | 41 |
| Tabela 4.2. Resultados do QSE para a F2 D’Jong | 44 |
| Tabela 4.3. Resultados do QSE para a F2 D’Jong | 44 |
| Tabela 4.4. Resultados do QSE para a Esfera | 44 |
| Tabela 4.5. Resultados do QEA para a Esfera | 45 |
| Tabela 4.6. Resultados do QEA para a Esfera | 45 |
| Tabela 4.7. Resultados do QSE para a função 4 picos | 47 |
| Tabela 4.8. Resultados do QEA para a função 4 picos | 47 |
| Tabela 6.1. Variáveis de estado dos acidentes/transientes | 64 |
| Tabela.6.2. Resultados do QEA | 70 |
| Tabela 6.3. Comparação entre os algoritmos QEA, PSO e GA. | 73 |
| Tabela 6.4. Vetor protótipo $t = 1s$ | 75 |

| | |
|---|----|
| Tabela 6.5. Vetor protótipo $t=30s$ | 76 |
| Tabela 6.6. Vetor protótipo $t=50s$ | 77 |
| Tabela 6.7. Vetor protótipo $t=60s$ | 78 |
| Tabela 6.8. Variáveis de estado retiradas do sistema de identificação de acidentes/transientes e o número de acertos. | 78 |
| Tabela 6.9. Vetor protótipo sem as variáveis da tabela 6.8. | 79 |
| Tabela 6.10. Variáveis de estado retiradas do sistema de identificação de acidentes/transientes e o número de acertos. | 79 |
| Tabela 6.11. Vetor protótipo sem as variáveis da tabela 6.10. | 79 |
| Tabela 6.12. Variáveis de estado retiradas do sistema de identificação de acidentes/transientes e o número de acertos. | 80 |
| Tabela 6.13. Vetor protótipo sem as variáveis da tabela 6.12. | 80 |
| Tabela 6.14. Primeira linha de cada acidente/transiente | 81 |
| Tabela 6.15. Segunda linha de cada acidente/transiente | 82 |

CAPÍTULO 1

INTRODUÇÃO

A Computação Quântica (DEUTSH, 1985) é uma área de pesquisa que une elementos de três áreas do conhecimento: Matemática, Física e Computação. A utilização de fenômenos quânticos para a representação e o processamento de informação, tem atraído crescente atenção da área científica, tecnológica e industrial.

A primeira descrição de um aparato computacional foi proposta por Paul Benioff em 1980, conhecida como máquina de Turing. Richard Feynman, em 1982, iniciou a história da Computação Quântica ao estudar a possibilidade de se criar objetos de Mecânica Quântica por meio de sistemas quânticos. Apontou possibilidades de que efeitos quânticos poderiam oferecer algo que efeitos clássicos não conseguiriam. Mas, a força da Computação Quântica só começou a ser percebida em 1985, quando David Deutsch da Universidade de Oxford publicou um documento descrevendo um Computador Quântico. Propôs soluções para problemas que máquinas usando Mecânica Quântica poderiam realizar de forma eficiente, ao contrário das máquinas clássicas. Além disso, apresentou um algoritmo com apenas operações quânticas capaz de resolver um determinado problema matemático de maneira mais eficiente que qualquer algoritmo clássico. Porém, tal algoritmo só teve repercussão em 1989, quando Deutsch introduziu o modelo de circuitos quânticos (OLIVEIRA *et. al.*, 2004).

Em 1994 Peter Shor (SHOR, 1994), dos laboratórios Bell AT&T em Nova Jersey – EUA apresentou o primeiro algoritmo quântico que em tese poderia desenvolver fatoração de forma eficiente. Tal algoritmo é importante em processos como o de criptografia de senhas bancárias, onde dado um número com mais de uma centena de algarismos é possível encontrar dois outros que multiplicados entre si, resultem nele. Caso essa tarefa fosse realizada por centenas de computadores atuais trabalhando em paralelo, levaria vários meses para ser realizada. Dessa forma, o mérito de Peter Shor está no fato de desenvolver um algoritmo que torne a realização desta tarefa mais rápida.

Um computador quântico é um dispositivo que executa cálculos fazendo uso direto de propriedades da Mecânica Quântica, tais como sobreposição e interferência de estados. Teoricamente, computadores quânticos podem ser implementados e o mais desenvolvido atualmente trabalha com poucos *qubits* de informação. O principal ganho desses computadores é a possibilidade de resolver em tempo eficiente, alguns problemas que na computação clássica levariam tempo impraticável.

Diferente de um computador clássico que apresenta uma memória constituída de bits, onde cada bit guarda um "1" ou um "0" de informação, um computador quântico mantém um conjunto de *qubits*. Um *qubit* (Q-bit) pode conter um "1", um "0" ou uma sobreposição destes. Em outras palavras, pode conter tanto um "1" como um "0" ao mesmo tempo. E o seu funcionamento está baseado na manipulação destes *qubits*.

Um computador quântico pode ser implementado com alguns sistemas com partículas pequenas, desde que obedeçam à natureza descrita pela Mecânica Quântica. Pode-se construir computadores quânticos com átomos que podem estar excitados e não excitados ao mesmo tempo, ou com fótons que podem estar em dois lugares ao mesmo tempo, ou com prótons e nêutrons, ou ainda com elétrons e pósitrons que podem ter um spin ao mesmo tempo "para cima" e "para baixo" e se movimentam em velocidades próximas à da luz. (COLLINS, 2006).

Embora a Computação Quântica ofereça uma boa promessa em termos de capacidade de processamento, a grande questão a ser resolvida hoje para que essas máquinas se tornem uma ferramenta útil é a capacidade de controlar os sistemas nos quais são planejados, já que as interferências são grandes e o tempo de coerência dos estados das partículas pequeno, além disso, existe a grande dificuldade de se criar algoritmos que tirem proveito da capacidade de processamento em paralelo destes computadores.

Devido a essas dificuldades ao invés de desenvolver novos algoritmos para computadores quânticos ou de tentar viabilizar o uso destes, atualmente estão sendo criados algoritmos evolucionários de otimização com inspiração quântica. Esses algoritmos são implementados em computadores clássicos e suas estruturas operacionais foram desenvolvidas com base nos principais paradigmas da Teoria Quântica: a superposição e interferência de estados quânticos.

Por se tratarem de algoritmos evolucionários de otimização com inspiração quântica, englobam um conjunto de métodos computacionais inspirados nos mecanismos evolutivos da Teoria da Evolução das Espécies (DARWIN, 1859) que procuram encontrar os pontos que maximizem (ou minimizem) uma dada função matemática, ou o melhor desempenho de um sistema.

Os principais algoritmos evolucionários com inspiração quântica e que foram estudados, neste trabalho, como ferramenta de otimização, foram o QEA (*Quantum Evolutionary Algorithm*) e o QSE (*Quantum Swarm Evolutionary*). Esses dois algoritmos unem elementos de três da Computação Quântica, da Computação Evolucionária e da Inteligência de Enxames.

O QEA (HAN *et.al.*, 2002) foi construído com base nos principais conceitos da Computação Quântica e da Computação Evolucionária. Nele o bit é chamado de bit quântico ou Q-bit, que apresenta a probabilidade de superposição de estados quânticos. Assim como os Algoritmos Genéticos - AG (GOLDBERG, 1989) desenvolvidos por Holland na década de 60, é caracterizado por um cromossomo, uma função de avaliação e uma dinâmica populacional. Entretanto, ao invés de uma representação binária convencional, utiliza uma representação especial que simula um cromossomo formado por Q-bits, definido por $[\alpha, \beta]$. Diferente do AG, onde o aprendizado da população é feito através de operadores de cruzamento, mutação, no QEA o aprendizado da população quântica é feito através de um operador variação chamado de portão quântico (Q-gate).

O QSE (WANG *et. al.*, 2007) utiliza basicamente as mesmas estruturas quânticas da Computação Quântica e sua dinâmica populacional é inspirada na Inteligência de Enxames, onde é simulado o comportamento coletivo auto organizado de sistemas descentralizados constituído de um elevado número de agentes com um objetivo final comum. O Q-bit é usado como representação de probabilidades, e diferente do QEA é definido por $[\cos \theta, \sin \theta]$. Assim como o PSO (*Particle Swarm Optimization*) (KENNEDY, EBERHART, 2001), o aprendizado do QSE é feito através de equações de velocidade e posição.

Na presente dissertação, a eficiência e a robustez dos algoritmos QEA e QSE como ferramentas de otimização, foram verificadas através de testes realizados com funções discretas e contínuas de alta dimensão de ótimos bem conhecidos. Tais testes, foram considerados necessários e suficientes para a comparação do desempenho dos algoritmos e para a escolha de um deles como ferramenta de otimização, de um modelo de diagnóstico de acidentes/transientes de uma Usina Nuclear PWR, operando a 100% de potência.

Partindo do princípio de que uma Usina Nuclear é um sistema complexo, composto de muitos subsistemas e milhares de componentes e, que a dinâmica da variação das medidas das grandezas associadas ao evento em curso, dificulta o processo de identificação e tomada de decisão por parte do operador, sistemas computadorizados de auxílio à operação na sala de controle das usinas nucleares podem ser bastante úteis no gerenciamento global das condições de segurança da usina e, no auxílio aos operadores nas tomadas de decisões de emergência reduzindo sua carga cognitiva, e maximizando a segurança de funcionamento da Usina.

Dessa forma, propomos neste trabalho um modelo de diagnóstico de acidentes/transientes de uma Usina Nuclear PWR, baseado no algoritmo de inspiração quântica QEA. Tal modelo foi implementado em um sistema protótipo que identifica um evento anômalo da usina de Angra 2, dentre um conjunto de 3 acidentes/transientes de base de projeto, qual melhor caracteriza o evento em curso. O QEA foi usado para encontrar a melhor posição protótipos dos centróides, Vetores de Voronoi (HAYKIN, S., 1994) de cada um dos três acidentes/transientes selecionados, de modo que essas posições maximizam o número de classificações corretas. Sendo assim, o sistema de diagnóstico proposto classifica o evento anômalo através da menor distância euclidiana entre os protótipos centróides gerados pelo QEA e, a assinatura das variáveis de estado do evento, ou seja, da evolução temporal das variáveis de estado do evento anômalo.

Para apresentar o método proposto, seus fundamentos teóricos e os resultados obtidos, este trabalho foi organizado em sete capítulos descritos sumariamente a seguir.

No presente capítulo é apresentado uma breve descrição dos principais fundamentos da Computação Quântica, do surgimento dos algoritmos com inspiração quântica QEA e QSE, bem como os objetivos deste trabalho e a organização do mesmo.

O capítulo 2 apresenta uma breve descrição dos principais fundamentos teóricos que embasaram o desenvolvimento desta dissertação. Inicialmente são introduzidos os principais aspectos da Mecânica Quântica, seus principais postulados e conceitos importantes para o entendimento do funcionamento da Computação Quântica. Em seguida, são apresentados os principais fundamentos dos Algoritmos Evolucionários e da Inteligência de Enxames, além de uma breve descrição deste método de otimização da área da Inteligência Artificial e sua implementação na Computação Clássica.

No capítulo 3 são apresentados as características de dois algoritmos clássicos de otimização com inspiração quântica: o QEA (*Quantum Evolutionary Algorithm*) e o QSE (*Quantum Swarm Evolutionary*). Esses algoritmos são executados em computadores clássicos, porém baseados na Computação Quântica e dessa forma, nos principais conceitos da Teoria Quântica: a superposição e interferência de estados quânticos.

No capítulo 4 são apresentados os resultados dos testes realizados com os algoritmos de inspiração quântica: QEA e QSE, quando aplicados na otimização de funções contínuas e discretas de alta dimensão. Inicialmente são descritas as funções de testes utilizadas com o propósito de avaliar o comportamento de cada algoritmo, bem como a implementação destes, em cada função de teste e, finalmente, são apresentados os resultados obtidos nesta seção.

No capítulo 5 são apresentadas as principais características do problema de identificação de acidentes/transientes de uma Usina Nuclear, bem como uma breve descrição dos principais acidentes/transientes de base de projeto postulados para a usina de Angra 2. Em seguida, são introduzidos os objetivos básicos de um sistema de identificação de acidentes/transientes de uma Usina Nuclear, baseados em técnicas de Inteligência Artificial.

No capítulo 6 são apresentados os testes e resultados da implementação de um sistema protótipo de identificação de um conjunto de 3 acidentes de base de projeto,

dentre os 17 acidentes/transientes, postulados pelo FSAR (*Final Safety Analysis Report*), para a usina nuclear Angra 2. O objetivo desta seção é avaliar a capacidade do QEA como ferramenta de otimização de sistemas complexos da área nuclear. Primeiramente, são apresentadas as características dos acidentes/transientes de base de projeto selecionados para a realização dos testes desta seção. Em seguida, são apresentadas as características do sistema protótipo de identificação de acidentes/transientes proposto neste trabalho, bem como, a modelagem do problema com o QEA e, a comparação dos resultados encontrados neste trabalho, com outros existentes na literatura.

O capítulo 7 apresenta as conclusões finais e sugestões para trabalhos futuros.

CAPÍTULO 2

FUNDAMENTAÇÃO TEÓRICA

O presente capítulo apresenta uma breve descrição dos principais fundamentos teóricos que embasaram o desenvolvimento desta dissertação. Inicialmente são introduzidos os principais aspectos da Mecânica Quântica, seus principais postulados e conceitos importantes para o entendimento do funcionamento da Computação Quântica. Em seguida são apresentados os principais fundamentos dos Algoritmos Evolucionários e da Inteligência de Enxames, além de uma breve descrição deste método de otimização da área da Inteligência Artificial e sua implementação na Computação Clássica.

2.1. Mecânica Quântica

2.1.1. Introdução

A Mecânica Quântica é um ramo da física que lida com o comportamento da matéria e da energia na escala de átomos e partículas subatômicas. É fundamental para o entendimento das forças da natureza, exceto a gravidade. Além disso, é a base de diversos ramos da física, incluindo eletromagnetismo, física de partículas, física da matéria condensada, e até mesmo partes da cosmologia. Também é essencial para a teoria das ligações químicas, biologia estrutural e tecnologias como a eletrônica, tecnologia da informação e nanotecnologia.

A Teoria Quântica foi elaborada durante as primeiras décadas do século XX, é considerada o maior avanço da física do século XX, tendo representado o que se costuma chamar de uma revolução científica. Ela surgiu meio à necessidade de se explicar certos fenômenos físicos que a física clássica não era capaz de explicar.

A teoria que surgia mostrava comportamentos estranhos da natureza. O primeiro com o qual os cientistas depararam foi o fato de algumas grandezas físicas, que até então só apresentavam valores contínuos, como a energia, passarem a apresentar valores discretos. Isso motivou o nome teoria quântica, pois a palavra “quantum” em latim significa quantidade e dessa forma, foi usada para designar as unidades discretas das grandezas que deixavam de se comportar como contínuas.

As principais idéias da Teoria Quântica são: dualidade onda partícula, princípio da incerteza de Heisenberg, superposição de estados, e emaranhamento de estados quânticos (EISBERG e RESNICK, 1983). Essas duas últimas são em especial exploradas na implantação de computadores e algoritmos quânticos, permitindo com suas características vantagens em relação aos computadores e algoritmos clássicos.

2.1.2. Superposição de estados.

Na Mecânica Quântica, é possível que uma partícula esteja em dois ou mais estados ao mesmo tempo (EISBERG e RESNICK, 1983). De forma ilustrativa pode-se dizer que ao jogar uma “moeda quântica” para cima, o resultado poderia ser cara, coroa, ou qualquer superposição destes estados; ou seja, a moeda poderia cair com as duas faces para cima.

No entanto, se um determinado objeto quântico estiver em mais de um estado simultaneamente, ao medi-lo ele irá colapsar em um dos seus estados sobrepostos e permanecer neste estado medido. Uma vez realizada a medida o outro estado deixa de existir, ou seja, não é possível conhecer todos os estados sobrepostos.

Isso levou Erwin Schrödinger, a elaborar um experimento mental denominado “o gato de Schrödinger”. Neste experimento um gato é colocado em uma caixa lacrada, juntamente com um dispositivo que contém uma pequena quantidade de substância radioativa. Há 50% de chance que um dos átomos da substância decaia em uma hora. Se um átomo decair, o dispositivo faz com que se quebre um frasco contendo substância venenosa, matando o gato. Se o átomo não decair, o gato permanece vivo. Aplicando as leis da Mecânica Quântica ao gato, sem abrir a caixa ele não estaria nem morto nem

vivo, mas numa superposição destes estados: morto e vivo, ao mesmo tempo. Somente quando a caixa fosse aberta, e a situação do gato fosse medida, é que seu estado se colapsaria em “morto” ou “vivo”. Ele queria mostrar que a teoria estava incompleta e que não existiam os estados sobrepostos, apenas uma probabilidade de eles ocorrerem. No entanto, uma equipe liderada por Lukens e Friedman conseguiu comprovar com um experimento a existência de dois estados quânticos sobrepostos, sem medi-los. A sobreposição de estados é o responsável pelo paralelismo dos computadores quânticos (ALVES, 2003, OLIVEIRA *et. al.*, 2004).

2.2. Computação Quântica

2.2.1. Introdução

Um computador quântico é em princípio, um dispositivo que usa leis da Teoria Quântica para processar a informação, sua principal vantagem é o chamado “paralelismo quântico”, este é baseado numa das principais propriedades da Mecânica Quântica, a superposição e interferência de estados distintos.

Os computadores clássicos codificam a informação através de uma sequência de bits, que assumem os valores zeros e uns. Esses dois dígitos formam a base binária, que permite expressar qualquer número inteiro. Os bits, são processados por dispositivos eletrônicos que permitem a realização de operações básicas, em termos dos quais qualquer computação pode ser realizada.

Diferente de um computador clássico, um computador quântico é um dispositivo que executa cálculos fazendo uso direto de propriedades da Mecânica Quântica. Dessa forma, processa a informação através de bits quânticos, mais comumente chamados de Q-bits. Um Q-bit pode conter um "1", um "0" ou uma sobreposição destes. Em outras palavras, pode conter tanto um "1" como um "0" ao mesmo tempo.

Um registrador clássico de 8 bits pode armazenar um número de 0 a 255. Um registrador quântico de 8 Q-bits, não só pode armazenar os mesmo números de 0 a 255,

mas todos eles simultaneamente. Essa característica, conhecida como paralelismo quântico, mostra que a memória de um computador quântico é exponencialmente maior que sua memória física (ALVES, 2003). Isso sugere um possível ganho exponencial de velocidade dos computadores quânticos sobre os clássicos.

O interesse pela computação quântica teve início quando Feynman em 1982, apontou que sistemas clássicos não seriam capazes de modelar eficientemente os sistemas quânticos e, que estes só poderiam ser modelados utilizando um sistema quântico. Feynman sugeriu que computadores baseados nas leis da Mecânica Quântica ao invés das leis da física clássica poderiam ser usados para modelar sistemas quânticos. (OLIVEIRA *et. al.*, 2004)

Deutsch, (DEUTSH, 1985), foi o primeiro a levantar o questionamento de uma real maior capacidade de processamento dos computadores quânticos em relação aos computadores clássicos em 1985. Com esta questão, ele estendeu a teoria da computação, ainda mais, com o desenvolvimento dos conceitos de um computador quântico universal e da máquina quântica de Turing. Foi ele também o primeiro a publicar um algoritmo quântico, conhecido como: “O Problema de Dois Bits de Deutsch”, em 1989. Até 1990, a computação quântica era apenas uma curiosidade.

Em 1994 Peter Shor (SHOR, 1994), construiu um algoritmo que permitia a um computador quântico fatorar números inteiros rapidamente. Ele resolve tanto o problema da fatoração quanto o problema de logaritmo discreto. Com esse algoritmo, um número seria fatorado muito mais rapidamente do que com as máquinas clássicas e por isso ficou conhecido como “*Killer application*”. O algoritmo de Shor poderia, em teoria, quebrar muitos dos sistemas criptográficos em uso atualmente. Essa descoberta criou um enorme interesse pelos computadores quânticos, até fora da comunidade acadêmica.

A partir desse interesse, surgiram outros algoritmos quânticos, tais como o algoritmo para logaritmos discretos de Shor, e o de fatoração de Jozsa. Enquanto o número de algoritmos quânticos crescia, os esforços no sentido de produzir um hardware quântico também aumentavam. Técnicas como ressonância nuclear magnética

(NMR) e armadilha de íons são usadas com sucesso no desenvolvimento de sistemas com 3 e 5 Q-bits.(SCIENTIFIC AMERICAN, 2006).

Atualmente, o computador quântico mais desenvolvido foi implementado na IBM por um grupo de pesquisadores liderados por Isaac Chuang, do MIT. O computador possui 7 átomos: cinco de flúor e dois de carbono, inseridos em uma molécula mais complexa. Com ele foi possível fatorar o número 15 utilizando-se o algoritmo de Shor. Para isso, utilizaram um frasco contendo 1018 dessas moléculas, que tiveram o movimento controlado por ondas de rádio. O computador quântico chegou aos números 3 e 5 (CHRISTOFOLETTI e MELO, 2003).

2.2.2. Bit quântico (Q-bit)

Nos computadores clássicos as informações são codificadas através de uma sequência de bits, que podem assumir os valores 0 ou 1. Diferente de um computador clássico, o computador quântico processa a informação através de um conjunto de bits quânticos, chamados de Q-bits. Dessa forma, os valores 0 e 1 de um bit são substituídos pelos vetores $|0\rangle$ e $|1\rangle$, representados por:

$$|0\rangle = \begin{bmatrix} 1 \\ 0 \end{bmatrix} \quad e \quad |1\rangle = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

A diferença entre um bit e um Q-bit é que um Q-bit genérico $|\psi\rangle$ pode também ser representado como uma combinação linear dos vetores $|0\rangle$ e $|1\rangle$, ou seja,

$$|\psi\rangle = \alpha|0\rangle + \beta|1\rangle \tag{1}$$

onde, α e β são números complexos, que satisfazem :

$$|\alpha|^2 + |\beta|^2 = 1 \tag{2}$$

A equação (1) apresenta um estado genérico do Q-bit que pode ser parametrizado por ângulos θ e φ , fazendo-se $\alpha = \cos(\theta/2)$ e $\beta = e^{i\varphi} \sin(\theta/2)$, a equação (1), pode ser escrita como:

$$|\psi\rangle = \cos(\theta/2)|0\rangle + e^{i\varphi} \sin(\theta/2)|1\rangle \quad (3)$$

Esta representação permite que o estado de um Q-bit seja visualizado como um ponto sobre a superfície de uma esfera de Bloch (PORTUGAL *et al.*, 2004). (Figura 2.1)

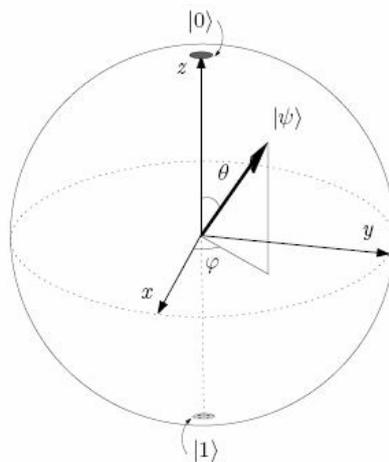


Figura 2.1. Esfera de Bloch

Em Mecânica Quântica, vetor é também chamado de estado. Dessa forma, a interpretação física do Q-bit, em (1) é que ele está simultaneamente nos estados $|0\rangle$ e $|1\rangle$. Na Mecânica Quântica essa capacidade de estar simultaneamente em dois, ou mais estados é conhecida como superposição de estados quânticos. Isso faz com que a quantidade de informação que pode ser armazenada no estado $|\psi\rangle$ seja infinita.

Para tornar a informação $|\psi\rangle$ acessível, no nível clássico, é necessário que se faça uma medida. Essa medida tem como resultado probabilístico um único valor contido na superposição. A superposição que existia antes é irreversivelmente alterada

(e perda). Em resumo, apesar de existir uma superposição de estados, quando se faz uma observação de um estado, o mesmo se colapsa para um único estado.

Assim, quando é feita a medida de $|\psi\rangle$ é possível encontrar ou o estado, $|0\rangle$ com probabilidade $|\alpha|^2$, ou o estado $|1\rangle$, com probabilidade $|\beta|^2$.

Um conjunto de N Q-bits pode ser colocado, em uma superposição de 2^N estados, cada um desses estados correspondendo a certos Q-bits no estado $|0\rangle$ e outros no estado $|1\rangle$: (000...0), (100...0), (010...0), (111...0), ... (111...1). Esses estados codificam todos os números possíveis de serem representados por N bits. Isso permite aplicar uma operação física que corresponderia a um cálculo computacional, simultaneamente a todas as entradas possíveis, realizando-se assim, uma computação em paralelo.

2.3. ALGORITMOS EVOLUCIONÁRIOS

2.3.1. Introdução

Os algoritmos evolucionários englobam um conjunto de métodos computacionais inspirados nos mecanismos evolutivos encontrados na natureza. Esses mecanismos estão diretamente relacionados com a Teoria da Evolução das Espécies (DARWIN,1859), onde afirma que a vida na Terra é o resultado de um processo de seleção feito pelo meio ambiente, em que somente os mais aptos e adaptados possuirão chances de sobreviver e, conseqüentemente, reproduzir-se. Dessa forma, os algoritmos evolucionários possuem auto organização e comportamento adaptativo, seus elementos chaves são: população de indivíduos; noção de aptidão, ciclo de nascimento e morte baseados na aptidão e noção de herança.

Os primeiros passos dados na área da Computação Evolucionária (COELHO, 2008) foram de biólogos e geneticistas. Estes tinham interesse em simular os processos vitais de um ser humano em um computador. Dentre os cientistas destacam-se os nomes

de Barricelli, Fraser, Martin e Cockerham. Na década de 60, um grupo de cientistas, em que o nome de Holland se destaca, iniciaram um estudo em que era implementada uma população de n indivíduos onde cada um possuía seu genótipo e estava sujeito a operações de seleção, mutação e recombinação. Tal estudo foi modelado e passou a ser conhecido como Algoritmo Genético (GOLDBERG, 1989).

2.3.2. AG – Algoritmos Genéticos

Os algoritmos genéticos (AG) são uma família de modelos computacionais de otimização, inspirados no mecanismo de evolução das espécies de Darwin. Foi desenvolvido por John Holland, em 1975 e popularizado por David Goldberg em 1989.

Os AG, normalmente, incorporam uma solução potencial para um problema específico numa estrutura semelhante à de um cromossomo, representado por um *string* binário. Cada cromossomo, chamado de indivíduo no AG, corresponde a um ponto no espaço de soluções do problema de otimização. O processo de solução adotado nos algoritmos genéticos consiste em gerar, através de regras específicas, um grande número de indivíduos (população), de forma a promover uma varredura tão extensa quanto necessária do espaço de soluções. Um cromossomo pode conter um ou mais genes (subseqüências), que representem, de forma codificada, características do problema em questão.

Os principais conceitos do AG são:

- *cromossomo (genótipo)* - cadeia de bits que representa uma solução possível para o problema;
- *gene* - representação de cada parâmetro de acordo com o alfabeto utilizado (binário, inteiro ou real);
- *fenótipo* – cromossomo decodificado
- *população* - conjunto de pontos (indivíduos) no espaço de busca

- *geração* - iteração completa do AG que gera uma nova população
- *aptidão bruta* - saída gerada pela função objetivo para um indivíduo da população
- *aptidão normalizada* - aptidão bruta normalizada, entrada para o algoritmo de seleção.
- *aptidão máxima* - melhor indivíduo da população corrente
- *aptidão média* - aptidão média da população corrente

Uma vez definida a codificação genética do problema a ser resolvido, o AG gera as possíveis soluções candidatas (população inicial). A população inicial evolui, para um conjunto de indivíduos mais aptos que representarão à solução ótima procurada. A avaliação de cada indivíduo é feita através de uma função objetivo, chamada de aptidão. Os indivíduos mais aptos têm a tendência de sobreviverem e os menos aptos de desaparecerem.

Uma das vantagens de um algoritmo genético é a simplificação que eles permitem na formulação e solução de problemas de otimização. AG's simples normalmente trabalham com descrições de entrada formadas por cadeias de bits de tamanho fixo. AG's possuem um paralelismo implícito decorrente da avaliação independente de cada uma dessas cadeias de bits, ou seja, pode-se avaliar a viabilidade de um conjunto de parâmetros para a solução do problema de otimização em questão. O AG é indicado para a solução de problemas de otimização complexos, NP-Completo, como o da recarga do reator nuclear (CHAPOT *et. al.*, 1999), e o problema de identificação de acidentes de uma usina nuclear que envolve um grande número de variáveis e, conseqüentemente, espaços de soluções de dimensões elevadas (PEREIRA *et. al.*, 1998, SCHIRRU *et. al.*, 1997). Além disso, em muitos casos onde outras estratégias de otimização falham na busca de uma solução, os AG's convergem de forma eficiente para o ótimo global.

Uma implementação de um algoritmo genético começa com uma população aleatória de cromossomos. Essas estruturas são, então, avaliadas e associadas a uma

probabilidade de reprodução de tal forma que as maiores probabilidades são associadas aos cromossomos que representam uma melhor solução para o problema de otimização do que àqueles que representam uma solução pior. A aptidão da solução é tipicamente definida com relação à população corrente.

A função objetivo de um problema de otimização é construída a partir dos parâmetros envolvidos no problema. Ela fornece uma medida da proximidade da solução em relação a um conjunto de parâmetros. Os parâmetros podem ser conflitantes, ou seja, quando um aumenta o outro diminui. O objetivo é encontrar o ponto ótimo. A função objetivo permite o cálculo da aptidão bruta de cada indivíduo, que fornecerá o valor a ser usado para o cálculo de sua probabilidade de ser selecionado para reprodução.

A estrutura básica do algoritmo genético (pseudocódigo) é mostrada na figura 2.2,

```
gerar a população inicial.  
  
avaliar cada indivíduo da população.  
  
enquanto critério de parada não for satisfeito faça  
  
    selecionar os indivíduos mais aptos.  
  
    criar novos indivíduos aplicando os operadores cruzamento e mutação.  
  
    armazenar os novos indivíduos em uma nova população.  
  
    avaliar cada cromossomo da nova população.  
  
fim
```

Figura 2.2. Pseudocódigo de um AG simples

Observa-se na figura 2.2, que cada iteração do algoritmo genético corresponde à aplicação de um conjunto de quatro operações básicas: cálculo de aptidão, seleção, cruzamento e mutação. Ao fim destas operações cria-se uma nova população, chamada de geração, onde, espera-se que ela represente uma melhor aproximação da solução do problema de otimização que a população anterior. A população inicial é gerada atribuindo-se aleatoriamente valores aos genes de cada cromossomo. A aptidão bruta de um indivíduo da população é medida pela função aptidão. A aptidão bruta é em seguida normalizada (aptidão normalizada), para permitir um melhor controle do processo de seleção. Como critérios de parada do algoritmo em geral são usados a aptidão do melhor indivíduo em conjunto com a limitação do número de gerações. Outros critérios podem envolver, por exemplo, um erro abaixo de um valor especificado pelo projetista para um determinado parâmetro do problema.

Um dos métodos mais usados para implementar o processo de seleção é conhecido como método da roleta (GOLDBERG, 1989). Nele cada indivíduo ocupa, em uma roleta, uma área proporcional ao valor de sua aptidão. Desta forma, obtém-se uma aptidão relativa que pode ser interpretada como a probabilidade de seleção de um indivíduo, dada por:

$$P_{seleção}(I_k) = \frac{f_{I_k}}{\sum_j^N f_{I_j}} \quad (4)$$

onde, I_k é o k -ésimo indivíduo da população, f_{I_k} é a aptidão deste indivíduo e N é número de indivíduos da população.

O processo de cruzamento tem a função de combinar e/ou perpetuar material genético (bits) dos indivíduos mais aptos, criando novos indivíduos, misturando características de dois ou mais indivíduos pais, que levam estas características para as próximas gerações. Este processo pode ser implementado de vários modos, sendo os mais comuns o cruzamento de um ponto e o cruzamento de dois pontos.

No cruzamento de um ponto, é feita uma escolha randômica de um ponto de cruzamento sobre a sequência de bits que representa o genótipo, seguida da troca de partes entre eles. Este procedimento é mostrado no exemplo abaixo.

□ Pai 1: 1010101011 | 0101010111

□ Filho 1: 10101010110101110010

□ Pai 2: 0000100101 | 0101110010

□ Filho 2: 00001001010101010111

No cruzamento de dois pontos, há uma escolha randômica de dois pontos de corte no genótipo, seguida da troca de parte central entre os dois genótipos operando, conforme o exemplo abaixo:

□ Pai 1: 101010 | 101101 | 01010111

□ Filho 1: 000010 | 101101 | 01110010

□ Pai 2: 000010 | 010101 | 01110010

□ Filho 2: 101010 | 010101 | 01010111

A operação de mutação é utilizada para garantir uma maior varredura do espaço de estados e evitar que o algoritmo genético convirja prematuramente para mínimos locais. A mutação é efetuada alterando-se o valor de um gene de um indivíduo sorteado aleatoriamente com uma determinada probabilidade de mutação, ou seja, vários indivíduos da nova população podem ter um de seus genes alterados aleatoriamente. O exemplo abaixo ilustra tal mecanismo.

□ Antes da mutação: 10101010110101



□ Depois da mutação: 1010100110101

Em uma população de estruturas simbólicas, percebe-se que certos padrões possuem prêmios mais altos. Estes padrões tendem a aumentar sua representatividade de geração para geração, seguindo um teorema que se baseia nas probabilidades de “sobreviverem” ao cruzamento e mutação, que alteram a estrutura.

Um grupo de padrões que representam determinada classe de indivíduos e chamado de esquemas ou modelo de similaridade, daí o nome de Teoria de Esquemas aplicado à teoria matemática, que dá origem ao Teorema Fundamental dos Algoritmos Genéticos.

A inequação 5 é o Teorema Fundamental dos Algoritmos Genéticos que rege a evolução dos esquemas considerando os processos de seleção, cruzamento e mutação de um AG.

$$m(H, t + 1) \geq m(H, t) \cdot \frac{f(H)}{\bar{f}} \cdot \left[1 - p_c \cdot \frac{\delta(H)}{l-1} - o(H) \cdot p_m \right] \quad (5)$$

onde, $m(H, t)$ é número m de indivíduos pertencente ao esquema H , no tempo t , $f(H)$ é o prêmio, \bar{f} é o prêmio médio da população, p_c é a taxa de cruzamento, l é o comprimento da cadeia de bits, $o(H)$ é a ordem do esquema, $\delta(H)$ é o tamanho do esquema e p_m é a probabilidade de mutação, considerando um ponto de corte.

Dentro desta formulação, o algoritmo genético não pode ser classificado como um método de busca aleatória, mas sim como um método de busca dirigida por esquemas que melhoram a solução do problema (GOLDBERG, 1989).

2.4. INTELIGÊNCIA DE ENXAMES

2.4.1. Introdução

A inteligência de enxames é uma técnica computacional, desenvolvida no final da década de 1980. Foi baseada no comportamento coletivo auto-organizado de sistemas descentralizados, constituído de um número elevado de agentes, com o objetivo de realizar uma determinada tarefa.

O termo “enxame” (ou coletivo) é utilizado de forma genérica para se referir a qualquer coleção estruturada de agentes capazes de interagir. O exemplo clássico de um enxame é um enxame de abelhas. Entretanto, a metáfora de um enxame pode ser estendida a outros sistemas com uma arquitetura similar. Uma revoada de pássaros é um enxame, onde os agentes são pássaros, um cardume de peixes é um enxame, onde os agentes são peixes e, assim por diante. Assim, inclui qualquer tentativa de projetar

algoritmos ou dispositivos de solução de problemas, inspirados no comportamento coletivo de insetos sociais e outras sociedades animais (BONABEAU *et al.*, 1999).

As principais propriedades de um sistema baseado no comportamento coletivo de enxames são:

- *proximidade*: os agentes interagem entre si;
- *qualidade*: os agentes avaliam seus comportamentos;
- *diversidade*: permitem ao sistema reagir a situações inesperadas;
- *estabilidade*: nem todas as variações ambientais afetam o comportamento de um agente;
- *adaptabilidade*: se adequar a variações ambientais.

Sendo assim, um sistema de enxame é aquele composto por um conjunto de agentes capazes de interagir entre si e com o meio ambiente. A Inteligência de Enxame é uma propriedade emergente de um sistema coletivo que resulta de seus princípios de proximidade, qualidade, diversidade, estabilidade e adaptabilidade

Um dos principais algoritmos de inteligência de exames é o PSO (*Particle Swarm Optimization*) baseado no comportamento de bando de pássaros e cardumes de peixes, quando em busca de alimento em uma determinada região.

2.4.2. PSO – Particle Swarm Optimization

A otimização por Enxames de Partículas, do inglês *Particle Swarm Optimization* (PSO) é um algoritmo de computação evolucionária baseado em inteligência de exames, criado por Kennedy e Eberhart em 1995. É uma técnica de otimização estocástica baseada em populações, que implementa a metáfora do comportamento social da interação de bandos de pássaros e cardumes de peixes em busca de alimento em uma determinada região.

Assim como o AG, é inicializado por uma população de soluções randômicas que buscam o ótimo através da atualização das gerações. Não exige conhecimento prévio sobre o espaço de busca nem sobre a existência de limites e derivadas da função objetivo ou das funções de restrição, bastando para sua aplicação a existência de uma função de avaliação dos indivíduos da população. Porém, ao contrário do AG, onde o aprendizado do algoritmo é feito através dos operadores de cruzamento e mutação, no PSO o aprendizado do algoritmo é feito através de equações de velocidade e posição.

No PSO cada partícula corresponde a um ponto do espaço de solução do problema que é avaliada a cada iteração do algoritmo de acordo com uma função objetivo. Cada indivíduo, representado como um vetor de números de dimensão igual à dimensão do espaço de busca, é inicializado com uma posição e velocidade aleatórias, e guarda consigo informação sobre a melhor posição por ele já visitada. Por outro lado, o algoritmo guarda a melhor posição já alcançada pelo enxame. A cada iteração os indivíduos da população são avaliados e as melhores posições de cada indivíduo e do enxame são armazenadas.

A velocidade de cada partícula (V_i) é modificada considerando basicamente duas informações (componentes): a primeira é o melhor local por onde já passou durante toda sua história (sua melhor posição, $pbest$); e a segunda é a posição da melhor partícula (componente social, $gbest$) eleita a cada passo de geração, ou seja, a trajetória de cada indivíduo no espaço de busca é ajustada dinamicamente alternando a velocidade de cada partícula de acordo com a própria experiência de busca e a experiência de busca de outras partículas no espaço. O que pode ser observado na figura 2.3.

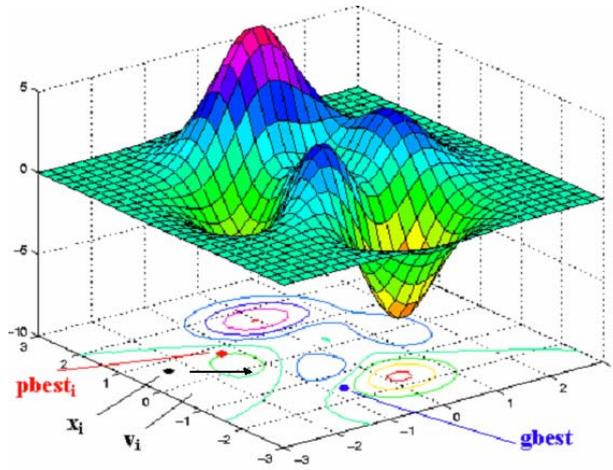


Figura 2.3: Atualização de uma partícula no PSO simples

Seja, $X_i = \{x_{i_1}, x_{i_2}, \dots, x_{i_d}\}$ e $V_i = \{v_{i_1}, v_{i_2}, \dots, v_{i_d}\}$, a posição e a velocidade da i -ésima partícula, respectivamente em um espaço de busca d -dimensional. Cada partícula carrega consigo a informação da sua melhor posição ($pbest$), $P_b = \{p_{b_1}, p_{b_2}, \dots, p_{b_d}\}$ alcançada dentro do tempo t e a informação da posição da melhor partícula ($gbest$) encontrada dentro do enxame até o instante t , e eleita a cada passo de geração.

As equações de atualização da velocidade e da posição das partículas são descritas pelas equações (6) e (7), respectivamente. Na equação (6) a nova velocidade da partícula é calculada pela diferença entre a melhor posição individual da partícula ($pbest$) e sua posição atual e, pela diferença entre a posição da melhor partícula do grupo ($gbest$) e a posição atual da partícula.

$$v_{ij}(t+1) = wv_{ij}(t) + c_1r_1(pbest(t)_{ij} - x_{ij}(t)) + c_2r_2(gbest(t)_j - x_{ij}(t)), \quad j = 1, 2, \dots, d \quad (6)$$

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1), \quad j = 1, 2, \dots, d \quad (7)$$

Dessa forma o vetor velocidade é ajustada através da distância euclidiana, entre os vetores os vetores X_i e $pbest$, e X_i e $gbest$ como ilustra a figura 2.4.

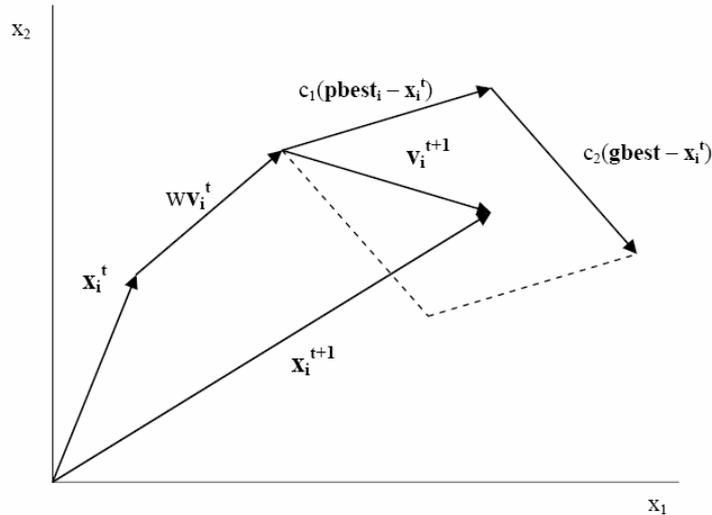


Figure 2.4: Atualização das partículas no PSO simples.

O fator momento (peso de inércia, w) estabelece o compromisso entre diversidade e refinamento de busca, onde valores maiores do momento favorecem buscas abrangentes e valores menores favorecem o refinamento da busca, dessa forma, controla o grau de refinamento de busca do algoritmo. Seu valor pode ser fixo ou cair linearmente. A força de atração do algoritmo é dada através das constantes c_1 e c_2 . Sendo assim, são os coeficiente de aceleração pessoal e global, respectivamente, e influenciam no tamanho máximo do passo que uma partícula pode dar em uma iteração, acelerando o deslocamento das partículas. Os fatores randômicos r_1 e r_2 , distribuídos no intervalo $[0,1]$, são variáveis aleatórias que permitem manter a diversidade da população e retardam a convergência prematura para pontos não ótimos, além disso, representam o componente estocástico do algoritmo.

Se, $pbest$ for diferente de $gbest$, o ponto de atração muda de interação para interação mesmo que não ocorram melhores soluções, ou seja, mesmo que $pbest$ e $gbest$ permaneçam constantes.

A estrutura básica (pseudocódigo) do PSO é apresentada na figura 2.5.

```

inicializar  $x(i,j)$  e  $v(i,j)$  randomicamente.
repetir até critério de parada

    para cada partícula  $i$  da população faça

        se  $f(x_i(t)) < f(pbest(i))$  então  $pbest(t) = x_i(t)$ 
        se  $f(pbest(t)) < f(gbest(t))$  então  $gbest(t) = pbest(t)$ 

    fim para

atualizar  $v(i,j)$  e  $x(i,j)$  de cada partícula de acordo com as
equações (6) e (7), respectivamente.

```

Figure 2.5: Pseudocódigo de um PSO simples.

Em suma, pode-se dizer que a estratégia de procura por ótimos no PSO é simples. Usam-se basicamente operadores aritméticos triviais em suas estruturas. A partir desta simplicidade, bons resultados conseguem ser obtidos em diversos tipos de funções contínuas, inclusive as multimodais. (PARSSOPOULOS *et. al.*, 2002).

CAPÍTULO 3

ALGORITMOS DE OTIMIZAÇÃO COM INSPIRAÇÃO QUÂNTICA

Neste capítulo serão apresentados dois algoritmos quânticos de otimização: o QEA (*Quantum Evolutionary Algorithm*) e o QSE (*Quantum Swarm Evolutionary*). Esses algoritmos são clássicos, ou seja, são executados em computadores clássicos, porém utilizam os principais recursos da Computação Quântica, a superposição e interferência de estados quânticos.

3.1. Introdução

Embora a Computação Quântica ofereça uma boa promessa em termos de capacidade de processamento, dois problemas impedem atualmente, que a mesma se torne uma ferramenta útil: a dificuldade de se implementar um computador quântico e a dificuldade de se criar algoritmos que tirem proveito da capacidade de processamento destes computadores.

No entanto, em MOORE (1995), uma nova abordagem é proposta. Ao invés de desenvolver novos algoritmos para computadores quânticos ou de tentar viabilizar o uso destes, a idéia de processamento em paralelo é apresentada. O objetivo desta nova abordagem é criar algoritmos clássicos que tirem proveito dos paradigmas da Teoria Quântica, de forma a melhorar seu desempenho na resolução de problemas computacionais.

MOORE (1995) apresenta uma metodologia para a formulação inicial de um algoritmo com inspiração quântica, esta metodologia consiste dos seguintes passos:

1. O problema deve ter uma representação numérica ou, caso não tenha, um método para sua conversão em representação numérica deve ser empregado;
2. A configuração inicial deve ser determinada;

3. Uma condição de parada deve ser definida;
4. O problema deve poder ser dividido em subproblemas menores;
5. O número de universos (ou estados de superposição) deve ser identificado;
6. Cada subproblema deve ser associado a um dos universos;
7. Os cálculos nos diferentes universos devem ocorrer de forma independente;
8. Alguma forma de iteração entre os múltiplos universos deve existir. Esta interferência deve, ou permitir encontrar a solução para o problema, ou fornecer informação para que cada subproblema possa em cada universo ser capaz de encontrá-la.

Neste contexto surgem os algoritmos de otimização com inspiração quântica. Por se tratarem de algoritmos de otimização, procuram encontrar os pontos que maximizem (ou minimizem) uma dada função matemática, ou o melhor desempenho de um sistema com base nos principais conceitos da Teoria Quântica.

No presente capítulo serão apresentados dois algoritmos de otimização com inspiração quântica: o QEA, proposto por HAN *et.al.*, (2002) e o QSE proposto por YAN WANG *et. al.*, (2007).

O QEA foi construído com base nos principais conceitos da Computação Quântica, o bit quântico (Q-bit) e a superposição de estados. Assim como o AG é caracterizado por um cromossomo, uma função de avaliação e uma dinâmica populacional. Entretanto, ao invés de uma representação binária convencional, utiliza uma representação especial que simula um cromossomo formado por Q-bits, definido por $[\alpha, \beta]$. Além disso, o aprendizado do QEA é feito através de um operador variação, chamado de portão quântico (Q-gate), que promove a atualização individual do Q-bit.

O QSE utiliza-se basicamente da mesma estrutura quântica do QEA, porém o Q-bit usado como representação de probabilidades, é definido por $[\cos\theta, \sin\theta]$. Além disso, o aprendizado do algoritmo é baseado nas equações de velocidade (6) e posição (7) do PSO, apresentados no capítulo 2 deste trabalho.

3.2. QEA – Quantum Evolutionary Algorithm

O QEA é um modelo de algoritmo evolutivo com inspiração quântica, proposto por HAN, (2002). Esse modelo, assim como o AG, é caracterizado por um cromossomo, uma função avaliação e uma dinâmica populacional. Entretanto, ao invés de uma representação binária convencional, utiliza uma representação especial formada por bits quânticos (Q-bits) definido por um par de números (α, β) , que satisfaz $|\alpha|^2 + |\beta|^2 = 1$. O valor dado por $|\alpha|^2$, indica a probabilidade do Q-bit assumir o valor 0 quando for observado e o valor $|\beta|^2$, indica a probabilidade do Q-bit assumir o valor 1 quando for observado. Esta relação entre α e β pode ser visualizada graficamente na figura 3.1.

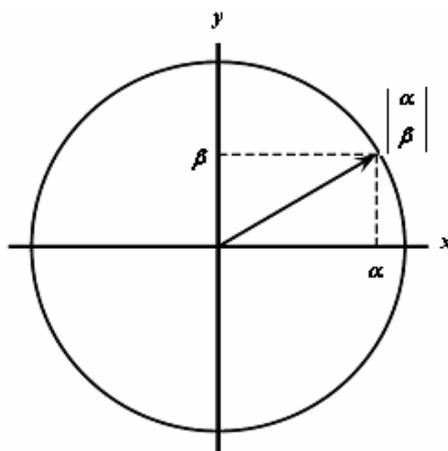


Figura 3.1: Representação gráfica de um círculo de raio unitário com as amplitudes de probabilidade de se observar os valores 0 e 1 para um Q-bit qualquer, no caso em que α e β são reais.

Deste modo, cada indivíduo no QEA representa uma superposição de indivíduos formados por m-Q-bits, definidos por: uma população $Q(t) = \{q_1(t), q_2(t), \dots, q_n(t)\}$, na geração t ; onde n é o tamanho da população, e $q_j(t)$ é o j-ésimo indivíduo da população representado por m-Q-bits, chamado neste trabalho de IndivíduoQ-bit,:

$$q_j(t) = \left[\begin{array}{c|c|c|c} \alpha_{j1}(t) & \alpha_{j2}(t) & \dots & \alpha_{jm}(t) \\ \beta_{j1}(t) & \beta_{j2}(t) & \dots & \beta_{jm}(t) \end{array} \right] \quad (8)$$

Onde m é o número de Q-bits, e j representa um IndivíduoQ-bit da população. Seja por exemplo, um IndivíduoQ-bit formado por 3 Q-bits definido por:

$$q_j(t) = \left[\begin{array}{c|c|c} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & \frac{1}{2} \\ \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} & \frac{\sqrt{3}}{2} \end{array} \right] \quad (9)$$

Para se calcular a amplitude de probabilidade do estado $|000\rangle$, multiplica-se as amplitudes de probabilidade de se observar os estados 0 em cada um dos bits ($\alpha_{j1}(t), \alpha_{j2}(t)$ e $\alpha_{j3}(t)$). Para calcular a amplitude de probabilidade de se observar o estado $|001\rangle$, multiplica-se as amplitudes de probabilidade de se observar estes bits ($\alpha_{j1}(t), \alpha_{j2}(t)$ e $\beta_{j3}(t)$). Estendendo para outras possibilidades de observação dos estados, a superposição dos mesmos pode ser representada por:

$$\frac{1}{4}|000\rangle + \frac{\sqrt{3}}{4}|001\rangle - \frac{1}{4}|010\rangle - \frac{\sqrt{3}}{4}|011\rangle + \frac{1}{4}|100\rangle + \frac{\sqrt{3}}{4}|101\rangle - \frac{1}{4}|110\rangle - \frac{\sqrt{3}}{4}|111\rangle \quad (10)$$

Dessa forma, o resultado acima significa que cada um dos possíveis estados, do IndivíduoQ-bit, pode ser observado com as probabilidades apresentadas na tabela 3.1, abaixo.

Tabela 3.1. Probabilidades de observação de cada um dos possíveis estados do IndivíduoQ-bit.

| Estado | 000 | 001 | 010 | 011 | 100 | 101 | 110 | 111 |
|---------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|
| Probabilidade | $\frac{1}{16}$ | $\frac{3}{16}$ | $\frac{1}{16}$ | $\frac{3}{16}$ | $\frac{1}{16}$ | $\frac{3}{16}$ | $\frac{1}{16}$ | $\frac{3}{16}$ |

Sendo $Q(t)$ uma população com um ou mais IndivíduosQ-bits, temos que no passo de inicialização, estes IndivíduosQ-bits são inicializados com os valores de $\alpha_{ji}(t)$ e $\beta_{ji}(t)$ iguais a $\frac{1}{\sqrt{2}}$. Sendo assim, na geração inicial, todos os genes dos IndivíduosQ-bits terão a mesma probabilidade de gerarem os estados $|0\rangle$ ou $|1\rangle$.

Sendo, $P(t) = \{X_1(t), X_2(t), \dots, X_n(t)\}$, $X_j(t) = \{x_{j1}(t), x_{j2}(t), \dots, x_{jm}(t)\}$, onde cada $x_{ji}(t)$ representa o bit num determinado instante t, e $B(t) \subset X_j$. O pseudocódigo do QEA é apresentado abaixo:

```

iniciar
inicializar  $Q(0)$  at  $t = 0$ 
gerar  $P(0)$  observando os estados de  $Q(0)$ 
avaliar  $f(X_j(t))$ 
armazenar as melhores soluções de  $P(0)$  em  $B(0)$ 
enquanto não ocorrer a condição de parada
     $t = t + 1$ 
    gerar  $P(t)$  observando os estados de  $Q(t)$ 
    avaliar  $f(X_j(t))$ 
    atualizar  $Q(t)$  usando Q-gate  $U(t)$ 
    armazenar a melhor solução de  $P(t)$  em  $B(t)$ 
fim
fim

```

Figura 3.2: Pseudocódigo de um QEA simples

A estrutura $B(t)$ é usada para armazenar os melhores indivíduos gerados pelo algoritmo ao longo do processo evolutivo. Os dois últimos passos do algoritmo servem para armazenar os melhores indivíduos gerados na população atual com os melhores indivíduos criados nas gerações anteriores.

Cada bit $x_{ji}(t)$ do string binário é obtido observando o passo de construir a população $P(t)$. Quando observamos todos os estados de $Q(t)$, o valor $|x_{ji}|=0$ ou $|x_{ji}|=1$, de $P(t)$ é determinado pela probabilidade $|\alpha_{ji}|^2$ ou $|\beta_{ji}|^2$.

O Pseudocódigo de geração de $P(t)$ no QEA é determinado da seguinte forma:

```

Iniciar
j = 0;
enquanto (j < n) faça
    j = j + 1;
    i = 0
    enquanto (i < m) faça
        i = i + 1;

        se o randômico [0,1] >  $|\alpha_{ji}(t)|^2$ 
            então  $|x_{ji}(t)| = 1$ 
            senão  $|x_{ji}(t)| = 0$ 

    fim
fim
fim

```

Figura 3.3. Pseudocódigo de geração de $P(t)$ no QEA simples.

A atualização da população no QEA é realizada pelo operador portão quântico Q-gate, definido pela matriz de rotação $U(\Delta\theta_i)$:

$$U(\Delta\theta_i) = \begin{vmatrix} \cos(\xi(\Delta\theta_i)) & -\text{sen}(\xi(\Delta\theta_i)) \\ \text{sen}(\xi(\Delta\theta_i)) & \cos(\xi(\Delta\theta_i)) \end{vmatrix} \quad (11)$$

onde, $\xi(\Delta\theta_i) = S(\alpha_i, \beta_i) * \Delta\theta_i$, $S(\alpha_i, \beta_i)$ e $\Delta\theta_i$ representam a direção de rotação e o ângulo, respectivamente. O tamanho do passo $\Delta\theta_i$ deve ser concebido de acordo com o problema, porém não tem base teórica até o momento. (WANG *et. al.*, 2006)

Esta matriz deve ser usada para multiplicar cada uma das colunas do IndivíduoQ-bit, ou seja, os valores α_{ji} e β_{ji} são tratados como um vetor bidimensional e são rotacionados usando a matriz especificada. Em outras palavras, considerando-se o IndivíduoQ-bit $q_j(t) = \{(\alpha_{j1}(t), \beta_{j1}(t)), (\alpha_{j2}(t), \beta_{j2}(t)), \dots, (\alpha_{jm}(t), \beta_{jm}(t))\}$, a atualização deste indivíduo é feita da seguinte forma:

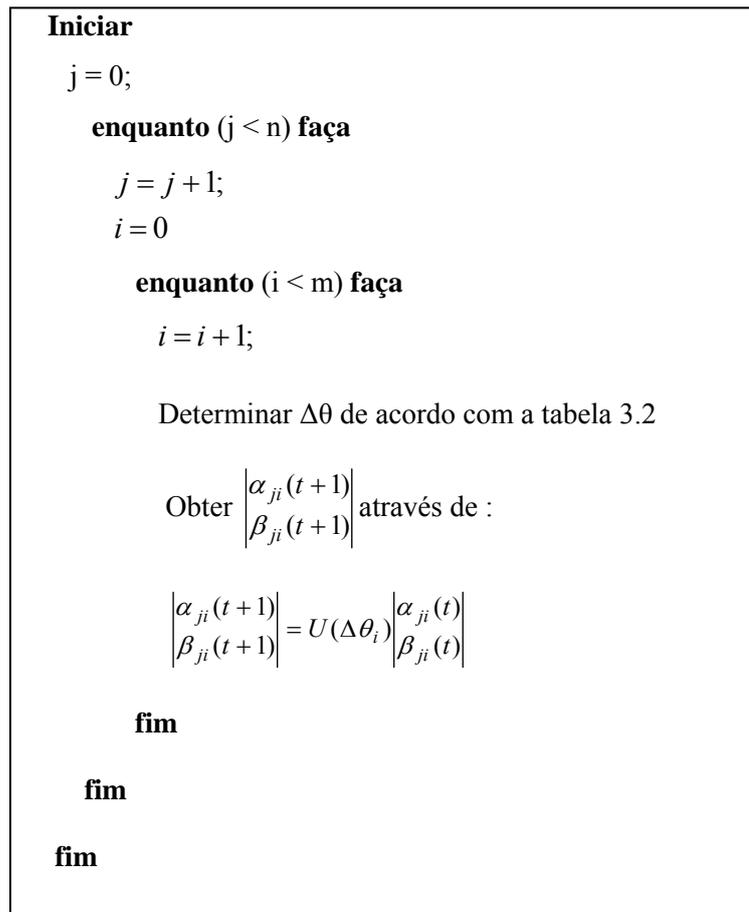


Figura 3.4. Pseudocódigo de atualização do Q-bit no QEA simples.

Os valores de $\Delta\theta_i$ são definidos no QEA através da tabela 3.2, abaixo. Esta tabela indica a direção de rotação do ângulo, considerando os valores de b_i (i-ésimo bit da melhor solução até o momento), x_i (solução binária x), $f(X)$ (aptidão de X), $\Delta\theta$ (rotação do ângulo que controla a velocidade de convergência), $S(\alpha_i, \beta_i)$ (função sinal que controla a direção de rotação) e Δ (o valor do incremento do ângulo). Por exemplo, quando $x_i=0$, $b_i=1$, $f(B)>f(X)$, onde $f(B)$ é a aptidão da melhor solução até o momento, para um problema de maximização, a probabilidade da solução $x_i=1$ deve ser incrementada de modo à obter um melhor cromossomo, ou seja, a probabilidade $|\beta_i|^2$ deveria ser maior.

Dessa forma, considerando uma esfera de raio 1, onde a abscissa representa o estado $|0\rangle$ e a ordenada o estado $|1\rangle$, onde (α_i, β_i) se encontram no primeiro quadrante, o sentido de rotação do portão quântico será o anti-horário, ou seja, no sentido do $|1\rangle$, e caso (α_i, β_i) se encontrem no terceiro quadrante, o sentido de rotação do portão quântico será o horário, ou seja, no sentido do $|0\rangle$. Tal situação é ilustrada da figura 3.5.

Table 3.2. Mudança do ângulo de rotação do QEA simples.

| x_i | b_i | $f(X)>f(B)$ | $\Delta\theta$ | $S(\alpha_i, \beta_i)$ | | | |
|-------|-------|-------------|----------------|------------------------|---------------------|--------------|-------------|
| | | | | $\alpha_i\beta_i>0$ | $\alpha_i\beta_i<0$ | $\alpha_i=0$ | $\beta_i=0$ |
| 0 | 0 | Falso | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | Verdade | 0 | 0 | 0 | 0 | 0 |
| 0 | 1 | Falso | Δ | 1 | -1 | 0 | ± 1 |
| 0 | 1 | Verdade | Δ | -1 | 1 | ± 1 | 0 |
| 1 | 0 | Falso | Δ | -1 | 1 | ± 1 | 0 |
| 1 | 0 | Verdade | Δ | 1 | -1 | 0 | ± 1 |
| 1 | 1 | Falso | 0 | 0 | 0 | 0 | 0 |
| 1 | 1 | Verdade | 0 | 0 | 0 | 0 | 0 |

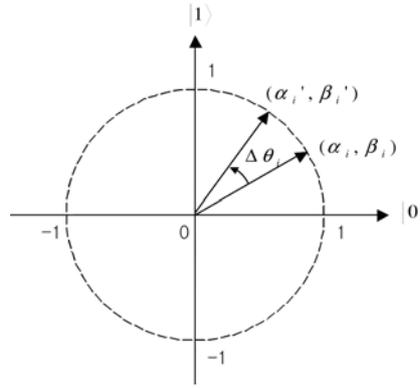


Figure 3.5. Rotação do portão quântico no QEA simples.

O algoritmo QEA foi usado com sucesso em problemas de otimização combinatória (HAN, 2000, HAN 2002), apresentando resultados superiores aos algoritmos genéticos convencionais em termos de tempo de convergência e qualidade das soluções encontradas. Vale ressaltar que o algoritmo QEA, até o momento, só foi usado em problemas de teste simples e em nenhuma aplicação real. Uma descrição mais detalhada deste algoritmo pode ser encontrada em (HAN, 2002).

3.3. QSE – Quantum Inspired Evolutionary

O QSE é um modelo de algoritmo com inspiração quântica proposto, por YAN WANG *et. al.*, (2007). É uma técnica de computação com inspiração quântica, baseada no comportamento auto organizado de um elevado número de agentes, chamados de enxame quântico, que interagem entre si com um objetivo final comum. A estrutura quântica deste modelo é baseada na estrutura do algoritmo QEA.

Ao contrário do QEA no QSE o Q-bit é definido por um ângulo θ arbitrário que carrega (α, β) simultaneamente. Esse ângulo é representado por um vetor $[\theta]$, de representação implícita $\begin{bmatrix} \cos(\theta) \\ \sin(\theta) \end{bmatrix}$, que satisfaz espontaneamente $|\sin \theta|^2 + |\cos \theta|^2 = 1$.

Assim como no QEA, a população do enxame quântico é definido por: $Q(t) = (q_1(t), q_2(t), \dots, q_n(t))$, onde o indivíduo Q-bit, definido por: $q_j(t)$, na geração t , é representado por:

$$q_j(t) = \left[\begin{array}{c|c|c} \alpha_1(t) & \alpha_2(t) & \dots & \alpha_m(t) \\ \beta_1(t) & \beta_2(t) & \dots & \beta_m(t) \end{array} \right], \text{ onde } j = 1, 2, \dots, m \quad (11)$$

substituído por:

$$q_j(t) = [\theta_1(t) | \theta_2(t) | \dots | \theta_m(t)] \quad (12)$$

Sendo, $P(t) = \{X_1(t), X_2(t), \dots, X_n(t)\}$, $B(t) \in X_j$ $X_j(t) = \{x_{j1}(t), x_{j2}(t), \dots, x_{jm}(t)\}$ e cada $x_{ji}(t)$ representa o bit num determinado instante t . O pseudocódigo do QSE simples, pode ser escrito como:

iniciar

inicializar $Q(0)$ at $t = 0$

gerar $P(0)$ observando os estados de $Q(0)$

avaliar $f(X_j(t))$

armazenar as melhores soluções de $P(0)$ em $B(0)$

enquanto não ocorrer a condição de parada

$t = t + 1$

gerar $P(t)$ observando os estados de $Q(t)$

avaliar $f(X_j(t))$

atualizar $Q(t)$ usando as equações 6 e 7 do PSO

armazenar a melhor solução de $P(t)$ em $B(t)$

fim

fim

Figura 3.6: Pseudocódigo de um QSE simples

Assim como no QEA a estrutura $B(t)$ é usada para armazenar os melhores indivíduos gerados no algoritmo ao longo da evolução do enxame.

O passo de gerar $P(t)$, observado $Q(t)$ no QSE é feito da seguinte forma:

```
início  
   $j = 0$ ;  
  enquanto ( $j < n$ ) faça  
     $j = j + 1$ ;  
     $i = 0$   
    enquanto ( $i < m$ ) faça  
       $i = i + 1$   
  
      se o randomico  $[0,1] > |\cos(\theta_{ji})|^2$   
  
        então  $|X_{ji}(t)| = 1$   
  
        senão  $|X_{ji}(t)| = 0$   
  
      fim se  
  
    fim enquanto  
  
  fim enquanto  
  
fim
```

Figure 3.7. Pseudocódigo de produção de $P(t)$, no QSE simples.

Diferente do QEA que utiliza um portão quântico para determinar a evolução do algoritmo, no QSE o aprendizado do enxame é feito utilizando-se as equações semelhantes as equações de velocidade (6) e posição (7) do PSO, descritas no capítulo 2 deste trabalho. Assim como, um indivíduo do enxame do PSO, um indivíduo Q-bit do enxame quântico no QSE carrega consigo duas principais informações: o melhor ângulo do seu histórico, e o melhor ângulo do histórico do enxame, encontrado até o momento.

Esse procedimento de aprendizado do algoritmo é representado pelas equações (14) e (15).

$$v_j(t+1) = \chi * (wv_{ji}(t) + c_1r_1 * (\theta_{ji}^{pbest}(t) - \theta_{ji}(t)) + c_2r_2 * (\theta_{ji}^{gbest}(t) - \theta_{ji}(t))) \quad (14)$$

$$\theta_{ji}(t+1) = \theta_{ji}(t) + v_{ji}(t+1) \quad (15)$$

Onde, χ , w , $v_{ji}(t)$, $\theta_{ji}(t)$, $\theta_{ji}^{pbest}(t)$, $\theta_{ji}^{gbest}(t)$ são o fator de constricção, o fator de inércia, a velocidade angular, o ângulo atual, o melhor ângulo individual e global. De tal forma que, $w > \frac{(c_1 + c_2)}{2} - 1$, onde $c_2 > c_1$, o que garante a convergência das partículas.

Comparando a equação (14) apresentada anteriormente, com a equação (6) do PSO (capítulo 2), observa-se que o fator de constricção (χ) (EBERHART *et. al.*, 2000), da equação (14), não aparece na equação (6). EBERHART *et. al.*, (2000) realizou testes com o PSO original (sem o fator de constricção) e com um variante do PSO (com o fator de constricção), e mostrou que o PSO com o fator de constricção converge para melhores resultados, do que o PSO original, além disso, mostra que o fator de constricção assegura a convergência do algoritmo.

Vale ressaltar que o algoritmo QSE, até o momento, só foi usado em problemas de teste simples e em nenhuma aplicação real. Mais detalhes sobre o algoritmo QSE podem ser encontrados em YAN WANG *et. al.*, (2006).

CAPÍTULO 4

OTIMIZAÇÃO DE FUNÇÕES CONTÍNUAS E DISCRETAS

Neste capítulo são apresentados os resultados dos testes realizados com os algoritmos quânticos de otimização, QEA e QSE, quando aplicados na otimização de funções contínuas e discretas. Inicialmente são apresentadas as funções de testes usadas nesta seção. A seguir é apresentada a modelagem do problema para a solução pelo QEA e QSE e, finalmente são apresentados os resultados obtidos com a aplicação do QEA e do QSE.

4.1. Introdução

O objetivo desta seção é verificar o desempenho do QSE e do QEA como ferramentas de otimização. Sendo assim, foram realizados testes com funções discretas e contínuas de ótimos bem conhecidos, essas funções tem sido comumente utilizadas como funções de teste de comparação entre algoritmos de otimização e diferentes versões tem aparecido na literatura.

Para testar o desempenho dos algoritmos QEA e QSE na otimização de funções contínuas de alta complexidade dimensional, utilizou-se a função Esfera e, na otimização de funções discretas utilizou-se o problema dos 4 picos.

4.2. Funções de teste

4.2.1. Funções contínuas

- **Função Rosenbrock - F2 D’Jong**

A função Rosenbrock tem sido comumente usada em outros trabalhos, como função de teste de comparação entre técnicas de otimização e dessa forma diferentes versões tem aparecido na literatura.

A função Rosenbrock é um problema de mínimo zero, que foi transformado, para um problema de máximo 3905.93. A função Rosenbrock foi escolhida com o propósito de avaliar os resultados obtidos neste trabalho, com outros encontrados na literatura. (CLERC M. et.al., 2002).

A fórmula e o espaço de busca da função Rosenbrock utilizada, nesta seção, é descrita pela equação (16), e sua forma é representada na figura 4.1, abaixo:

$$F(x,y) = 3905.93 - (100 * (x^2 - y)^2 + (1 - x)^2) \quad (16)$$
$$- 5.12 \leq x \leq 5.12 \quad e \quad - 5.12 \leq y \leq 5.12$$

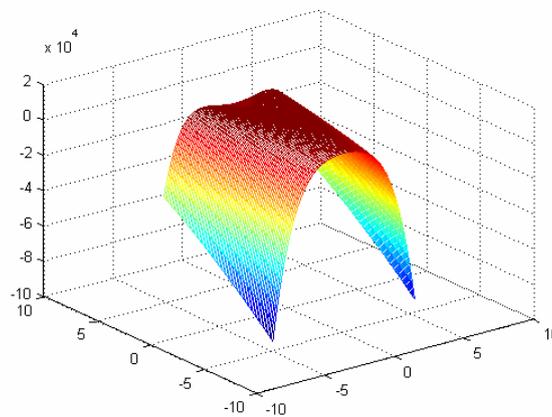


Figura 4.1. Função Rosenbrock F2 D'Jong.

- **Função Esfera**

A função Esfera é uma função de mínimo zero e, assim como, a função Rosenbrock, tem sido utilizada como função de teste de comparação entre algoritmos de

otimização, porém diferente da função Rosenbrock a função Esfera é uma função de difícil otimização, devido a sua complexidade dimensional.

A fórmula e o limite da função Esfera utilizada, nesta seção, é descrita pela equação (17), e sua forma é apresentada na figura 4.2, abaixo, onde n representa a dimensão do problema.

$$F(x) = \sum_{i=1}^n x_i^2, \quad -100 \leq x \leq 100 \quad (17)$$

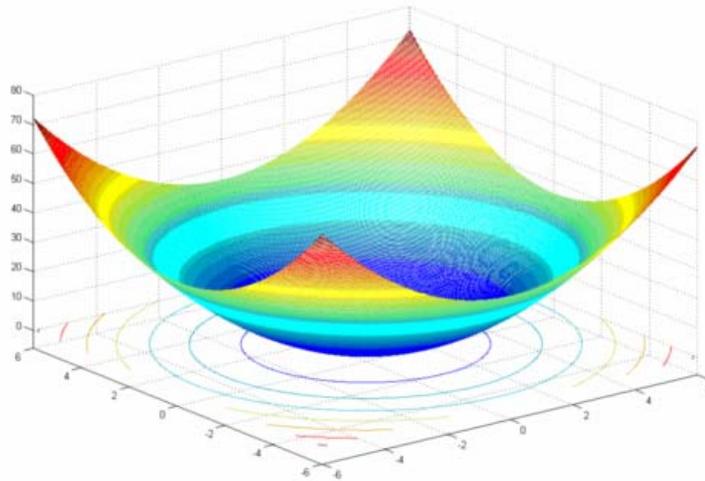


Figura 4.2. Função Esfera, para $n=2$.

4.2.2. Função Discreta.

- **Problema dos quatro picos**

O problema dos 4 picos é formado por uma classe de funções definidas por uma cadeia binária, contendo 100 bits, parametrizados pelo valor P . A função quatro picos é definida pela equação (18), abaixo:

$$F(x) = \text{MAX}(O(x), Z(x)) + \text{Prêmio} \quad (18)$$

onde, $O(x)$ é o número de “uns” contíguos começando na posição 1 da cadeia de bits, e $Z(x)$ é o número de “zeros” contíguos terminando na posição 100 da cadeia de bits .

O prêmio é dado seguindo a regra:

$$\text{Prêmio} = \begin{cases} 100, & \text{se } O(x) \succ P \text{ e } Z(x) \succ P \\ 0, & \text{caso contrário} \end{cases}$$

O problema dos quatro picos é altamente deceptivo, contendo duas regiões distintas, uma premiada e outra não premiada. No problema dos quatro picos, existe um total de $2^{100} = 1.267.650.600.228.229.401.496.703.205.376$ possíveis indivíduos. A dificuldade do problema aumenta com o aumento do valor de P .

O objetivo é maximizar a função (18), obtendo-se uma cadeia de bits capaz de atender as condições para a obtenção do prêmio e ao mesmo tempo tendo o comprimento de um dos parâmetros $O(x)$ e $Z(x)$ o maior possível.

4.3. Modelagem dos algoritmos de inspiração quântica.

- **Modelagem do problema com o QEA.**

O modelo do QEA, adotado para a solução das funções de teste descritas na seção 4.1 acima, corresponde basicamente ao modelo original (HAN *et. al.*, 2002) descrito no capítulo 2, deste trabalho, porém com algumas alterações. Tais alterações feitas por nós foram: - mudanças no valor do passo Δ , que determina a rotação do ângulo de atualização Q-bit, da tabela 4.1. A mudança do Δ levou a resultados mais satisfatórios que os encontrados com o QEA original.

O Pseudocódigo de geração de $P(t)$ usado nos testes realizados nesta seção foi determinado de acordo com a figura 4.3.

Table 4.1. Mudança do ângulo de rotação.

| x_i | b_i | $f(x) > f(B)$ | $\Delta\theta$ | $S(\alpha_i, \beta_i)$ | | | |
|-------|-------|---------------|----------------|------------------------|------------------------|----------------|---------------|
| | | | | $\alpha_i \beta_i > 0$ | $\alpha_i \beta_i < 0$ | $\alpha_i = 0$ | $\beta_i = 0$ |
| 0 | 0 | Falso | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | Verdade | 0 | 0 | 0 | 0 | 0 |
| 0 | 1 | Falso | Δ | $\Delta^*(1)$ | $\Delta^*(-1)$ | 0 | $\Delta^*(1)$ |
| 0 | 1 | Verdade | Δ | $\Delta^*(-1)$ | $\Delta^*(1)$ | $\Delta^*(1)$ | 0 |
| 1 | 0 | Falso | Δ | $\Delta^*(-1)$ | $\Delta^*(1)$ | $\Delta^*(1)$ | 0 |
| 1 | 0 | Verdade | Δ | $\Delta^*(1)$ | $\Delta^*(-1)$ | 0 | $\Delta^*(1)$ |
| 1 | 1 | Falso | 0 | 0 | 0 | 0 | 0 |
| 1 | 1 | Verdade | 0 | 0 | 0 | 0 | 0 |

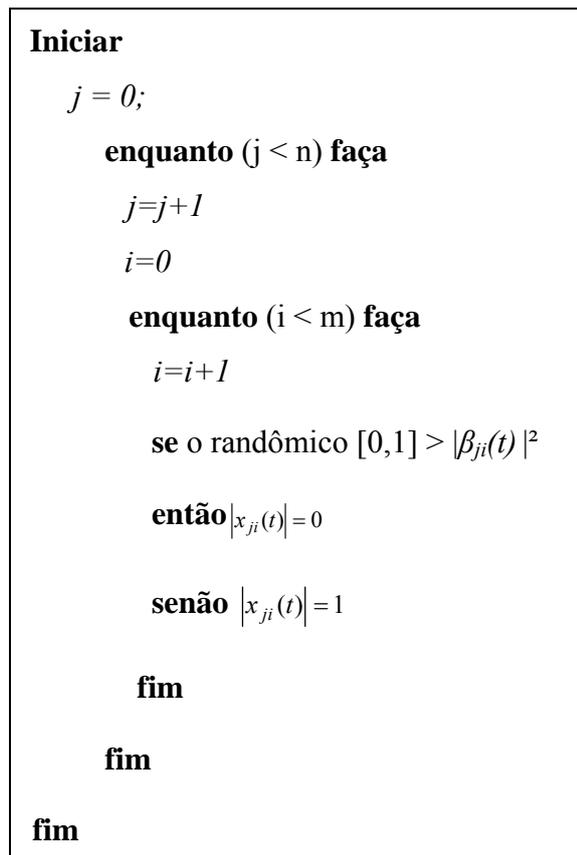


Figura 4.3. Novo Pseudocódigo de geração de P(t).

Cada indivíduo do QEA consiste de um vetor m-Q-bits binário, onde n representa a dimensão do espaço do problema, e cada vetor (indivíduo) representa uma possível

solução do problema. Cada vetor solução binário do QEA é convertido em real pelo código Gray (COELHO,2008) e sua performance é avaliado pelo QEA.

- **Modelagem do problema com o QSE.**

O modelo do QSE, adotado para a solução das funções de teste descritas na seção 4.1, corresponde ao modelo original proposto por YAN WANG *et. al.*, (2007), descrito no capítulo 2 deste trabalho.

Os parâmetros do QSE usados para a realização dos testes dessa seção são apresentados na tabela 4.2, onde Qid_j corresponde ao bit j do indivíduo Q-bit, com $j=1,2,\dots,m$, onde m corresponde ao número de Q-bits.

4.4. Análise e Resultados

De modo a avaliar a robustez dos algoritmos QSE e QEA, foram realizados testes com 10 sementes diferentes, em 2000 gerações, com uma população de 100 indivíduos. Tanto o QEA quanto o QSE foram inicializados com $Qid_j(0) = \left[\frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}} \right]$, onde Qid_j corresponde ao bit j do indivíduo Q-bit, com $j= 1,2,\dots,m$, e m representa o número de Q-bits.

O número de bits usados na função F2 foi 24, sendo 12 reservados para x e 12 para y . Já na função 4 Picos, foram utilizadas 100 bits.

- **Função Rosenbrock - F2 D’Jong**

A função Rosenbrock (16) é um problema de mínimo transformado em um problema de máximo, de ótimo global igual a 3905.93. Os parâmetros usados no QSE e no QEA, para os testes dessa seção foram representados nas tabelas 4.2 e 4.3.

Pode-se observar nas tabelas 4.2 e 4.3 que tanto o QSE, quanto o QEA apresentaram resultados satisfatórios, uma vez que os dois algoritmos encontram resultados bem próximos do ótimo global, com divergência apenas na quarta casa decimal. A função Rosenbrock é uma função de fácil resolução para estes algoritmos, sendo assim não pode ser usada para avaliar o desempenho dos algoritmos de otimização.

Tabela 4.2. Resultados do QSE para a F2 D’Jong

| | w | c_1 | c_2 | <i>Melhor</i> | <i>Média</i> |
|------------|-------|-------|-------|------------------|-------------------|
| <i>QSE</i> | 0.729 | 2.0 | 2.0 | 3905.92983064062 | 3905.929473039344 |
| | 0.729 | 2.0 | 2.1 | 3905.92983064062 | 3905.929473039344 |
| | 0.9 | 2.0 | 2.1 | 3905.92933766302 | 3905.929298725422 |

Tabela 4.3. Resultados do QEA para a F2 D’Jong

| | Δ | <i>Média</i> | <i>Melhor</i> |
|------------|----------------|-------------------|------------------|
| <i>QEA</i> | $0.01*\pi$ | 3905.929653310368 | 3905.92993164062 |
| | $0.02*\pi$ | 3905.929683801526 | 3905.92993064053 |
| | $(0.01/2)*\pi$ | 3905.929378583346 | 3905.99316406300 |
| | $1*\pi$ | 3905.935697360178 | 3905.92993064053 |

- **Função Esfera**

Com o propósito de avaliar o comportamento do QEA e do QSE em um ambiente de maior complexidade dimensional, usou-se a função Esfera (17) de mínimo zero. No intervalo de $0 < x < 1$. Observa-se nas tabelas 4.4 e 4.5, que o QEA apresentou resultados melhores que o QSE, encontrando resultados da ordem de 100 vezes menor, para $n=30$, com 100 indivíduos.

Tabela 4.4. Resultados do QSE para a Esfera

| <i>População</i> | <i>Dimensão</i> | <i>Geração</i> | <i>1º Melhor</i> | <i>2º Melhor</i> | <i>3º Melhor</i> | <i>Média</i> |
|------------------|-----------------|----------------|------------------|------------------|------------------|--------------|
| 20 | 10 | 1000 | 0.2579 | 0.5269 | 0.3011 | 0.3619 |
| | 20 | 1500 | 1.2640 | 1.7443 | 1.2017 | 1.4033 |
| | 30 | 2000 | 2.9143 | 2.6192 | 2.8305 | 2.7880 |
| 40 | 10 | 1000 | 0.2003 | 0.3527 | 0.1458 | 0.2329 |
| | 20 | 1500 | 1.0606 | 1.1500 | 1.2038 | 1.1381 |
| | 30 | 2000 | 2.5915 | 3.2583 | 2.9745 | 2.9414 |
| 80 | 10 | 1000 | 0.3041 | 0.3235 | 0.1109 | 0.2461 |
| | 20 | 1500 | 1.1365 | 0.9207 | 1.7291 | 1.2621 |
| | 30 | 2000 | 2.4241 | 2.8262 | 2.4831 | 2.5778 |
| 100 | 10 | 1000 | 0.1705 | 0.2482 | 0.2498 | 0.2228 |
| | 20 | 1500 | 0.6671 | 0.8600 | 1.0266 | 0.8512 |
| | 30 | 2000 | 2.3183 | 2.2628 | 1.6264 | 2.0691 |

Tabela 4.5. Resultados do QEA para a Esfera

| <i>População</i> | <i>Dimensão</i> | <i>Geração</i> | <i>1º Melhor</i> | <i>2º Melhor</i> | <i>3º Melhor</i> | <i>Média</i> |
|------------------|-----------------|----------------|------------------|------------------|------------------|--------------|
| 20 | 10 | 1000 | 7.1597E-4 | 6.6790E-6 | 4.1147E-6 | 2.4225E-4 |
| | 20 | 1500 | 1.3300E-2 | 1.2000E-3 | 1.0000E-3 | 5.1666E-3 |
| | 30 | 2000 | 3.7390E-1 | 1.5600E-2 | 2.5300E-2 | 1.3830E-1 |
| 40 | 10 | 1000 | 5.3151E-5 | 3.5780E-7 | 1.0734E-6 | 1.8194E-5 |
| | 20 | 1500 | 1.9000E-3 | 5.8751E-4 | 9.2009E-4 | 1.1358E-3 |
| | 30 | 2000 | 1.0940E-1 | 1.0700E-2 | 7.1000E-3 | 4.2400E-2 |
| 80 | 10 | 1000 | 1.5633E-5 | 6.5597E-7 | 0.0000 | 5.4296E-6 |
| | 20 | 1500 | 4.1000E-3 | 1.0013E-4 | 8.7781E-5 | 1.4293E-3 |
| | 30 | 2000 | 4.8400E-2 | 1.2000E-3 | 2.9000E-3 | 1.6850E-2 |
| 100 | 10 | 1000 | 2.8139E-5 | 4.1744E-7 | 0.0000 | 9.5188E-6 |
| | 20 | 1500 | 1.8759E-5 | 1.2941E-4 | 9.1717E-5 | 7.9962E-5 |
| | 30 | 2000 | 5.3700E-2 | 4.500E-3 | 2.6000E-3 | 2.0260E-2 |

Para analisar o comportamento do QEA, na otimização da função Esfera, realizamos testes no intervalo $-100 < x < 100$.

Observa-se na tabela 4.6 que o QEA encontra resultados muito mais satisfatórios para a função esfera, no intervalo de $-100 < x < 100$, do que aqueles encontrados pelo QSE no intervalo $0 < x < 1$. Dessa forma, apresenta-se mais robusto e eficaz que o QSE.

Tabela 4.6. Resultados do QEA para a Esfera

| <i>População</i> | <i>Dimensão</i> | <i>Geração</i> | <i>1º Melhor</i> | <i>2º Melhor</i> | <i>3º Melhor</i> | <i>Média</i> |
|------------------|-----------------|----------------|------------------|------------------|------------------|--------------|
| 20 | 10 | 1000 | 1.6400E-2 | 6.2400E-2 | 8.2400E-2 | 1.7073E-2 |
| | 30 | 4000 | 4.3656E-6 | 6.6939E-6 | 1.1351E-5 | 6.3929E-4 |
| 100 | 10 | 1000 | 9.1998E-4 | 7.4768E-4 | 0.0014E-4 | 2.7467E-3 |
| | 30 | 4000 | 4.3656E-6 | 4.3656E-6 | 4.3656E-6 | 4.3656E-6 |

A seguir encontram-se os gráficos de convergência do QEA, para a função esfera no intervalo $-100 < x < 100$, dos primeiros melhores resultados de cada população.

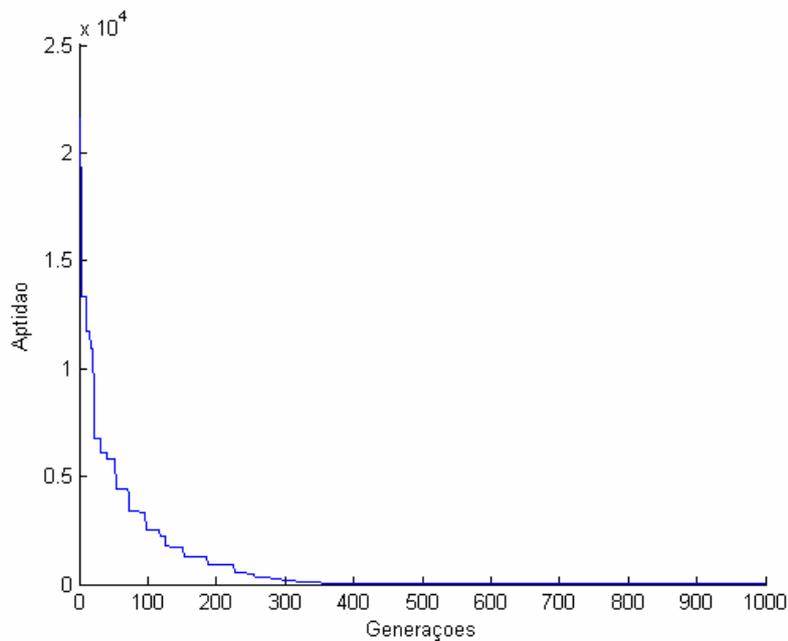


Figura 4.4. Gráfico de convergência do melhor resultado encontrado pelo QEA para a função esfera de dimensão $n=10$ no intervalo de $-100 < x < 100$, para uma população de 20 indivíduos.

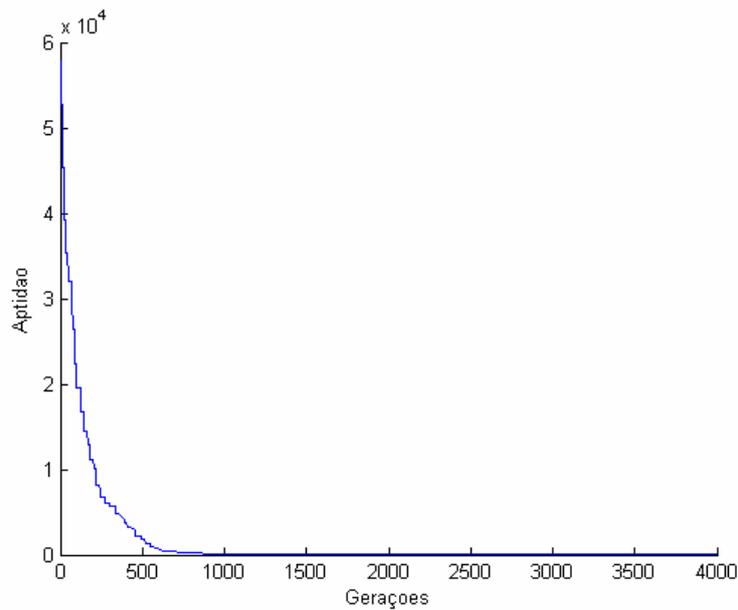


Figura 4.5. Gráfico de convergência do melhor resultado encontrado pelo QEA para a função esfera de dimensão $n=30$ no intervalo de $-100 < x < 100$, para uma população de 100 indivíduos.

- **Problema dos 4 picos**

A função 4 picos (18) é um problema de máximo de valor igual a 189, para $P=11$. Os testes realizados com os algoritmos quânticos QSE e QEA, com diferentes valores de P tiveram o objetivo de comparar a evolução e a robustez dos algoritmos. Espera-se que com $P=11$ e com $P=21$ a função ganhe prêmio e com $P=101$ não ganhe prêmio, mas que sua aptidão se aproxime de 100.

As tabelas 4.7 e 4.8 apresentam os resultados obtidos pelo QSE e pelo QEA, na otimização da função 4 picos. Pode-se observar que o QEA conseguiu premiar a função com $P=21$ e com $P=11$, já o QSE só premiou a função com $P=11$. Dessa forma, o QEA apresentou resultados 33% superiores ao QSE para $P=11$ e 31% para $P=21$.

Tabela 4.7. Resultados do QSE para a função 4 picos

| <i>QSE</i> | <i>w</i> | <i>c</i> ₁ | <i>c</i> ₂ | <i>Melhor</i> | | | <i>Média</i> | | |
|------------|----------|-----------------------|-----------------------|---------------|-------|-------|--------------|-------|-------|
| | | | | P=21 | P=11 | P=101 | P=21 | P=11 | P=101 |
| | 0.729 | 2.0 | 2.1 | 55.0 | 141.1 | 55.0 | 40.9 | 128.1 | 40.9 |
| | 0.900 | 2.0 | 2.1 | 52.0 | 144.0 | 52.0 | 44.8 | 130.5 | 44.8 |

Tabela 4.8. Resultados do QEA para a função 4 picos

| <i>QEA</i> | Δ | <i>Melhor</i> | | | <i>Média</i> | | |
|------------|-------------|---------------|------|-------|--------------|-------|-------|
| | | P=21 | P=11 | P=101 | P=21 | P=11 | P=101 |
| | 0.01* π | 162 | 189 | 100 | 100.9 | 166.2 | 91.5 |
| | 0.02* π | 152 | 189 | 100 | 101.6 | 171.3 | 67.0 |
| | 0.1* π | 139 | 189 | 100 | 100.2 | 142.4 | 78.8 |

4.5. Escolha do algoritmo de inspiração quântica.

Nesta seção foi possível observar através dos resultados encontrados nas tabelas 4.4, 4.5, 4.6, 4.7 e 4.8 que o algoritmo QEA mostrou-se mais eficaz e robusto que o QSE na otimização das funções Esfera e 4 picos. Apoiando nesses resultados, o QEA foi escolhido para ser usado como ferramenta de otimização no Problema de Identificação de Acidentes de uma Usina Nuclear – PWR, que será descrito no capítulo 6, deste trabalho.

CAPÍTULO 5

IDENTIFICAÇÃO DE ACIDENTES NUCLEARES

Neste capítulo serão apresentadas as principais características do problema de identificação de acidentes de uma Usina Nuclear, bem como uma breve descrição dos principais acidentes/transientes postulados para uma Usina PWR. Em seguida, serão introduzidas as idéias básicas de um sistema de identificação de acidentes/transientes de uma Usina Nuclear, baseados em técnicas de Inteligência Artificial.

5.1. Introdução

Uma central nuclear é um sistema complexo, composto de muitos subsistemas e milhares de componentes que devem operar com máxima eficiência e em perfeitas condições, oferecendo a maior segurança possível. Sua operação envolve o controle e monitoração de vários sistemas cujas falhas podem provocar o aparecimento de situações anormais, que se não forem diagnosticadas a tempo e corretamente, poderão produzir consequências graves, não só para a Usina, como também para o público e o meio ambiente.

O funcionamento eficaz da Usina é garantido através do monitoramento de diversos de seus sistemas internos. As informações coletadas através desses sistemas são suficientes para informar ao operador o estado operação da Usina. Dessa forma, a partir da instrumentação instalada nesses sistemas os operadores monitoram um grande número de medidas das variáveis de estado envolvidas em cada processo da Usina. Caso um evento anormal de operação aconteça, os operadores devem identificar e diagnosticar tal situação em função da análise das medidas das variáveis de estado correspondentes.

O grande número de instrumentos e a dinâmica da variação das medidas das grandezas associadas ao evento em curso, dificulta o processo de identificação e tomada de decisão por parte do operador. Dessa forma, aumenta-se a probabilidade de ações

inadequadas, por parte do operador, e seus resultados podem ser catastróficos como no caso do acidente de *Three Mile Island* (TMI) (NUREG , 1979).

No TMI, as válvulas das três bombas de água de alimentação foram deixadas fechadas após uma parada de manutenção da Usina, além disso o Sistema de Injeção de Segurança à Alta Pressão foi desligado por um dos operadores da sala de controle, por consequência desses atos a Usina foi levada a condições não previstas em sua base de projeto e teve fins catastróficos (MOL, 2002).

Uma das maiores consequências regulatórias proposta após o acidente do TMI foi à emissão de documentos normativos, pela Comissão de Regulamentação Nuclear (NRC), com o objetivo de aumentar a segurança e funcionamento eficaz da Usina e por consequência aumentar a capacidade de resposta do operador, no caso de situações anormais da Usina. Dessa forma, foram introduzidos os conceitos das funções críticas de segurança (SFCS) e exigida à implementação de sistemas computadorizados de auxílio à operação na sala de controle das Usinas nucleares genericamente denominados de *Safety Parameter Display System* (SPDS)(PEREIRA *et. al.*,1998). Outros exemplos dessas modificações, principalmente em relação aos Fatores Humanos podem ser evidenciados em NUREG 0.933.

As funções críticas de segurança são grupos de parâmetros responsáveis por evitar o derretimento do núcleo do reator ou minimizar a quantidade de radiação liberada para o meio ambiente. São definidas por grupos de parâmetros associados às barreiras de proteção das Usinas responsáveis por controlar a criticalidade, o inventário do refrigerante do reator e a pressão do reator, além disso, são responsáveis pelo transporte do calor do reator do circuito primário para o secundário. Considerando situações nas quais uma função crítica não esteja em sua condição normal, são seguidos procedimentos operacionais de recuperação dessas funções com o objetivo garantir a integridade das barreiras de proteção da Usina.

Os sistemas computadorizados de auxílio à operação na sala de controle das Usinas nucleares são bastante úteis no gerenciamento global das condições de segurança da Usina e, no auxílio à tomada de decisões de emergência. Dessa forma, são responsáveis por auxiliarem os operadores nas tomadas de decisões, em casos de

situações anormais de funcionamento da Usina e por conseqüência, reduzem a carga cognitiva do operador, aumentando seu tempo disponível para ações rápidas e corretas e, conseqüentemente minimizam o risco de um diagnóstico incorreto do estado da usina.

Como descrito em MOL (2002), a filosofia básica dos órgãos reguladores em garantir a segurança no projeto, construção e operação de Usinas nucleares tem sido chamada de defesa em profundidade e se expressa em termos de três níveis de segurança.

O primeiro nível de segurança esta relacionado com o “projeto do reator” e com os componente associados a ele, uma vez que este deverá operar com alto grau de confiabilidade. Para este fim, os órgão reguladores dão uma ênfase especial à qualidade dos materiais e da mão de obra utilizada na construção da Usina. A Usina deve ser projetada e construída para ser resistente aos fenômenos naturais. Além disso, o projeto deve permitir o monitoramento contínuo ou periódico dos sistemas e componentes, de modo a detectar possíveis falhas.

A despeito de toda a segurança oferecida pelo cuidado no projeto e construção da Usina, é necessário prevenir que alguns incidentes venham a ocorrer durante o ciclo de vida da mesma. A proposta do segundo nível de segurança e fornecer meios para “evitar” ou “lidar” com esses eventos.

Finalmente, o terceiro nível de segurança é baseado no ponto de vista de que é prudente ir além dos níveis de segurança mencionados anteriormente, e incorpora sistemas adicionais e barreiras de radioatividade para proteger o público, mesmo se alguns acidentes ocorrem. Para isto, falhas de componentes e sistemas são postulados e suas conseqüências são analisadas. A análise de cada evento hipotético determina um conjunto de acidentes de base de projeto, e sistemas de segurança são, então, projetados para controlá-los.

Uma referencia em maiores detalhes dos objetivos de segurança para uma usina nuclear pode ser encontrada em INSAG-12. (IAEA-1999)

5.2. Principais Acidentes de base de projeto de uma Usina Nuclear do Tipo PWR.

Os eventos iniciadores internos de acidentes nucleares podem ocorrer tanto no sistema primário (nuclear) quanto no secundário (ciclo de vapor), que por sua vez são constituídos de subsistemas classificados segundo a sua importância para a segurança nuclear

O Relatório Final de Análise de Segurança (FSAR) analisa um conjunto de eventos, postulados para uma Usina Nuclear, que tem por objetivo demonstrar o cumprimento de três objetivos de segurança: - o desligamento seguro da Usina; - a remoção do calor residual do núcleo do reator; - e a limitação quanto à liberação da radioatividade. Os eventos analisados em cada um dos objetivos são classificados em três categorias de eventos em função da frequência de ocorrência. Essas categorias de evento são classificadas em: transientes operacionais; acidentes e transientes antecipados com falha no desligamento rápido do reator.

Em caso de transientes operacionais é demonstrado que os sistemas de controle, limitação e desligamento rápido do reator são suficientes para manter a integridade das barreiras de proteção da Usina; manter os sistemas e componentes da Usina funcionando dentro dos limites permitidos de operação normal; além de evitar a liberação de radioatividade para o meio ambiente fora dos limites permitidos para a operação normal. Os eventos conhecidos como transientes operacionais são:

- abertura inadvertida de uma válvula de bypass do Sistema de Vapor principal;
- desligamento da turbina (TRIP TUR);
- isolamento de uma válvula de isolamento do Sistema de Vapor principal;
- perda de água de alimentação devido à falha de uma bomba de alimentação;
- perda de água de alimentação devido à falha de todas as bombas de alimentação;
- perda de uma bomba de refrigeração do reator;
- desligamento de todas as bombas de refrigeração do reator;

- retirada descontrolada do banco de barras de controle a partir de uma condição subcrítico;
- retirada descontrolada do banco de barras de controle em operação normal;
- partida de uma bomba de refrigeração inativa em um nível de potência incorreto;
- atuação inadvertida do Sistema de Injeção de Segurança durante a operação normal;
- diluição descontrolada de boro;
- abertura inadvertida da válvula de alívio de segurança do pressurizador;
- perda de alimentação elétrica externa para a operação de equipamentos auxiliares (BLACKOUT).

Na categoria de acidentes é demonstrado que as funções realizadas pelo sistema de proteção do reator são suficientes para manter a integridade das barreiras de proteção da Usina; manter os sistemas e componentes funcionando dentro dos limites permitidos para a condição de acidente; além de evitar a liberação de radioatividade para o meio ambiente fora dos limites permitidos para a condição de acidente. Nesta categoria estão incluídos os seguintes eventos:

- abertura inadvertida de todas as válvulas de “bypass” do Sistema de vapor principal;
- perda de refrigerante do reator, resultante de rupturas na tubulação do primário (LOCA);
- ruptura de tubos de gerador de vapor (SGTR);
- ruptura das linhas de vapor (STMLIBR);
- isolamento da linha de vapor principal (MFWISO);
- ruptura da linha de alimentação principal (MFWBR);
- abertura inadvertida de uma válvula de alívio do gerador de vapor;

Os transientes antecipados com falha no desligamento rápido do reator (ATWS) podem ser causados devido ao fato do sinal de desligamento não conseguir percorrer o caminho até os magnetos de sustentação das barras de controle. Entretanto, para este caso a inserção ou queda das barras de controle, ainda é possível através da limitação da potência do reator. Uma segunda hipótese para a falha no desligamento é uma falha

mecânica das barras de controle (presas), onde nem o sistema de limitação de potência do reator consegue movimentação das barras de controle. Sendo assim, os meios utilizados para tratar este evento são suficientes para: assegurar a remoção de calor originário do sistema de refrigeração do reator e manter os limites da pressão do sistema de refrigeração do reator.

O ATWS é considerado um caso de acidente hipotético. Mesmo assim, são previstas ações do Sistema de Limitação do Reator, que atuam em casos de ATWS, para conduzir a Usina a uma condição segura.

Transientes sem desligamento rápido conduzem, na maioria dos casos, através do calor produzido e não removido, a uma elevação da temperatura e da pressão no circuito primário, em consequência, ocorre uma atuação das válvulas de segurança com redução de pressão e perda parcial de refrigerante do reator ocasionando a redução da pressão e perda parcial de refrigerante do reator. A redução da pressão provoca a formação de bolhas no refrigerante do reator, que por sua vez evapora parcialmente acarretando uma piora considerável da moderação e consequentemente um ganho de reatividade negativa, ocasionando o desligamento do reator.

Um comportamento desse tipo de acidente com desligamento próprio, sem a atuação das barras de controle e sem consequência para a Usina, está de acordo com o conceito de segurança intrínseca. (MOW) Além da segurança intrínseca, pela limitação da movimentação de barras de controle, é realizada a monitoração da queda de barras de controle. Se, após a presença da ativação do sinal de desligamento do reator nuclear, as barras de controle não atingirem um limite de queda definida, ocorrerá à injeção de ácido bórico com as bombas de boração adicional dos tanques de armazenamento da água borada, com a qual a potência será também reduzida.

5.3. Sistemas de Identificação de Acidentes de Usinas Nucleares, baseados em Técnicas de Inteligência Artificial.

Conforme dito anteriormente, a operação de uma Usina Nuclear envolve a operação de vários sistemas cuja falha pode provocar uma evolução adversa das condições operacionais da Usina que, se não forem diagnosticada corretamente, e em tempo, podem oferecer sérios danos não só para a Usina como também para o público e o meio ambiente.

A evolução das condições operacionais da Usina usualmente apresentam um comportamento com padrões temporais bem definidos (assinaturas), das medidas e das variáveis de estado envolvidas em cada situação operacional. O grande número de instrumentos e a dinâmica de cada grandeza medida dificultam o processo de identificação e tomada de decisão por parte do operador. Sendo assim, sistemas de identificação e diagnósticos de acidentes poderiam ser incorporados ao sistema de operação da Usina, com o objetivo de auxiliar o operador na tomada de uma decisão rápida e correta do evento em curso.

Neste contexto surgem sistemas de identificação baseados em técnicas de inteligência artificial (IA). Estas técnicas conseguem contornar bem o problema da complexidade do espaço de busca, não necessitando das condições de continuidade e existência de derivadas normalmente exigida pelos métodos clássicos. Seguindo então esta tendência, diversos trabalhos foram publicados com base em sistemas especialistas, redes neurais artificiais, lógicas nebulosas, algoritmos genéticos e inteligência de enxames para resolver problemas relacionados à monitoração de uma Usina Nuclear, principalmente no que se refere ao problema de validação dos sinais e identificação de transientes.

Um dos primeiros sistemas propostos de identificação de acidentes nucleares baseados em técnicas de inteligência artificial foi concebido por BARTLETT e UHRIG (1992), que utilizou redes neurais para o diagnóstico de falhas, no trabalho: “Nuclear Power Plant Diagnostics Using an Artificial Neural Network”. BASU e BARTLETT (1994) aperfeiçoou o trabalho de BARTLETT e UHRIG (1992), utilizando uma

arquitetura composta de duas RNAs que identificavam 27 transientes de um reator BWR, usando 97 variáveis de processo de planta.

BARTAL, LIN e UHRIG (1995) desenvolveram um sistema classificador baseado em redes neurais, que assumia a resposta “não sei” quando apresentado a um novo transiente que não estava contido na base de conhecimento acumulado. O classificador foi utilizado para classificar 72 cenários de 13 diferentes tipos de transientes, a partir do comportamento de 76 variáveis ao longo do tempo. Eles também introduziram um mecanismo denominado de acumulação de evidência mediante o qual resultados de classificações obtidos em instantes anteriores são usados como suporte de evidências para a classificação final, onde a classificação final é feita usando uma votação majoritária dos valores obtidos em cada instante de tempo.

Outra contribuição importante foi dada por FURUKAWA, UEDA e KITAMURA, (1995) que propuseram um sistema de classificação de eventos baseado em um classificador independente para cada variável observada. O classificador recebe em sua entrada a série temporal completa de variável selecionada e produz na saída a melhor classificação parcial possível em conjuntos de classes (isto é, um evento é incluído em uma das superclasses que são separáveis a partir da informação trazida por uma simples variável). A interseção dos conjuntos de classes (superclasses) gerada por todos os classificadores produz a classificação final. Este método tem a vantagem de ser muito robusto, já que a classificação final é baseada em múltiplos classificadores independentes. A dificuldade ocorre nos casos para os quais a função discriminação (critério de classificação) venha a ser muito complexa e seja necessária uma análise da interação entre duas ou mais variáveis.

Um método alternativo de identificação de transiente foi proposto por JEONG, FURUTA e KONDO, (1996), usando o que eles chamaram de “*adaptive template matching*”. Seu método é baseado em RNAs do tipo “feedforward” (sem alimentações internas) que permite não só identificar transientes diferentes, como avaliar vários transientes do mesmo tipo com diferentes níveis de severidade.

ROVERSO, (1998) desenvolveu três métodos para classificação de eventos dinâmicos representados por series temporais. Os dois primeiros utilizam algoritmos de

agrupamento de padrões (“*clustering*”), baseado em conjuntos nebulosos, e redes neurais artificiais que conseguem avaliar as distâncias das amostras às classes do conjunto de treinamento, no caso de Funções de Base Radial (“*RBF-Radial Basis Functions*”) e Mapas de Kohonen. No terceiro método, foi usado um tipo especial de RNA recorrente (com realimentações internas) – o Classificador de Elman – que tem capacidade de lidar diretamente com series temporais, dispensando a etapa de agrupamento de padrões. Os resultados obtidos pelos três métodos foram comparados e o Classificador de Elman apresentou o melhor desempenho.

Redes neurais artificiais do tipo AVQ (“*Adaptative Vector Quantization*”), algoritmos genéticos e lógica nebulosa foram utilizados por ALVARENGA (1997) em um sistema de diagnóstico para acidentes em centrais nucleares. As RNAs eram responsáveis por gerar centróides das classes representativas dos acidentes postulados. Os centróides eram utilizados para particionar os eixos das variáveis em conjuntos nebulosos e estabelecer zonas de influência de cada acidente. Os algoritmos genéticos posicionavam tais centróides gerados pelas RNAs no eixo do tempo, de modo a encontrar a melhor posição dos centróides que determinava uma classificação final de mínima incerteza.

Uma nova metodologia para identificação de transientes nucleares foi proposto por PEREIRA, SCHIRRU e MARTINEZ (1998), onde um algoritmo genético foi usado como algoritmo de otimização de um sistema de classificação baseado em medidas diretas de distância euclidiana. O método proposto denominado “Conjunto Mínimo de Centróides (CMC)”, utiliza o AG para particionar o espaço de busca do problema e tem por objetivo encontrar subconjuntos das classes, definidos como subclasses, cujos centróides (um ou mais por classe), representam as classes com o máximo número de classificações corretas.

ALMEIDA (2001) aprimorou o método desenvolvido por PEREIRA *et. al.*, (1998) substituindo o critério de classificação baseado em medidas diretas de distâncias euclidianas por outro baseado em medidas de pertinência possibilística, utilizando conjunto nebulosos. O critério de pertinências possibilística permite um avaliação das zonas de influência dos centróides, tornando o processo de identificação mais consistente que o método anterior, possibilitando o estabelecimento de um limiar para a

obtenção de classificações “não sei” para transientes desconhecidos ou fora do conjunto de treinamento. Finalmente a identificação do transiente em curso é efetuada com base na acumulação de evidências das classificações efetuadas em instantes anteriores.

Em sua tese de doutorado MOL, (2002) propõe um sistema de identificação de transientes baseado em redes neurais artificiais, com capacidade da resposta “não sei” na identificação dinâmica de eventos desconhecidos, ou melhor, para eventos não pertencentes ao conjunto de aprendizado utilizado durante seu treinamento. Nesse método são utilizadas duas redes sendo uma rede responsável pela identificação dinâmica, de um conjunto recente de valores de entrada, através de uma janela de tempo móvel e a segunda rede responsável por validar a identificação realizada pela primeira rede através da validação de cada variável, permitindo assim uma resposta “*não sei*” para eventos desconhecidos. Para aumentar a robustez à rede é treinada acrescentando ruído aos dados de treinamento. Neste trabalho são consideradas 17 variáveis como conjunto mínimo de variáveis capazes de caracterizar 16 condições operacionais de uma Usina PWR.

MEDEIROS (2005), baseado nas assinaturas de 17 variáveis de estado, de 3 transientes nucleares propôs um sistema de diagnóstico que classifica um evento anômalo dentro das assinaturas desses transientes de base. O sistema mede a distância euclidiana entre o conjunto de variáveis do evento anômalo, em um determinado instante t , e o centróide das variáveis do transiente de base, onde o PSO é usado, como ferramenta de otimização, para encontrar a melhor posição dos centróides (Vetores de Voranoí) dos transientes de base, que maximizam o número de classificações corretas.

CAPÍTULO 6

OTIMIZAÇÃO DO PROBLEMA DE IDENTIFICAÇÃO DE ACIDENTES NUCLEARES

Neste capítulo são apresentados os testes e resultados da implementação de um protótipo para um sistema de identificação de um conjunto de 3 acidentes de base de projeto, dentre os 17 acidentes/transientes postulados para a Usina Nuclear Angra 2. O objetivo desta seção é avaliar a capacidade do QEA como ferramenta de otimização de sistemas complexos da área nuclear. Primeiramente, são apresentadas as características dos acidentes/transientes de base de projeto selecionados para a realização dos testes desta seção. A seguir, são apresentadas as características do sistema protótipo de identificação de acidentes/transientes proposto, bem como, a modelagem do problema com o QEA e a comparação dos resultados encontrados, neste trabalho, com outros existentes na literatura.

6.1. Introdução

Como descrito no capítulo anterior uma central nuclear é um sistema complexo, composto de muitos subsistemas e milhares de componentes que devem operar com máxima eficiência e em perfeitas condições. O grande número de instrumentos e a dinâmica de cada grandeza medida associada ao evento em curso, dificulta o processo de identificação e tomada de decisão pelo operador. Dessa forma, sistemas de identificação e de diagnósticos de acidentes/transientes, poderiam ser incorporados ao sistema de operação da Usina com o objetivo de auxiliar o operador na tomada de uma decisão em curto intervalo de tempo com máxima certeza associada.

Propomos, nesta seção, um modelo de diagnóstico de acidentes/transientes baseado no algoritmo quântico QEA. Tal modelo foi implementado em um sistema protótipo que identifica um evento anômalo da Usina de Angra 2, dentre um conjunto de 3 acidentes/transiente de base de projeto, gerados por simulação computacional, qual melhor caracteriza o evento em curso. O QEA foi usado para encontrar a melhor

posição dos protótipos centróides, Vetores de Voronoi de cada um dos três acidentes/transientes selecionados (BLACKOUT, LOCA, SGTR), de modo que essas posições maximizam o número de classificações corretas. O sistema de diagnóstico proposto classifica o evento anômalo através da menor distância euclidiana entre os centróides gerados pelo QEA e, a assinatura, ou seja, evolução temporal das variáveis de estado do evento anômalo.

6.2. Modelo de um sistema protótipo de identificação de acidentes/transientes

O sistema proposto utiliza-se de um método baseado em distância euclidiana, que mede a distância entre o vetor de variáveis do evento anômalo, em um determinado instante t , e o vetor centróide das variáveis dos acidentes/transientes de base de projeto selecionado. O QEA é usado, como ferramenta de otimização, para encontrar a melhor posição dos protótipos dos centróides de cada um dos três acidentes/transientes de base, e desta forma maximizar o número de classificações corretas. Uma vez que nada obriga a que os protótipos para a classificação sejam os centróides resultantes de alguma função do particionamento do espaço de busca, o algoritmo foi usado na busca de protótipos que maximizam o número de acertos para a classificação de todos os acidentes. Esta abordagem estabelece um modelo solução que corresponde à pesquisa dos Vetores de Voronoi para a identificação das classes de acidentes/transientes.

Cada acidente/transiente foi representado pela evolução temporal de 18 variáveis de estado, consideradas necessárias e suficientes para o reconhecimento de cada transiente, no intervalo de 0 a 60 segundos, de um em um segundo, onde o primeiro segundo corresponde ao TRIP do reator.

A classificação do evento anômalo foi feita pela medida da menor distância euclidiana entre o conjunto de variáveis (assinatura) do evento anômalo, em um determinado instante t , e o centróide de cada acidente/transiente, de acordo com a figura 6.1.

Na figura 6.1, são considerados três tipos de acidentes, representados pelos seus centróides e uma amostra a ser classificada por um sistema, que avalia a menor distância

euclidiana entre o centróide de cada acidente e amostra, e classifica o tipo da amostra através da menor distância medida entre o centróide do acidente e a amostra.

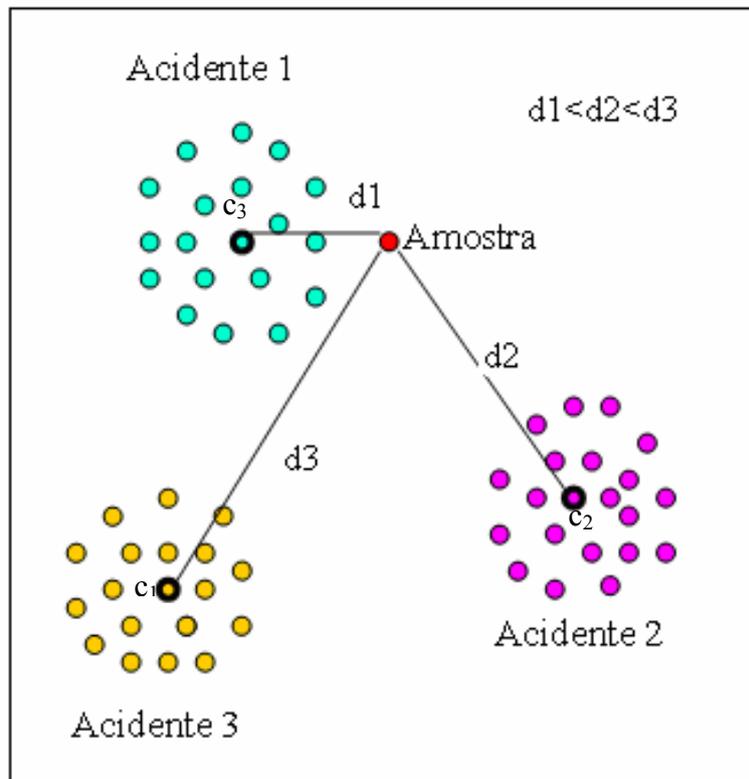


Figura 6.1. Exemplo de classificação de uma amostra, onde os pontos c_1 , c_2 e c_3 são os centróides dos acidentes 1, 2 e 3, respectivamente e d_1 , d_2 e d_3 as respectivas distâncias entre os centróides dos acidentes e a amostra a ser classificada.

Observando a figura 6.1, conclui-se que a amostra será classificada como sendo o acidente 1, pois a distância d_1 é a menor encontrada pelo sistema.

6.3. Acidentes/transientes de base de projeto selecionados para a implementação do sistema proposto.

O conjunto de acidentes/transientes selecionados para testar o sistema protótipo de diagnóstico, proposto neste trabalho, foi escolhido tomando como base os acidentes de projeto postulados para a Usina Nuclear Angra 2, que constam no capítulo 15 do Relatório Final de Análise de Acidentes (FSAR), exigido pela Comissão Nacional de Energia Nuclear.

Os eventos iniciadores destes acidentes podem ocorrer tanto no sistema primário quanto no secundário, que por sua vez são constituídos de subsistemas menores. A garantia de segurança nuclear está diretamente relacionada ao funcionamento destes e outros sistemas. Em MOL (2002) pode ser encontrado uma descrição detalhada desses sistemas e outros sistemas de segurança do reator.

Os acidentes/ transientes selecionados foram:

BLACKOUT – consiste na perda de alimentação elétrica externa; a perda coincidente de potência da Usina e externa pode ocorrer se, por exemplo, a transferência para a rede externa falha após TRIP da turbina. Neste caso existirá uma perda de potência para os auxiliares da planta tais como: bombas de refrigerante do reator, bombas de água de alimentação e bombas de água de circulação. No lado do secundário, a estação de “bypass” de vapor principal é bloqueada devido a perda das bombas de condensado e das bombas de água de circulação, e a remoção de calor é suprida pelas válvulas de alívio e de segurança do vapor principal. O suprimento de água de alimentação para os GVs é executado pelas bombas de partida e parada. O modo de alimentação elétrica de emergência a curto prazo é classificado como um transiente operacional. A planta se estabiliza com a remoção de calor do lado secundário sendo realizada pelas válvulas de controle de alívio do vapor principal até que o suprimento de potências auxiliar seja recuperado. Caso o suprimento de potência não seja restaurado em 12 horas, a planta tem que ser transferida para a condição de subcrítico frio. Este evento de longo prazo é analisado com respeito a liberações radioativas no vapor aliviado para a atmosfera.

LOCA – consiste na perda de refrigeração do reator é classificado em três categorias: grande, médio e pequeno LOCA. Neste trabalho exploramos a ocorrência de um pequeno loca que é definido como uma ruptura com área de seção reta de aproximadamente 5 cm de diâmetro das tubulações de refrigerante do reator ou linhas de conexão, onde a pressão no SRR se estabiliza entre 109 bar e 9bar. O núcleo permanece coberto, apesar de que o nível do pzi cai para < 2.28 m. Como a remoção de calor no núcleo através do vazamento e da injeção do refrigerante não é suficiente o bastante (no caso de seção de retas de ruptura muito pequenas), a remoção de calor é auxiliada pelo lado secundário. É assumido para este cenário modo de alimentação elétrica de Emergência coincidente. A característica típica de um loca pequeno é que o vazamento do refrigerante pode ser repostado dentro de uma faixa de pressão entre 109 e 9 bar, isto é, as bombas de injeção de segurança e as bombas de boração possivelmente auxiliadas pelos acumuladores, repõem o vazamento e desenvolvem uma pressão no SRR a um nível maior que o da pressão de saturação, que está caindo de 25 bar, os acumuladores não descarregam. Uma parte do calor é removido através do lado secundário pelo resfriamento a 100 Km/h. Uma vez que o SRR está cheio e subresfriado, a transferência de calor no núcleo é boa, equanto a circulação natural (as BRRs estão desligadas) permite uma boa transferência de calor para o lado secundário. A outra parte do calor (dependendo do tamanho da ruptura) é descarregada através da ruptura. Apenas uma leve pressão (teoricamente até aproximadamente 1 bar) se desenvolve na contenção. A liberação da radioatividade foi interrompida pelo isolamento da ventilação do prédio de contenção.

SGRT – consiste em rupturas nos tubos geradores de vapor – na ocorrência de vazamentos nos tubos em U dos geradores de vapor, haverá uma transferência de refrigerante radioativo para o circuito de água vapor, devido a alta diferença de refrigerante radioativo para o circuito de água vapor e, a alta diferença de pressão existente entre o lado primário e o secundário. As principais funções das ações automáticas e manuais que se desenvolvem, são as de restringir a perda de refrigerante e a de limitar os

efeitos do acidente para que não haja liberação de vapor radioativo, através das válvulas de alívio, para a atmosfera. Para isso, as potências do reator e do gerador devem ser reduzidas o mais rápido possível. Com o funcionamento das BRRS, é mantida a circulação forçada evitando a formação de bolhas de vapor na região da tampa do vaso de pressão do reator com a pressão do sistema de refrigeração do reator reduzida. Com o condensador como fonte fria, evita-se que o vapor principal radioativo seja liberado para o meio ambiente. Com a redução da potência, e com a redução da pressão do sistema de refrigeração do reator, a diferença de pressão entre o lado primário e secundário é reduzida diminuindo a taxa de vazamento.

A simulação da variação temporal dos acidentes/transientes apresentados acima foi programada em linguagem MATLAB-4.0, por ALVARENGA (1997). O tempo total da amostragem foi de 61 segundos, onde o primeiro segundo corresponde à condição normal de potência e o segundo segundo o início do TRIP do reator. O tempo de 61 segundos foi considerado suficiente para que os acidentes possam ser destacados uns dos outros, devido a evolução particular de uma ou mais variáveis de estado do sistema, consideradas como aquelas que mais contribuem para a caracterização dos acidentes/transientes em questão. As amostragens dessas variáveis foram feitas com intervalos de um segundo.

As variáveis de processo selecionadas para o reconhecimento do evento em curso inclusive para efeito de comparação com os trabalhos desenvolvidos por MEDEIROS (2005) e ALMEIDA (2001), foram listadas na tabela 6.1.

Table 6.1. Variáveis de estado dos acidentes/transientes.

| | |
|-----|--|
| 1. | Vazão do núcleo (%) |
| 2. | Temperatura da perna quente (C) |
| 3. | Temperatura da perna fria (C) |
| 4. | Vazão no núcleo (kg/s) |
| 5. | Nível no gerador de vapor – faixa larga (%) |
| 6. | Nível no gerador de vapor – faixa estreita (%) |
| 7. | Pressão no gerador de vapor (Mpa) |
| 8. | Vazão de água de alimentação (kg/s) |
| 9. | Vazão de vapor (kg/s) |
| 10. | Vazão na ruptura (kg/s) |
| 11. | Vazão no circuito primário (kg/s) |
| 12. | Tempo (s) |
| 13. | Pressão no sistema primário (Mpa) |
| 14. | Potência térmica (%) |
| 15. | Potência nuclear (%) |
| 16. | Margem de sub-resfriamento (C) |
| 17. | Nível do pressurizador (%) |
| 18. | Temperatura média no primário (C) |

As figuras 6.2, 6.3, 6.4, 6.5, 6.6 e 6.7, a seguir, mostram a evolução temporal (assinatura) de cada variável de estado, listadas acima, para cada um dos 3 acidentes postulados considerando a Usina operando a 100% de potência nominal. A linha em vermelho representa o SGTR, a linha em verde representa o LOCA e a linha em azul representa o BLACKOUT, onde os índices das variáveis nas figuras correspondem as variáveis de estado listadas na tabela 6.1.

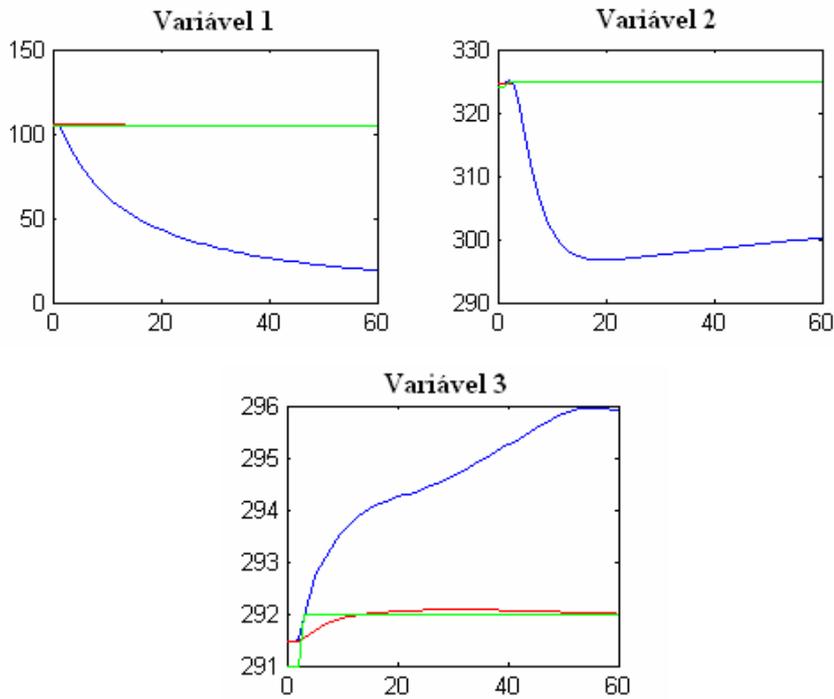


Figura 6.2. Assinatura das variáveis de estado 1, 2 e 3 para cada um dos 3 acidentes postulados considerando a Usina operando a 100% de potência nominal.

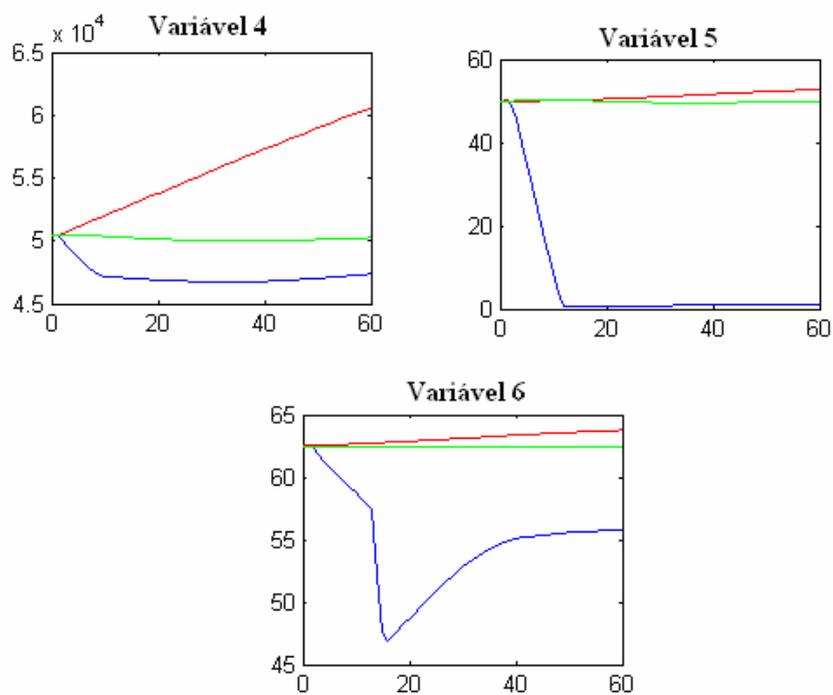


Figura 6.3. Assinatura das variáveis de estado 4, 5 e 6 para cada um dos 3 acidentes postulados considerando a Usina operando a 100% de potência nominal.

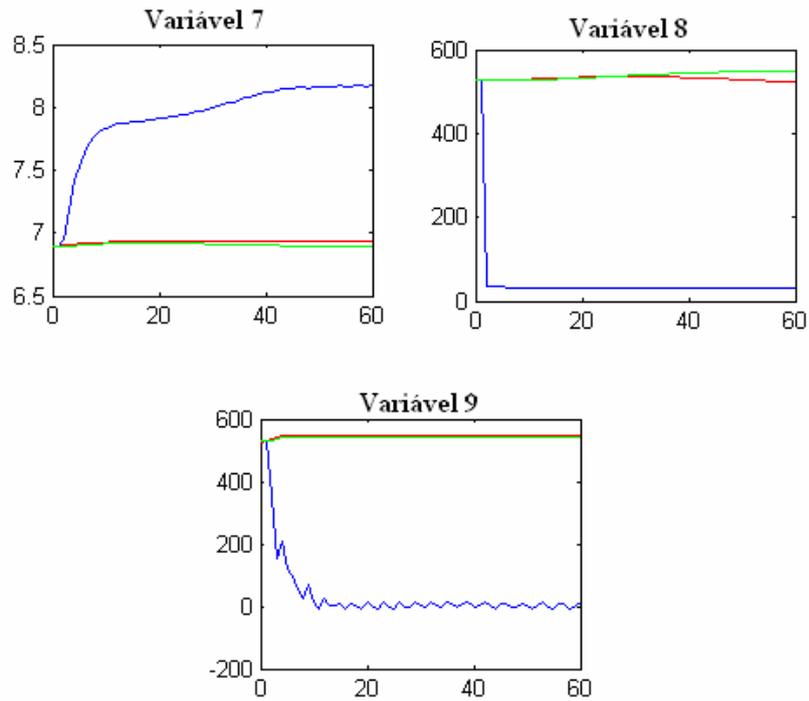


Figura 6.4. Assinatura das variáveis de estado 7, 8 e 9 para cada um dos 3 acidentes postulados considerando a Usina operando a 100% de potência nominal.

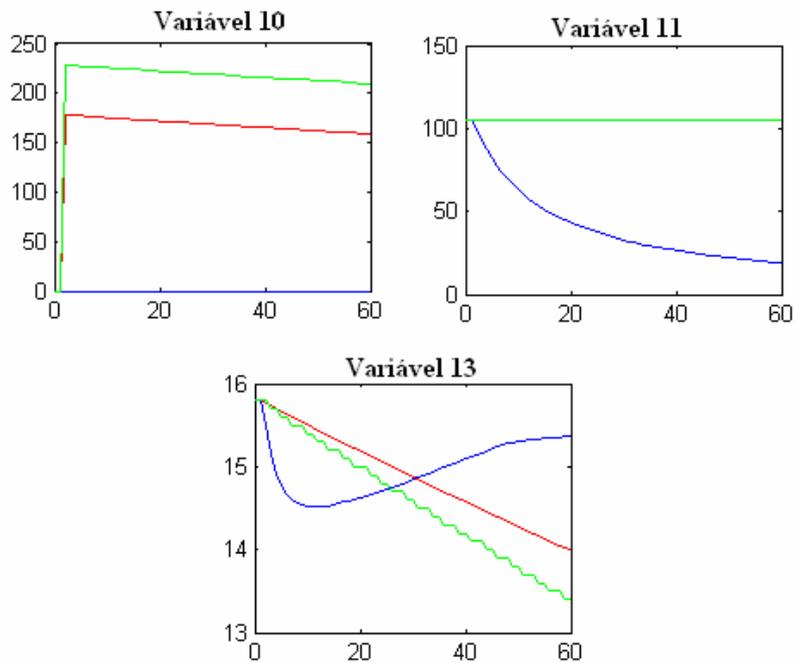


Figura 6.5. Assinatura das variáveis de estado 10, 11 e 13 para cada um dos 3 acidentes postulados considerando a Usina operando a 100% de potência nominal.

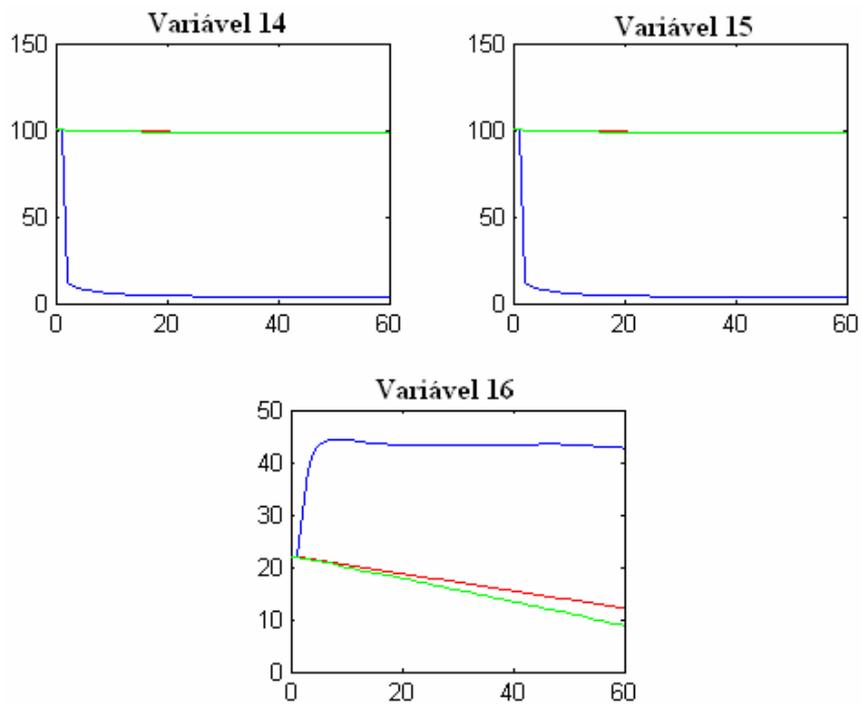


Figura 6.6. Assinatura da variável de estado 14, 15 e 16 para cada um dos 3 acidentes postulados considerando a Usina operando a 100% de potência nominal.

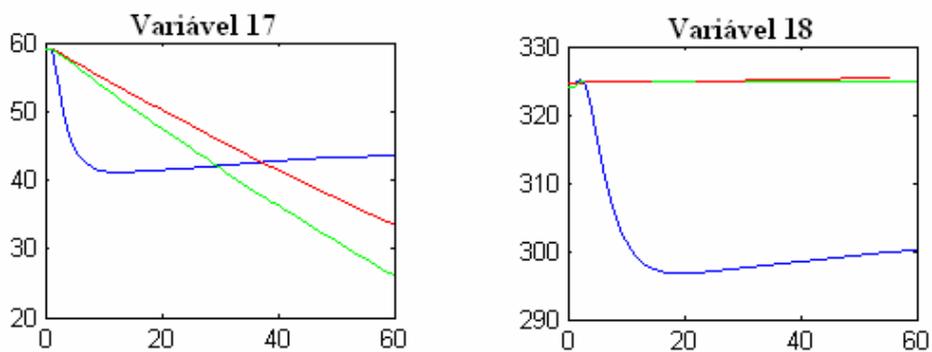


Figura 6.7. Assinatura da variável de estado 17 e 18 para cada um dos 3 acidentes postulados considerando a Usina operando a 100% de potência nominal.

6. 4. Configuração do QEA

O modelo do QEA, adotado para ser implementado no problema de identificação de acidentes/ transiente corresponde basicamente ao mesmo modelo do QEA usado no

capítulo 4, porém com uma nova definição para o portão quântico.

A rotação quântica, usada no QEA original descrito no capítulo 3 deste trabalho, pode induzir a convergência prematura de cada Q-bit', para os estados $|0\rangle$ ou $|1\rangle$, sendo assim, o Q-bit não consegue escapar desses estados, por si só, embora exista uma pequena probabilidade de ser mudado por uma atualização global. Se $|\alpha|^2 = 0$ ou $|\beta|^2 = 1$, o estado observado para o Q-bit será sempre $|0\rangle$ ou $|1\rangle$. Para evitar a convergência prematura do Q-bit, HAN *et.al.*, 2004 propuseram o portão quântico *He* (Q-gate), definido por: $[\alpha'_i \beta'_i]^T = He(\alpha_i, \beta_i, \Delta\theta_i)$. Onde, $[\alpha''_i \beta''_i]^T = R(\Delta\theta_i)(\alpha_i, \beta_i)^T$. Dessa forma, a nova atualização do Q-bit é dado por:

$$\text{i) Se } |\alpha''_i|^2 \leq \varepsilon \text{ e } |\beta''_i|^2 \leq 1 - \varepsilon$$

$$[\alpha'_i \beta'_i]^T = [\sqrt{\varepsilon} \sqrt{1 - \varepsilon}]^T$$

$$\text{ii) Se } |\alpha''_i|^2 \leq 1 - \varepsilon \text{ e } |\beta''_i|^2 \leq \varepsilon$$

$$[\alpha'_i \beta'_i]^T = [\sqrt{1 - \varepsilon} \sqrt{\varepsilon}]^T$$

iii) Outros casos

$$[\alpha'_i \beta'_i]^T = [\alpha''_i \beta''_i]^T$$

Onde $0 < \varepsilon < 1$, $R(\Delta\theta_i)$ é a rotação do portão quântico, e $\Delta\theta_i$, $i = 1, 2, \dots, m$, e o ângulo de rotação para o Q-bit tanto na direção do estado $|0\rangle$ ou $|1\rangle$, dependendo do seu sinal.

A figura 6.6 mostra o portão quântico *He* e o portão quântico do QEA original. Onde $\lim_{t \rightarrow 0} He$ é o portão quântico de rotação original. Enquanto o portão quântico do QEA original faz a probabilidade para $|\alpha|^2$ ou $|\beta|^2$ convergir para 0 ou 1, o portão

quântico He faz convergir para ε ou $1 - \varepsilon$. Vale notar que se ε for grande, a tendência de convergência do indivíduoQ-bit pode desaparecer.

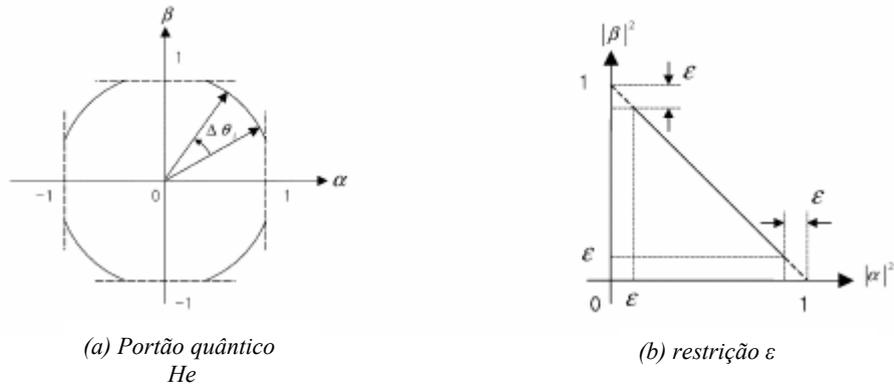


Figura 6.8. Portão quântico He baseado no portão quântico do QEA original.

Cada indivíduoQ-bit do QEA consiste de um vetor de 57×12 bits (57 variáveis com 12 bits de precisão), os primeiros 19×12 bits correspondem ao centróide do acidente 1, os 19×12 bits seguintes correspondem ao centróide do acidente 2 e os 19×12 últimos bits correspondem ao centróide do acidente 3.

O QEA foi inicializado com $Qid_j = \left[\frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}} \right]$, onde Qid_j corresponde ao bit j do indivíduoQ-bit, com $j = 1, 2, \dots, m$, onde m corresponde ao número de Q-bits, com uma população de 100 indivíduos e $\varepsilon = 0.01$.

6. 5. Análise e Resultados

Esta seção teve como objetivo avaliar o desempenho do QEA, quando aplicado ao problema de Identificação de Transiente de uma Usina Nuclear do tipo PWR, operando a uma potência de 100%. O eixo do tempo foi particionado em 60 pontos após o início do transiente, 61 pontos no total, com número máximo de classificações corretas igual a $((3 \text{ acidentes}) \times (61 \text{ pontos})) = 183$.

Na tabela 6.2 encontram-se os resultados dos testes realizados com uma população de 100 indivíduos, com diferentes valores para o parâmetro Δ do QEA, bem como o número de classificações corretas do conjunto dos transientes selecionados. Pode-se observar que quanto maior o valor do passo Δ , mais rápida é a convergência do algoritmo para um ótimo local. Quanto menor o valor do passo Δ , mais demorada é a convergência do algoritmo, porém mais refinada é a busca do algoritmo levando-o a convergir para o ótimo global.

Os resultados obtidos pelo método proposto foram superiores aqueles obtidos por métodos semelhantes (ALMEIDA, 2001, MEDEIROS, 2005) na identificação do problema dos três transientes postulados. O QEA permitiu uma solução que se aproxima da solução ideal, Vetores de Voronoi, para a classificação do transiente. Mostrando-se robusto e eficaz na classificação dos transientes selecionados e destacou-se como uma potencial técnica de otimização para problemas na área de engenharia nuclear.

Tabela.6.2 Resultados do QEA

| <i>QEA</i> | <i>Classificações</i> | | |
|------------|----------------------------|----------------|-----------------|
| | <i>Δ</i> | <i>Geração</i> | <i>corretas</i> |
| | 0.05* π | 5000 | 177 |
| | 0.005* π | 5000 | 177 |
| | 0.0005* π | 5000 | 183 |

Na figura 6.9 encontra-se a representação dos vetores protótipos encontrados pelo QEA no sistema de identificação de acidentes/transientes proposto nesta dissertação. O eixo y e o eixo x na figura 6.8 representa respectivamente, a variação temporal da variável 1 da tabela 6.1 normalizada no intervalo [0-1], e o tempo em segundos. Além disso, o círculo em vermelho representa o vetor protótipo do LOCA, a cruz em azul representa o vetor protótipo do BLACKOUT e o triângulo em rosa representa o vetor protótipo do SGTR. O gráfico foi gerado pelo sistema de identificação com algoritmo QEA, com 100 indivíduos, com $\Delta = 0,0005*\pi$ em 1000 gerações.

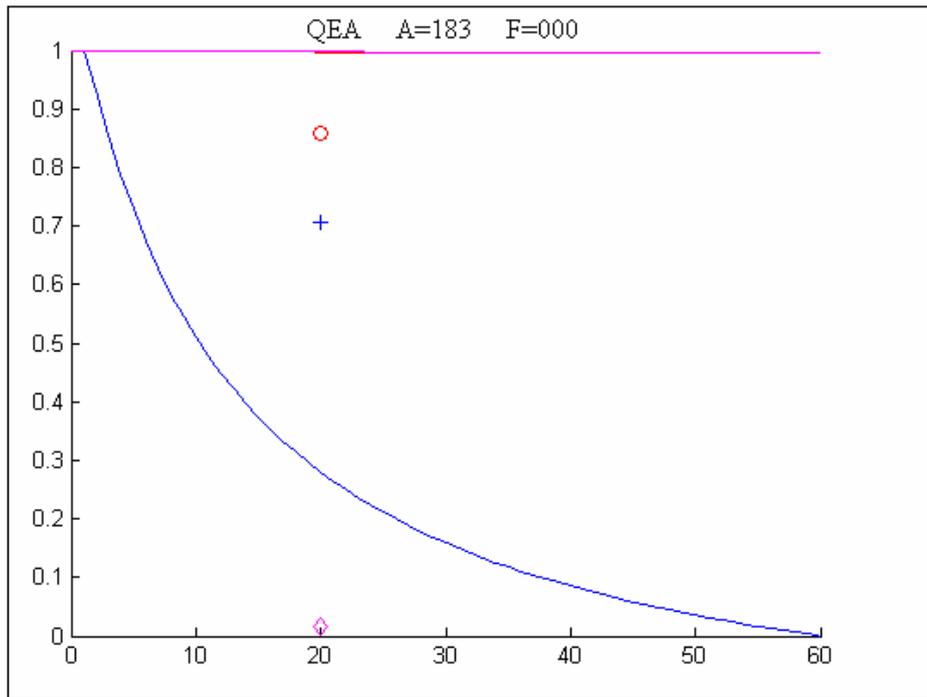


Figure 6.9. Representação dos protótipos de cada acidente.

Na figura 6.10 encontra-se o gráfico de convergência do algoritmo QEA, com 100 indivíduos, $\Delta = 0,0005 \cdot \pi$ em 3000 gerações. Observa-se que o algoritmo apresenta vários estados estacionários, ou seja, permanece entre as algumas gerações sem evolução significativa de aprendizagem. O maior desses estados estacionários aparece entre a geração 400 e 1000, onde o algoritmo converge para um ótimo local (177), vindo somente a convergir para o ótimo global (183) perto da geração 1000.

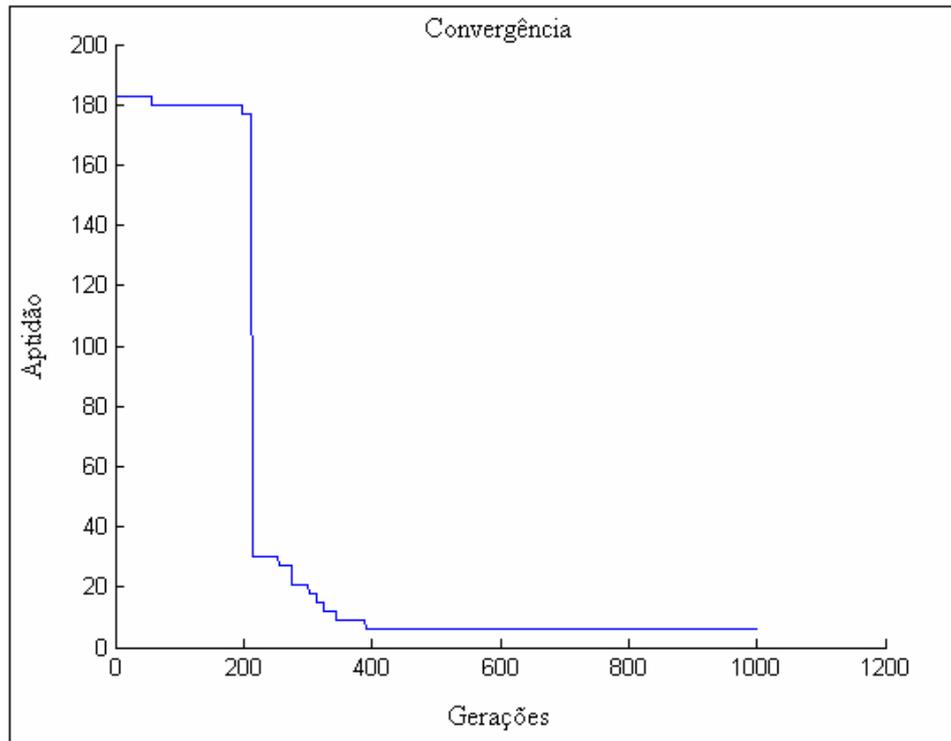


Figure 6.10. Convergência do QEA

6. 5. 1. Comparação do QEA com o PSO e GA na otimização do problema de identificação de acidentes/transientes de uma Usina Nuclear PWR.

Os algoritmos GA e PSO foram implementados no ambiente MATLAB, com o propósito de comparar os resultados obtidos em trabalhos anteriores (ALMEIDA, 2001, MEDEIROS, 2005) com os resultados encontrados pelo QEA neste trabalho para a otimização do problema de identificação de acidentes/transientes de uma Usina Nuclear do tipo PWR. Em cada algoritmo foram realizados testes com 10 sementes diferentes, em 100 gerações, com uma população de 500 indivíduos.

Na tabela 6.3 encontram-se os resultados dos testes realizados, bem como o número de classificações corretas do conjunto dos transientes selecionados, encontrado pelo QEA, GA e PSO. Pode-se observar na tabela 6.4 que os resultados obtidos com o QEA mostram soluções com resultados compatíveis, e até superiores, aos resultados obtidos nas soluções da literatura pelo PSO e GA, na solução do problema de identificação de acidentes, permitindo uma solução que se aproxima da solução ideal,

dos Vetores de Voronoi para a identificação das classes de acidentes/transientes selecionados.

Tabela 6.3. Comparação entre os algoritmos QEA, PSO e GA.

| <i>Classificações corretas</i> | <i>QEA</i> | <i>GA</i> | <i>PSO</i> |
|--------------------------------|------------|-----------|------------|
| Máximo | 183 | 183 | 177 |
| Mínimo | 159 | 003 | 015 |

6. 5. 2. Outros testes

Após os testes de implementação do modelo do sistema protótipo de identificação de acidentes/transientes, foram realizados outros testes com o objetivo de observar a robustez e eficácia do modelo proposto.

- **Teste 1: Tempo Fixo**

No primeiro teste, fixamos o valor da variável tempo, do quadro de variáveis de estado, utilizada pelo sistema para identificar o acidente/transiente. Pode-se observar nas figuras 6.11, 6.12, 6.13 e 6.14 que para cada valor de tempo fixado o sistema encontrava um vetor protótipo com o maior número de classificações corretas, além disso, o vetor protótipo encontrado, pelo sistema, era exatamente o mesmo para qualquer valor de tempo fixado.

O eixo y e o eixo x nas figuras 6.11, 6.12, 6.13 e 6.14 representa respectivamente, a variação temporal da variável 1 da tabela 6.1 normalizada no intervalo [0-1], e o tempo em segundos. O círculo em vermelho, nas figuras abaixo, representa o vetor protótipo do LOCA, a cruz em azul representa o vetor protótipo do BLACKOUT e o triângulo em rosa representa o vetor protótipo do SGTR. O gráfico foi gerado pelo sistema de

identificação com algoritmo QEA, com 100 indivíduos, com $\Delta = 0,0005*\pi$ em 1000 gerações.

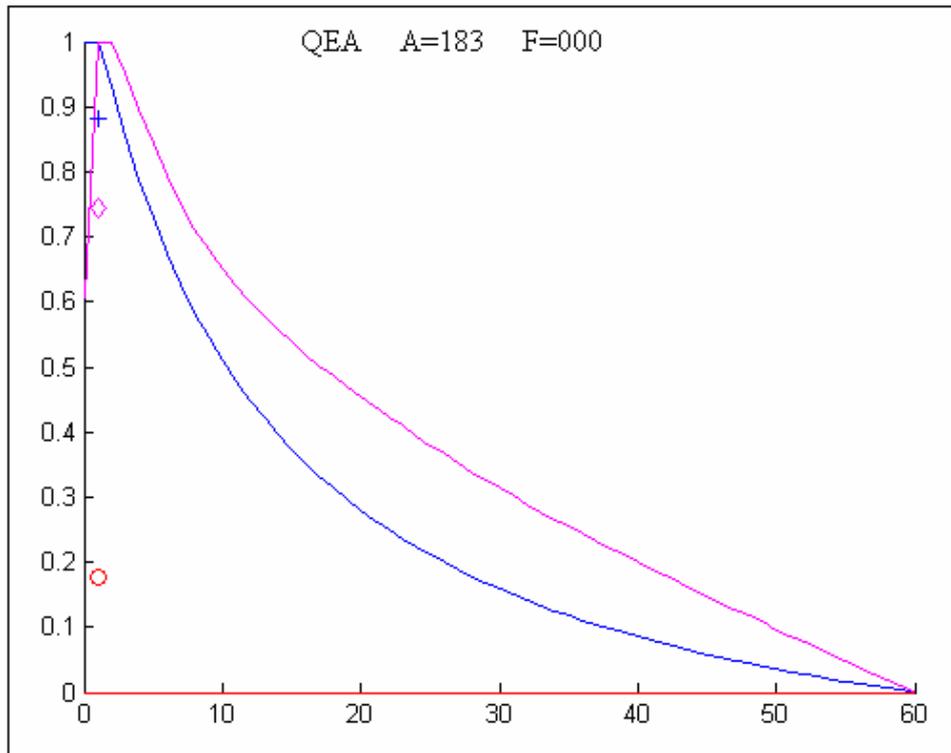


Figure 6.11. Representação dos protótipos de cada acidente com o $t=1s$.

As tabelas 6.4, 6.5, 6.6, e 6.7 apresentam os vetores protótipos encontrados pelo QEA, nos tempos, $t = 1$, $t = 30$, $t = 50$ e $t = 60$. Os vetor protótipos encontrados pelo QEA apresentados nessas tabelas são formados pela variável tempo mais as 18 variáveis da tabela 6.1, normalizadas no intervalo $[0-1]$, que encontra o número máximo de classificações corretas. Os dezenove primeiros componentes desses vetores representam o vetor protótipo do acidente BLACKOUT, os dezenove seguintes representam o vetor protótipo do acidente LOCA e os dezenove últimos o vetor protótipo do SGTR, onde o primeiro componente de cada vetor protótipo é a variável tempo. O vetor protótipo encontrado para $t=1s$ foi:

Tabela 6.4. Vetor protótipo $t = 1s$

| | | | | | | | | |
|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 1.0000 | 0.8808 | 0.5319 | 0.3592 | 0.5526 | 0.6371 | 0.5231 | 0.2654 | 0.8183 |
| 0.3634 | 0.0784 | 0.0823 | 0.2882 | 0.3888 | 0.0269 | 0.5932 | 0.5201 | 0.0818 |
| 0.8545 | 1.0000 | 0.0728 | 0.7197 | 0.4821 | 0.8125 | 0.6962 | 0.3883 | 0.0376 |
| 0.9223 | 0.2476 | 0.7282 | 0.1082 | 0.1856 | 0.5602 | 0.4264 | 0.4168 | 0.7377 |
| 0.2811 | 0.2987 | 1.0000 | 0.7451 | 0.1792 | 0.4332 | 0.5140 | 0.6759 | 0.3084 |
| 0.6210 | 0.5013 | 0.4183 | 0.9538 | 0.3485 | 0.1612 | 0.7929 | 0.7695 | 0.1680 |
| 0.6457 | 0.2505 | 0.8899 | | | | | | |

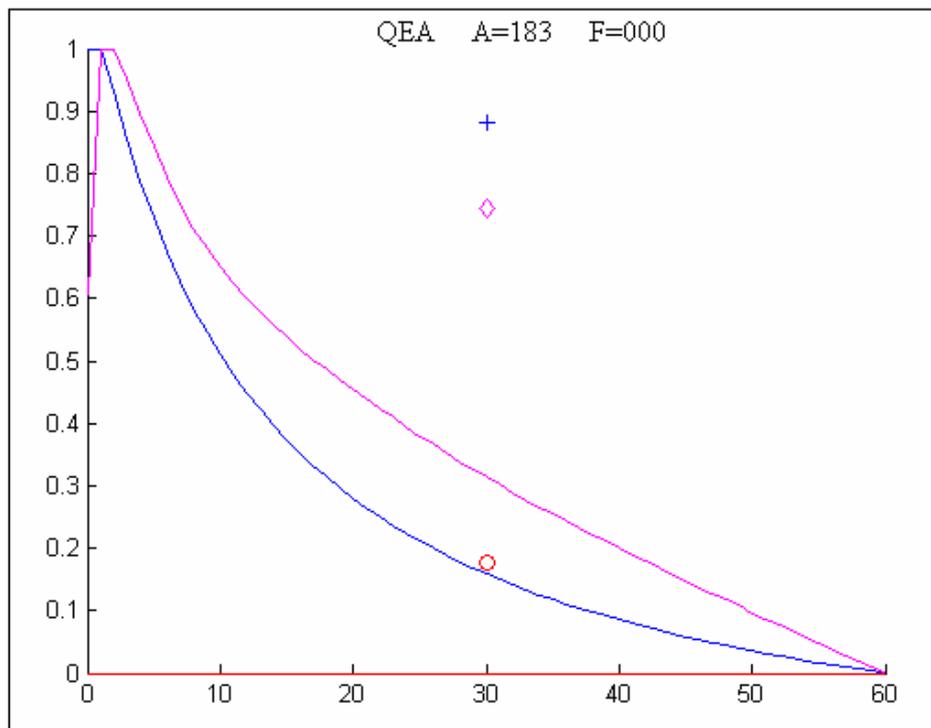


Figure 6.12. Representação dos protótipos de cada acidente com o $t = 30s$.

Tabela 6.5. Vetor protótipo $t = 30s$

| | | | | | | | | |
|---------|---------|---------|--------|--------|--------|--------|--------|--------|
| 30.0000 | 0.8808 | 0.5319 | 0.3592 | 0.5526 | 0.6371 | 0.5231 | 0.2654 | 0.8183 |
| 0.3634 | 0.0784 | 0.0823 | 0.2882 | 0.3888 | 0.0269 | 0.5932 | 0.5201 | 0.0818 |
| 0.8545 | 30.0000 | 0.0728 | 0.7197 | 0.4821 | 0.8125 | 0.6962 | 0.3883 | 0.0376 |
| 0.9223 | 0.2476 | 0.7282 | 0.1082 | 0.1856 | 0.5602 | 0.4264 | 0.4168 | 0.7377 |
| 0.2811 | 0.2987 | 30.0000 | 0.7451 | 0.1792 | 0.4332 | 0.5140 | 0.6759 | 0.3084 |
| 0.6210 | 0.5013 | 0.4183 | 0.9538 | 0.3485 | 0.1612 | 0.7929 | 0.7695 | 0.1680 |
| 0.6457 | 0.2505 | 0.8899 | | | | | | |

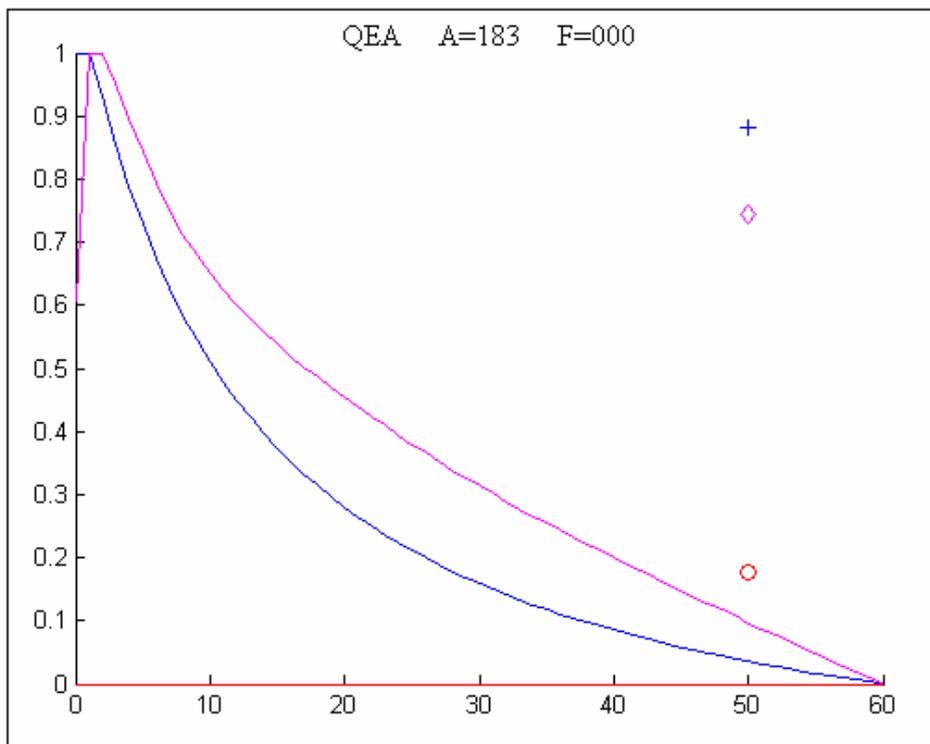


Figure 6.13. Representação dos protótipos de cada acidente com o $t = 50s$.

Tabela 6.6. Vetor protótipo $t = 50s$

| | | | | | | | | |
|---------|---------|---------|--------|--------|--------|--------|--------|--------|
| 50.0000 | 0.8808 | 0.5319 | 0.3592 | 0.5526 | 0.6371 | 0.5231 | 0.2654 | 0.8183 |
| 0.3634 | 0.0784 | 0.0823 | 0.2882 | 0.3888 | 0.0269 | 0.5932 | 0.5201 | 0.0818 |
| 0.8545 | 50.0000 | 0.0728 | 0.7197 | 0.4821 | 0.8125 | 0.6962 | 0.3883 | 0.0376 |
| 0.9223 | 0.2476 | 0.7282 | 0.1082 | 0.1856 | 0.5602 | 0.4264 | 0.4168 | 0.7377 |
| 0.2811 | 0.2987 | 50.0000 | 0.7451 | 0.1792 | 0.4332 | 0.5140 | 0.6759 | 0.3084 |
| 0.6210 | 0.5013 | 0.4183 | 0.9538 | 0.3485 | 0.1612 | 0.7929 | 0.7695 | 0.1680 |
| 0.6457 | 0.2505 | 0.8899 | | | | | | |

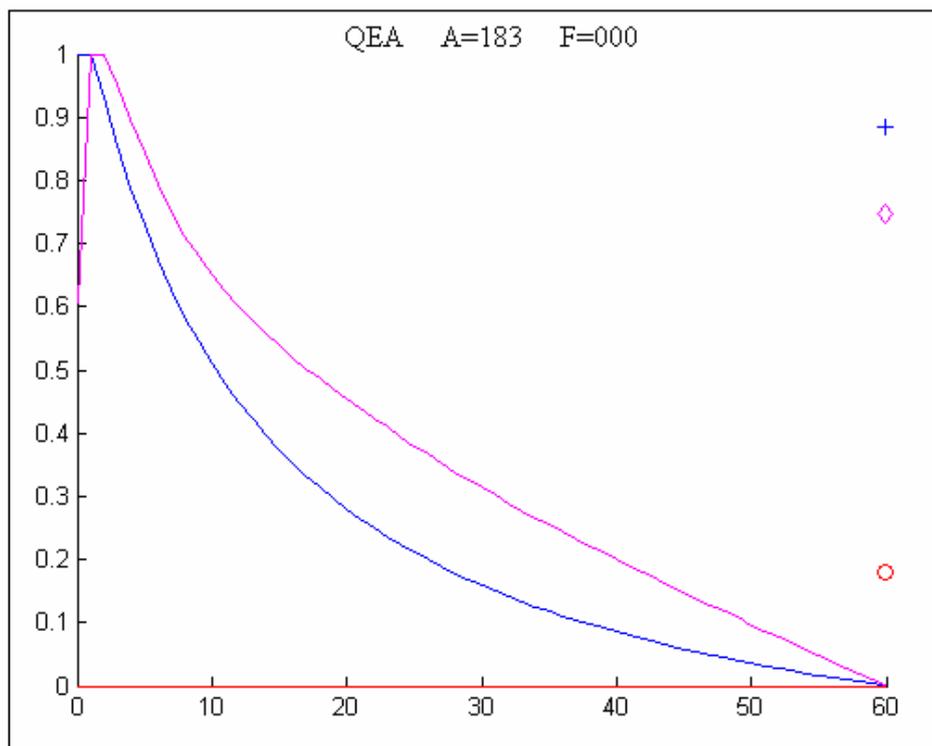


Figure 6.14. Representação dos protótipos de cada acidente com o $t = 60s$.

Tabela 6.7. Vetor protótipo $t = 60s$

| | | | | | | | | |
|---------|---------|---------|--------|--------|--------|--------|--------|--------|
| 60.0000 | 0.8808 | 0.5319 | 0.3592 | 0.5526 | 0.6371 | 0.5231 | 0.2654 | 0.8183 |
| 0.3634 | 0.0784 | 0.0823 | 0.2882 | 0.3888 | 0.0269 | 0.5932 | 0.5201 | 0.0818 |
| 0.8545 | 60.0000 | 0.0728 | 0.7197 | 0.4821 | 0.8125 | 0.6962 | 0.3883 | 0.0376 |
| 0.9223 | 0.2476 | 0.7282 | 0.1082 | 0.1856 | 0.5602 | 0.4264 | 0.4168 | 0.7377 |
| 0.2811 | 0.2987 | 60.0000 | 0.7451 | 0.1792 | 0.4332 | 0.5140 | 0.6759 | 0.3084 |
| 0.6210 | 0.5013 | 0.4183 | 0.9538 | 0.3485 | 0.1612 | 0.7929 | 0.7695 | 0.1680 |
| 0.6457 | 0.2505 | 0.8899 | | | | | | |

Através dos testes realizados pode-se concluir que em cada tempo t , existe um mesmo conjunto de três vetores protótipos que encontram o número máximo de classificações corretas, sendo assim, indica que a determinação dos protótipos independe do tempo.

- **Teste 2: Conjunto Mínimo de Variáveis**

No segundo teste, foram retiradas algumas das 18 variáveis de estado utilizadas pelo sistema proposto para classificar o evento em curso, além disso, fixamos o tempo em $t = 1s$. A lista de variáveis retirada do sistema, o vetor protótipo encontrado pelo QEA, bem como, o número máximo de acertos são apresentados a seguir:

Tabela 6.8. Variáveis de estado retiradas do sistema de identificação de acidentes/transientes e o número de acertos.

| Variáveis retiradas | Acertos |
|-----------------------------|---------|
| Potência nuclear | |
| Potência térmica | 183 |
| Temperatura da perna quente | |

Tabela 6.9. Vetor protótipo sem as variáveis da tabela 6.8.

| | | | | | | | | |
|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 1.0000 | 0.6227 | 0.0020 | 0.3741 | 0.2894 | 0.9746 | 0.1858 | 0.0271 | 0.2342 |
| 0.1697 | 0.2271 | 0.1612 | 0.5924 | 0.0835 | 0.9839 | 1.0000 | 0.2317 | 0.0391 |
| 0.8523 | 0.4027 | 0.3150 | 0.6266 | 0.5897 | 0.8354 | 0.7773 | 0.1324 | 0.6889 |
| 0.8618 | 0.1797 | 0.2129 | 1.0000 | 0.2833 | 0.3658 | 0.6794 | 0.2027 | 0.1385 |
| 0.7133 | 0.0283 | 0.8310 | 0.8703 | 0.6867 | 0.4967 | 0.8747 | 0.6007 | 0.8088 |

Tabela 6.10. Variáveis de estado retiradas do sistema de identificação de acidentes/transientes e o número de acertos.

| Variáveis retiradas | Acertos |
|-----------------------------|---------|
| Potência nuclear | |
| Potência térmica | |
| Temperatura da perna quente | 183 |
| Vazão do núcleo em (kg/s) | |

Tabela 6.11. Vetor protótipo sem as variáveis da tabela 6.10.

| | | | | | | | | |
|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 1.0000 | 0.5612 | 0.8269 | 0.4879 | 0.6823 | 0.8051 | 0.4518 | 0.1328 | 0.1013 |
| 0.5578 | 0.0210 | 0.3018 | 0.4701 | 0.8354 | 1.0000 | 0.1856 | 0.3648 | 0.2718 |
| 0.7939 | 0.7726 | 0.9433 | 0.4567 | 0.6960 | 0.2210 | 0.0020 | 0.1209 | 0.5363 |
| 0.2352 | 1.0000 | 0.1001 | 0.4442 | 0.2288 | 0.3907 | 0.5934 | 0.5050 | 0.2847 |
| 0.7016 | 0.5766 | 0.3656 | 0.3241 | 0.2767 | | | | |

Tabela 6.12. Variáveis de estado retiradas do sistema de identificação de acidentes/transientes e o número de acertos.

| Variáveis retiradas | Acertos |
|-----------------------------|---------|
| Potência nuclear | |
| Potência térmica | |
| Temperatura da perna quente | 183 |
| Vazão do núcleo em (kg/s) | |
| Nível do GV faixa larga (%) | |

Tabela 6.13. Vetor protótipo sem as variáveis da tabela 6.12.

| | | | | | | | | |
|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 1.0000 | 0.3832 | 0.2466 | 0.1915 | 0.8972 | 0.1678 | 0.9155 | 0.0249 | 0.0239 |
| 0.3902 | 0.4298 | 0.8447 | 0.3253 | 0.7695 | 1.0000 | 0.0093 | 0.4659 | 0.1270 |
| 0.3836 | 0.0154 | 0.6374 | 0.9985 | 0.6508 | 0.3421 | 0.8767 | 0.9267 | 0.6896 |
| 0.4413 | 1.0000 | 0.3292 | 0.0542 | 0.0664 | 0.2425 | 0.4447 | 0.3827 | 0.6628 |
| 0.5309 | 0.7639 | 0.2371 | 0.5368 | 0.9846 | 0.7548 | | | |

Através da análise dos resultados encontrados nos testes acima, pode-se concluir que existem vários conjuntos de variáveis de estado, não necessariamente mínimo, suficientes para que o sistema determine o número máximo de classificação corretas.

Analisando os resultados encontrados pelo sistema protótipo de identificação de acidentes/transientes, proposto neste trabalho, foi verificado que na maioria dos testes realizados ele acertava 177 vezes ao invés de 183. Mas, analisando as tabelas de evolução temporal das 18 variáveis de estado de cada acidente, foi possível constatar que as duas primeiras linhas dos primeiros segundos de cada acidente/transiente eram exatamente iguais, o que induziria o sistema ao erro nas primeiras classificações. Sendo assim, o número de pontos passa de 61 para 59 e, o número máximo de acertos passa a

ser $59 \times 3 = 177$. Dessa forma, pode-se dizer que o sistema proposto é robusto e eficaz na identificação de acidentes/transientes.

As tabelas 6.14 e 6.15, apresentam a evolução temporal das variáveis da tabela 6.1, não normalizadas, dos acidentes BLACKOUT, LOCA e SGTR.

Tabela 6.14. Primeira linha de cada acidente/transiente

| BLACKOUT | | | | |
|-----------------|--------------|--------------|--------------|--------------|
| +1.05223E+03 | +3.24465E+03 | +2.91456E+03 | +5.04184E+05 | +5.00000E+02 |
| +6.25153E+02 | +6.89480E+01 | +5.27767E+03 | +5.27767E+03 | +0.00000E+00 |
| +1.05223E+03 | +0.00000E+00 | +1.58000E+02 | +1.00000E+03 | +1.00000E+03 |
| +2.18620E+02 | +5.91491E+02 | +3.07959E+03 | | |
| SGTR | | | | |
| +1.05223E+03 | +3.24465E+03 | +2.91456E+03 | +5.04183E+05 | +5.00000E+02 |
| +6.25152E+02 | +6.89480E+01 | +5.27767E+03 | +5.27767E+03 | +0.00000E+00 |
| +1.05223E+03 | +0.00000E+00 | +1.58000E+02 | +1.00000E+03 | +1.00000E+03 |
| +2.18620E+02 | +5.91491E+02 | +3.07959E+03 | | |
| LOCA | | | | |
| +1.05223E+03 | +3.24465E+03 | +2.91456E+03 | +5.04184E+05 | +5.00000E+02 |
| +6.25153E+02 | +6.89480E+01 | +5.27767E+03 | +5.27767E+03 | +0.00000E+00 |
| +1.05223E+03 | +0.00000E+00 | +1.58000E+02 | +1.00000E+03 | +1.00000E+03 |
| +2.18620E+02 | +5.91491E+02 | +3.07959E+03 | | |

Tabela 6.15. Segunda linha de cada acidente/transiente

| BLACKOUT | | | | |
|-----------------|--------------|---------------|---------------|---------------|
| +1.05390E+03 | +3.24463E+03 | +2.91457E+03 | +5.04183E+05 | +5.00078E+02 |
| +6.25169E+02 | +6.89413E+01 | +5.27890E+03 | +5.28396E+03 | +0.000000E+00 |
| +1.05390E+03 | +1.00000E+01 | +1.157999E+02 | +1.100005E+03 | +1.100005E+03 |
| +2.18967E+02 | +5.91357E+02 | +3.07942E+03 | | |
| SGTR | | | | |
| +1.05390E+03 | +3.24463E+03 | +2.91457E+03 | +5.04182E+05 | +5.00078E+02 |
| +6.25169E+02 | +6.89414E+01 | +5.27890E+03 | +5.28396E+03 | +0.000000E+00 |
| +1.05390E+03 | +1.00000E+01 | +1.157999E+02 | +1.100005E+03 | +1.100005E+03 |
| +2.18967E+02 | +5.91357E+02 | +3.07942E+03 | | |
| LOCA | | | | |
| +1.05390E+03 | +3.24463E+03 | +2.91457E+03 | +5.04183E+05 | +5.00078E+02 |
| +6.25169E+02 | +6.89413E+01 | +5.27890E+03 | +5.28396E+03 | +0.000000E+00 |
| +1.05390E+03 | +1.00000E+01 | +1.157999E+02 | +1.100005E+03 | +1.100005E+03 |
| +2.18967E+02 | +5.91357E+02 | +3.07942E+03 | | |

CAPÍTULO 7

CONCLUSÕES E PROPOSTAS PARA TRABALHOS FUTUROS

7.1. Conclusões

Nesta dissertação exploramos a capacidade dos algoritmos evolucionários de otimização com inspiração quântica, QEA e QSE, mostrando a viabilidade dos algoritmos como ferramentas de otimização em espaços de busca contínuos e discretos de alta dimensão. Além disso, este trabalho mostra pela primeira vez a viabilidade de aplicação do algoritmo QEA em problemas reais multimodais e complexos de alta dimensão, como o Problema de Identificação de acidentes/transientes de uma Usina Nuclear PWR.

Inicialmente devemos ressaltar a simplicidade dos algoritmos com inspiração quântica QEA e QSE, cuja implementação é facilmente traduzida a partir das equações que definem o modelo canônico dos algoritmos. Além disso, devemos ressaltar que nos trabalhos encontrados na literatura (HAN, 2002, WANG, 2007), os algoritmos QEA e QSE foram implementados apenas em funções de teste. Dessa forma, o presente trabalho mostra pela primeira vez a aplicação do QEA em problemas reais.

Devido à naturalidade e facilidade de representação de espaços de busca de qualquer dimensão e devido a implementação do portão *He* e aos ajustes no tamanho do passo delta (Δ), feitos nesta dissertação, o algoritmo de inspiração quântica QEA foi aplicado com sucesso na solução do Problema de Identificação de Acidentes/Transientes de uma Usina Nuclear PWR e mostrou –se eficaz na busca de soluções em espaços multimodais de alta dimensão sem necessidade de conhecimento prévio sobre a complexidade dos espaços de busca envolvidos.

Quando aplicado à solução de funções contínuas e discretas de alta dimensão o QEA apresentou resultados da ordem de 100 vezes menor, para $n = 30$, com 100 indivíduos, do que o QSE para a função esfera no intervalo $0 < x < 1$.

Quando aplicado na solução da Função 4 picos o QEA conseguiu premiar a função com $P=21$ e com $P=11$, uma vez que o QSE só premiou a função com $P=11$, além disso, o QEA apresentou resultados 33% superiores ao QSE para $P=11$ e 31% para $P=21$.

Quando aplicado ao problema de identificação de acidentes, o algoritmo QEA foi usado, como ferramenta de otimização, para encontrar a melhor posição dos centróides protótipos de cada um dos três acidentes/transientes de base de projeto, e desta forma maximizar o número de classificações corretas. Esta abordagem estabelece um modelo solução que corresponde à pesquisa dos Vetores de Voronoi para a identificação das classes de acidentes/transientes.

Os outros testes realizados com o sistema proposto, baseado no QEA mostram caminhos que podem ser explorados em outros trabalhos, como por exemplo pode-se pesquisar um conjunto mínimo de variáveis necessárias e suficientes para que o sistema encontre o número máximo de classificações corretas, além disso, a hipótese de que o modelo de sistema identificação independe do tempo induz a criação de novos métodos de identificação de acidentes/transientes de uma central nuclear.

Os resultados obtidos com o QEA mostram soluções com resultados compatíveis, e até superiores, aos resultados obtidos nas soluções da literatura usada com referência (ALMEIDA, 2001, MOL, 2002, MEDEIROS, 2005), na solução do problema de identificação de acidentes, permitindo uma solução que se aproxima da solução ideal, ou seja, dos Vetores de Voronoi das classes para a classificação de acidentes.

7.2. Propostas para trabalhos futuros

A fim de estender os resultados encontrados neste trabalho e aperfeiçoar o método de identificação de acidentes/transientes desenvolvidos nesta dissertação, ficam como sugestões para trabalhos futuros:

- a) Aplicar o método proposto a um maior número de transientes;

- b) Pesquisar o conjunto mínimo de variáveis consideradas necessárias e suficientes para a classificação dos acidentes/transientes analisados.

- c) Pesquisar a influência do parâmetro do ϵ , nos resultados do QEA.

REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, J.C. S., 2001, *Método de Identificação de Transientes com Abordagem Possibilística, Otimizado por Algoritmo Genético*. Dissertação de M.Sc., COPPE/UFRJ, Rio de Janeiro,RJ, Brasil.

ALVARENGA, M.A.B., MARTINEZ, A.S., SCHIRRU, R., 1997, “Adaptive Vector Quantization Optimized by Genetic Algorithms for Real-Time Diagnosis through Fuzzy sets”, *Nuclear Technology*, v. 120, n.3, pp.. 188 -197.

ALVARENGA M.A.B.,1997 *Diagnóstico do Desligamento de um Reator Nuclear Através de Técnicas Avançada de Inteligência Artificial*. Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

ALVES, F.L., 2003, *Computação Quântica : Fundamentos Físicos e Perspectivas*. Monografia, Departamento de Ciências da Computação da Universidade Federal de Lavras, Minas Gerais, Brasil.

BARTAL, Y., LIN, J., UHRIG, R.E., 1995, “Nuclear Power Plant Transient Diagnostics Using Artificial Neural Networks that Allow Don’t Know Classifications”, *Nuclear Technology*, vol. 110, June, pp. 346-449.

BARTLETT, E.B., UHRIG, R.E.,1992, “Nuclear Power Plant Status Diagnostics Using an Artificial Neural Network”, *Nuclear Technology*, vol. 97, Mar, pp. 272 – 281.

BASU, A., BARTLETT, E.B.,1994, “Deteting Faults in a Nuclear Power Plant by Using a Dynamic Node Architecture Artificial Neural Network”, *Nuclear Science and Engineering*, vol. 116, pp..313-325.

BERNARDO J. L., Lima F. A., 2005, *Uma Introdução a Computação Quântica, Departamento de sistemas e computação*, Universidade Federal de Campina Grande, Departamento de Física.

BONABEAU, E., THERAULZA, G. DENEUBOURG, J.L., ARON, S., CAMAZINE, S., 1997. "Self-Organization in Social Insects," *Working Papers* 97-04-032, Santa Fé Institute.

CHAPOT, J.L.C., SILVA, F.C. and SCHIRRU, R., 1999. "A New Approach to the Use of Genetic Algorithms to Solve Pressurized Water Reactor's Fuel Management Optimization Problem", *Annals of Nuclear Energy*, v.26, n.7, pp. 641 – 665.

CHRISTOFOLETTI, T. V. D., MELO, B. L. M., 2003, *Computação Quântica: Estado de Arte*. Monografia ., INE/UFSC, Santa Catarina, SC, Brasil.

CLERC, M., KENNEDY, J., 2002, "The Particle Swarm – Explosion, Stability, and Convergence in a Multidimensional Complex Space", *IEE Transactions on Evolutionary Computation*, Vol.6, N.1, February.

COELHO, C.A., 2008, *Introducción a la Computación Evolutiva*, CINVESTAV-IPN, Departamento de Computación, México.

COLLINS, G.P., 2006, "Nós quânticos na Computação", *Scientific American*, ano 4, nº48 (Maio), pp. 49-55 .

DARWIN, C.R.,1859. *On the Origin of Species by means of natural selection, or the preservation of favoured races in the struggle for life* 1ed. London: John Merray.

DEUTSCH, D., 1985, "Quantum Theory, the Church-turing Principle and the universal quantum computer", *Proceedings of the Royal Society*, v. 400, pp. 97-117.

EISBERG R., RESNICK, 1994, *Física Quântica*, 9 ed. Editora Campus / Elsevier.

ELETRONUCLEAR, Final Safety Analysis Report, - FSAR, 2007, revisão 30, Rio de Janeiro.

FURUKAWA, H., UEDA, T., KITAMURA, M.,1995, "Use of Self-Organizing Neural Networks for Rational Definition of Palnt Diagnostic Symptoms", *Proceedings of the*

International Topical Meeting on Computer- Based Human Support System, pp. 441-448.

GOLDBERG D.E, 1989, *Genetic Algorithms in Search Optimization and Machine Learning*, Addison – Wesley Publishing Company, Reading, Massachusetts.

GRAY, F., Pulse Code Communication, March 17, 1953, U.S. patent n° 2.632.058.

HAN, K.; KIM, J., 2000, “Genetic quantum algorithm and its application to combinatorial optimization problem”, *Congress on Evolutionary Computation*, v. 2, p.p. 1354–1360.

HAN K.H., Kim, 2002, “Quantum-inspired evolutionary algorithm for a class of combinatorial optimization”, *IEEE IEEE Service Center*, pp. 580–593, Piscataway, NJ.

HAYKIN, S., 1994 *Neural Networks – A Comprehensive Foudation*. Macmillan College publishing Company, New York.

IAEA –International Nuclear Safety Advisory Group, 1999, “Basic Safety Principles for Nuclear Power Plant – 75, INSAG -3, Rev.1, INSAG -12”.

JEONG, E., FURUTA, K., KONDO, S.,1996, “Identification of Transient in Nuclear Power Plant Using Adaptive Template Matching with Neural Network, Proceedings of the International Topical Meeting on Nuclear Plant Instrumentation”, *Control and Human Machine Interface Tecnologies*, pp. 243-250.

KENNEDY J., EBERHART R.C., 1995, “Particle Swarm Optimization”, *Proc IEEE International Conference on Neural Net Works*, pp. IV: 1942-1948, Perth, Australia.

KENNEDY J., EBERHART R.C., Shi Y., 2001, *Swarm Intelligence*, **Morgan Kaufmann Publishers**. Inc, San Francisco, CA.

MACHADO M.D., 1999, *Um Novo Algoritmo Evolucionário Com Aprendizado LVQ Para Otimização de Problemas Combinatórios Como a Recarga de Reatores Nucleares*. Dissertação de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

MARTINEZ, A.S., OLIVEIRA, L.F.S., SCHIRRU, R., et al, 1986, “A new concept of safety parameter display system”. *In annals of the seminar on nuclear Engineering in latin America*, Asn, Mexico.

MARTINS, B.L.M., CHRISTOFOLETTI, V.D., 2003, *Computação Quântica – Estado de Artes*, Bacharelado em Ciências da Computação, INE, Universidade Federal de Santa Catarina (UFSC), Brasil.

MEDEIROS J.A.C.C., 2005, *Exames de Partículas como Ferramenta de Otimização em Problemas Complexos da Engenharia Nuclear*. Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

MOL, A.C.A., 2002, *Um Sistema de Identificação de Transientes com Inclusão de Ruídos e Indicação de Eventos Desconhecidos*, Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

MOORE, M.; NARAYANAN, A., 1995, “Quantum-inspired computing”, 2.4

NICOLAU, A.S., SCHIRRU, R., MEDEIROS, J.A.C.C, 2009, “Quantum computation and Swarm Intelligence Applied in the Optimization of Indentifications Accidents in a PWR Nuclear Power Plant”, COPPE/UFRJ, *INAC*.

NUREG -0585 - NUCLEAR REGULATORY COMMISSION, 1979, “TMI2 Lessons Learned Task Force Final Report”.

NUREG -0933 - NUCLEAR REGULATORY COMMISSION, 2008, “Resolution of Generic Safety Issues: Task HF5: Man-Machine Interface (Rev. 4) (Main Report with Supplements 1–32)”.

OLIVEIRA, I.S., SARTHOUR, R.S., 2004, “Computação Quântica e Informação Quântica”, 1ed., Centro Brasileiro de Pesquisas Físicas, Escola do CBPF – Rio de Janeiro.

PEREIRA, C.M.N.A., SCHIRRU, R., MARTINEZ, A.S., 1998, “Learning an optimized Classification System From a Data Base of Time Series Patterns Using Genetic Algorithm”. 1 ed. *Computation Mechanics Publications*, WIT Press, Inglaterra.

ROVERSO, D., 1998, “A Neural Model for Event Identification in Dynamic Processes. In: Report HWR-516”, *OECD HALDEN REACTOR PROJECT*, Institutt for Energieteknikk, Norway.

PARSOPOULOS, K.E, VRAHATIS, M.N., 2002. “Particle Swarm Optimization Method in Multiobjective Problems”. SAC, Madrid, Spain.

PORTUGAL, R., LAVOR, C. C., CARVALHO L. M., MACULAN N., 2004, “Uma Introdução aos Algoritmos Quânticos” Mini-curso apresentado na IV Escola Regional de Informática do Rio de Janeiro/Espírito Santo, **Sociedade Brasileira de Computação**.

SCHIRRU, R., PEREIRA, C.M.N.A, CHAPOT, L., CARVALHO, F., A., 1997, “Genetic Algorithm Solution for a Combinatorial Problems – The Nuclear Core Reload”, *Example, XI Encontro Nacional de Física de Reatores*, p.p.357-360.

SHI Y., EBERHART R.C., 1999, “Empirical Study of Particle Swarm Optimization”, *Congress of Evolutionary Computation*, vol.3, 1945-1950.

SHI Y., EBERHART R.C., 2000, “Comparing Inertia Weights and Constriction Factors in Particle Swarm Optimization”. *IEEE Service Center*.

SHOR, P.W., “Algorithms for quantum computation: discrete log and factoring”, *Proceedings of the 35th Annual Symposium on the Foundations of Computer Science*, S. Goldwasser (editor), *IEEE Computer Society Press*, Los Alamitos, 1994, pp. 124-134.

WANG Y. et. al., 2006, "A Novel Quantum Swarm Evolutionary Algorithm and its Applications, Neuro Computing", vol. 70, pp. 633-640, ISSUES 4-6.