



ALGORITMO EVOLUCIONÁRIO DE INSPIRAÇÃO QUÂNTICA APLICADO NA OTIMIZAÇÃO DE PROBLEMAS DA ENGENHARIA NUCLEAR

Andressa dos Santos Nicolau

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

Orientador: Roberto Schirru

Rio de Janeiro
Fevereiro de 2014

ALGORITMO EVOLUCIONÁRIO DE INSPIRAÇÃO QUÂNTICA APLICADO NA
OTIMIZAÇÃO DE PROBLEMAS DA ENGENHARIA NUCLEAR

Andressa dos Santos Nicolau

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

Examinada por:

Prof. Roberto Schirru, D.Sc

Prof. Eduardo Gomes Dutra de Carmo, D.Sc

Prof. José Antonio Carlos Canedo Medeiros, D.Sc

Prof. Cláudio Márcio do Nascimento Abreu Pereira, D.Sc

Prof. Paulo Victor Rodrigues de Carvalho, D.Sc

RIO DE JANEIRO, RJ - BRASIL

FEVEREIRO DE 2014

Nicolau, Andressa dos Santos

Algoritmo Evolucionário de Inspiração Quântica Aplicado na Otimização de Problemas da Engenharia Nuclear/Andressa dos Santos Nicolau. – Rio de Janeiro: UFRJ/COPPE, 2014.

XII, 138 p.: il.; 29,7 cm.

Orientador: Roberto Schirru

Tese (doutorado) – UFRJ/ COPPE/ Programa de Engenharia Nuclear, 2014.

Referências Bibliográficas: p. 130-138.

1. Algoritmos de Inspiração Quântica. 2. Problema de Identificação e Diagnóstico de Acidentes em uma Usina Nuclear PWR. 3. Problema da Recarga do Reator Nuclear. I. Schirru, Roberto. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Nuclear. III. Título.

"A menos que modifiquemos a nossa maneira de pensar, não seremos capazes de resolver os problemas causados pela forma como nos acostumamos a ver o mundo".

Albert Einstein

AGRADECIMENTOS

Agradeço a Deus por ter me concedido mais uma vitória e, por está sempre comigo me dando forças para nunca desistir dos meus sonhos.

Agradeço ao meu querido orientador Roberto Schirru que me infundiu da experiência e segurança necessária para encarar os problemas que surgiram durante o doutorado e, além disso, por me permitir desfrutar de seu convívio, sua sabedoria e sua amizade.

Agradeço a minha família, colegas e amigos por acreditar em mim e, nos momentos difíceis me mostrar que esse sonho seria real.

Agradeço aos meus colegas do LMP pelo apoio e pelas horas que passamos juntos. Horas essas necessárias para o bom andamento do meu trabalho.

Agradeço a todos aqueles que sejam pela tolerância com meus comportamentos egoístas ou pela compreensão das minhas necessidades permitiram que este trabalho se consolidasse.

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

ALGORITMO EVOLUCIONÁRIO DE INSPIRAÇÃO QUÂNTICA APLICADO NA OTIMIZAÇÃO DE PROBLEMAS DA ENGENHARIA NUCLEAR

Andressa dos Santos Nicolau

Fevereiro/2014

Orientador: Roberto Schirru

Programa: Engenharia Nuclear

Neste trabalho o algoritmo de inspiração quântica QEA (*Quantum Evolutionary Algorithm*) foi aplicado em dois proeminentes problemas da área nuclear: o Problema da Recarga do Combustível Nuclear (PRN) e o Problema de Identificação e Diagnóstico de Acidentes de uma Usina Nuclear (PDA). A aplicação do QEA ao PRN teve como objetivo avaliar o comportamento do algoritmo em um problema combinatório complexo, investigando suas vantagens e dificuldades em relação às técnicas de otimização da literatura. Por outro lado, a aplicação do QEA ao PDA teve como objetivo dar continuidade ao desenvolvimento do Sistema protótipo de Identificação e Diagnóstico de Acidentes desenvolvido em trabalhos anteriores, buscando desenvolver um novo método de classificação de acidentes com a resposta “Não Sei” para eventos desconhecidos, sem a necessidade de um evento iniciador que indicasse a ocorrência de uma condição anormal, SCRAM do reator por exemplo. Os resultados mostram que no caso do PRN o QEA foi capaz de encontrar resultados superiores para a concentração de boro com menor esforço computacional, comparado a outras metaheurísticas da literatura. Por outro lado, o método desenvolvido para o PDA, com o QEA e, usando um novo conceito de determinação de áreas de influência para a resposta “Não Sei”, foi capaz de encontrar soluções que permitiram a identificação de todos os tipos de acidentes de referência e, a distinção dos mesmos, com tipos desconhecidos (“Não Sei”).

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

QUANTUM INSPIRED EVOLUTIONARY ALGORITHM APPLIED ON
OPTIMIZATION PROBLEMS OF NUCLEAR ENGINEERING

Andressa dos Santos Nicolau

February/2014

Advisor: Roberto Schirru

Department: Nuclear Engineering

In this work Quantum Evolutionary Algorithm (QEA) was applied in two potential nuclear engineering problem: Nuclear Reactor Reload Problem (NRRP) and Accident Identification Problem (AIP). The approach in relation NRRP aimed to studied the behavior of QEA in combinatory problems investigating their advantages and difficulties in relation to others optimization techniques in the literature. On the other hand, the application of QEA in AIP aimed to continue the development of Diagnosis Prototype System developed in before works, aiming to develop a new method for accident classification with “don’t know” response for unknown events, without the use of an initiating event, reactor SCRAM for instance. The results of this study show in case of NRRP the QEA was able to find high results of boron concentration with less computational effort than others techniques in the literature. Moreover, the method developed for the AIP with the QEA and using a new concept for determining defined areas for response "do not know" was able to find solutions that identified the types of reference accidents and distinguish the unknown types ("Do not Know").

ÍNDICE

CAPÍTULO 1 – Introdução.....	1
CAPÍTULO 2 – Fundamentação Teórica.....	10
2.1 Mecânica Quântica.....	10
2.1.1 Superposição de Estados.....	12
2.1.2 Emaranhamento de Estados.....	14
2.2 Computação Quântica.....	16
2.2.1 A estrutura <i>qubit</i>	18
2.3 Algoritmos Evolucionários.....	20
2.3.1 Algoritmos Genéticos.....	21
CAPÍTULO 3 – Algoritmo Evolucionário de Inspiração Quântica.....	25
3.1 Introdução.....	25
3.2 Quantum Evolutionary Algorithm (QEA).....	27
3.2.1 A estrutura <i>qubit</i> no QEA.....	28
3.2.2 Representação da população no QEA.....	29
3.2.3 Operador portão quântico Q_gate	32
3.2.4 Operador portão quântico H_ϵ	36
CAPÍTULO 4 – QEA Otimização de Funções Contínuas e Discretas.....	39
4.1 Funções contínuas e discretas.....	39
4.2 Modelagem do QEA.....	43
4.2.1 Escolha do valor do parâmetro ϵ	45
4.3 Testes e Resultados experimentais.....	46
4.3.1 Comparação entre os resultados obtidos pelo QEA com os do PSO.....	51
CAPÍTULO 5 – Otimização do Problema da Recarga do Combustível Nuclear (PRN).....	52

5.1 O Problema.....	52
5.2 A Usina Nuclear Angra 1.....	56
5.3 Modelagem do QEA.....	58
5.4 Metodologia.....	61
5.5 Testes e Resultados experimentais.....	62
5.5.1 Comparação entre os resultados obtidos pelo QEA com os do AG.....	65
5.5.2 Comparação dos resultados do QEA com os de outras metaheurísticas da literatura.....	66
 CAPÍTULO 6 – Otimização do Problema de Identificação e Diagnóstico de Acidentes de uma Usina Nuclear (PDA).....	 69
6.1 O Problema.....	69
6.2 Sistemas de suporte ao operador.....	71
6.3 Principais Transientes operacionais e Acidentes de base de projeto postulados para Angra2.....	79
 Capítulo 7 - Modelo de Sistema de Identificação e Diagnóstico de Acidentes proposto.....	 85
7.1 O Modelo proposto.....	85
7.2 O Modelo Original.....	86
7.2.1 Independência da variável tempo e influência do parâmetro ε	89
7.2.2 Nova definição para os parâmetros ε e Δ do QEA.....	94
7.2.3 Mudanças nas condições de operação usadas como referência.....	96
7.2.4 Métrica de Minkowski Generalizada.....	103
7.2.5 Implementação da resposta “Não Sei” no SIDA2.....	110
 CAPÍTULO 8 – Conclusões e Propostas de Trabalhos Futuros.....	 126
 Referências Bibliográficas.....	 130

LISTA DE FIGURAS

FIGURA 1. Representação gráfica de um <i>qubit</i> $ \psi\rangle$ genérico.....	19
FIGURA 2. Esfera de Bloch.....	20
FIGURA 3. Pseudocódigo de criação de $P(t)$	32
FIGURA 4. Pseudocódigo de atualização do <i>qubit</i>	34
FIGURA 5. Processo de atualização do <i>qubit</i> através do portão quântico Q -gate.....	35
FIGURA 6. Pseudocódigo do QEA.....	35
FIGURA 7. Portão quântico H_ε baseado no portão quântico Q -gate.....	38
FIGURA 8. Função Schaffer.....	40
FIGURA 9. Função Esfera.....	41
FIGURA 10. Função Rastringin.....	42
FIGURA 11. Função Rosenbrock.....	43
FIGURA 12. Pseudocódigo de geração de $P(t)$	44
FIGURA 13. Melhor resultado do QEA para a função Schaffer com $n=30$	47
FIGURA 14. Melhor resultado do QEA para a função Esfera com $n=10$ e $n=30$	48
FIGURA 15. Melhor resultado do QEA para a função Rastringin com $n=10$ e $n=30$	49
FIGURA 16. Melhor resultado do QEA para a função Rosenbrock com $n=10$ e $n=30$..	50
FIGURA 17. Representação do núcleo do reator de Angra 2.....	56
FIGURA 18. Representação da simetria de 1/8 de núcleo do reator de Angra 1.....	57
FIGURA 19. Procedimento de construção do EC a partir do indivíduo quântico.....	58
FIGURA 20. Procedimento realizado pelo Random Keys.....	59
FIGURA 21. Curva de evolução do QEA para o melhor valor da C_B da tabela 5.....	63
FIGURA 22. Representação de simetria de 1/8 de núcleo para o resultado obtido pelo GA (a) e para o resultado obtido pelo QEA (b), mostrados na tabela 7.....	66
FIGURA 23. Representação do modelo do núcleo do reator de Angra 2.....	79
FIGURA 24. Representação de um ciclo da Usina Nuclear de Angra 2.....	81
FIGURA 25. Exemplo do processo de classificação realizado pelo SIDA1.....	87
FIGURA 26. Processo de conversão realizado pelo Código Gray.....	89
FIGURA 27. Exemplo do processo de classificação realizado pelo SIDA 2.....	97
FIGURA 28. Diagrama de Voronoi (Lopes, 2008).....	111
FIGURA 29. Semi-plano que contém p_i	112
FIGURA 30. Círculo que contém p_i e p_j	113

FIGURA 31. Representação do cálculo da distância entre os vetores protótipos.....	114
FIGURA 32. Representação do cálculo da distância do PontMed1 aos outros vetores protótipos.....	115
FIGURA 33. Representação de todos os pares de vetores protótipos que possuem arestas em comum.....	115
FIGURA 34. Representação das áreas de influência.....	116

LISTA DE TABELAS

TABELA 1. Atualização do portão quântico Q -gate.....	33
TABELA 2. Testes com diferentes valores para o parâmetro ε	45
TABELA 3. Resultados encontrados pelo QEA.....	46
TABELA 4. Comparação dos resultados do QEA com os do PSO.....	51
TABELA 5. Resultados do QEA.....	62
TABELA 6. Valores de queima e de K_{∞}	64
TABELA 7. Resultados da C_B obtidos pelo QEA e pelo GA.....	65
TABELA 8. Resultados obtidos por diferentes algoritmos na otimização do ciclo 7 de operação da Usina Nuclear Angra 1.....	67
TABELA 9. Variáveis de estado.....	87
TABELA 10. Testes com diferentes valores para o parâmetro ε	90
TABELA 11. Testes com diferentes valores para a variável tempo.....	91
TABELA 12. Resultados do QEA.....	92
TABELA 13. Classificação em tempo real.....	93
TABELA 14. Resultados com o SIDA1 com Δ e ε fixos.....	94
TABELA 15. Resultados obtidos com o SIDA1 com Δ linearmente decrescente no tempo e o ε fixo.....	95
TABELA 16. Resultados obtidos com SIDA1 com Δ e ε fixos.....	95
TABELA 17. Resultados obtidos com o ε linearmente decrescente no tempo e Δ fixo..	96
TABELA 18. Melhores vetores representantes gerados pelo QEA.....	101
TABELA 19. Classificação em tempo real.....	103
TABELA 20. Número de classificações corretas com o uso de diferentes valores para o parâmetro p	105
TABELA 21. SIDA2 com diferentes conjuntos de variáveis de estados e diferentes valores para o parâmetro p de Minkowski.....	106
TABELA 22. Classificação em tempo real com ruído de 1%.....	108
TABELA 23. Classificação em tempo real com ruído de 2%.....	109
TABELA 24. Melhores vetores representantes gerados pelo QEA.....	118
TABELA 25. Classificação em tempo real para o conjunto de 4 variáveis.....	120
TABELA 26. Classificação em tempo real para o conjunto de 6 variáveis.....	121
TABELA 27. Classificação em tempo real para o conjunto de 4 variáveis.....	123
TABELA 28. Classificação em tempo real para o conjunto de 6 variáveis.....	124

Capítulo 1

Introdução

A energia nuclear é a segunda maior fonte de eletricidade nos países da Organização para a Cooperação e Desenvolvimento Econômico (OCDE), embora tenha começado a ser empregada a menos de 40 anos.

Atualmente existem 435 reatores nucleares em operação em 31 países, com uma capacidade de geração elétrica acima de 370 GWe. Em 2011 foram produzidos 2518 bilhões de KWh, aproximadamente 13,5% da eletricidade mundial. Mais de 60 reatores nucleares estão, atualmente, sendo construídos em 13 países, com destaque para a China, Coreia do Sul e Rússia. Mesmo após o acidente de Fukushima no Japão, espera-se que a produção de energia por meio nuclear cresça em 60% até 2035. (WORD NUCLEAR ASSOCIATION (2013)).

No Brasil a busca pela tecnologia nuclear iniciou-se na década de 50 e atualmente existem dois reatores nucleares do tipo PWR em operação: Angra 1 e Angra 2, situados no sudeste do Brasil na ilha de Itaorna em Angra dos Reis, que são responsáveis por produzirem mais de 1900 MW de potência, correspondendo a um total de 2,3% de toda a energia gerada no país. Além desses dois reatores em funcionamento estima-se a construção de no mínimo quatro novas Usinas Nucleares em todo território brasileiro nos próximos 20 anos.

Devido ao cenário atual observa-se que pesquisas na área nuclear que desenvolvam novos e eficientes métodos de otimização visando melhorar tanto a eficiência e produção da usina, quanto aumentar sua segurança de operação são de extrema relevância. Uma forma de se alcançar esses objetivos é encontrar novos métodos de soluções para problemas complexos da área nuclear, que ainda encontram-se sem solução definitiva, tais como o Problema da Recarga do Combustível Nuclear

(PRN) e o Problema de Identificação e Diagnóstico de Acidentes de uma Usina Nuclear (PDA).

O PRN é um problema combinatório altamente complexo, pertencente á classe dos problemas não polinomiais (NP) completos, que vem sendo estudado por mais de 40 anos na área nuclear. A solução mais comum para este tipo de problema consiste na determinação de um padrão de carregamento que maximize a vida útil do combustível nuclear, permitindo o aumento do ciclo de queima do combustível, o que trará ganhos operacionais e econômicos relacionados ao funcionamento da Usina. Porém, a dificuldade de encontrar sua solução está relacionada com o grande número de possíveis combinações de elementos combustíveis que podem compor o núcleo do próximo ciclo. Por exemplo, no caso particular da Usina Nuclear Angra 1 – PWR (Pressurized Water Reactor), localizada no sudeste do Brasil, o núcleo do reator é composto por 121 elementos combustíveis, resultando em aproximadamente 10^{200} possíveis combinações de padrões de carregamento, que devido a restrições de posicionamento dos elementos combustíveis, relacionados com a geometria do núcleo, pode ser reduzido para um total de aproximadamente 10^{25} possíveis arranjos ou padrões de carregamento. Porém, seriam necessários cerca de 10^{19} anos para que todas essas combinações fossem testadas, com o uso de computadores e códigos de física de reatores atuais.

Por outro lado, o PDA é um problema contínuo extremamente complexo de alta dimensionalidade do espaço de busca, que está diretamente relacionado com a operação e segurança da Usina Nuclear. A operação de uma central nuclear envolve o controle e monitoração de seus sistemas e milhares de componentes cujas falhas podem provocar o aparecimento de situações anormais (FSAR, 2007), que devem ser identificadas, diagnosticadas e corrigidas a tempo para que a integridade da Usina seja preservada.

As tarefas de monitoração, identificação e tomada de decisão são de responsabilidades dos operadores da sala de controle. No entanto, a realização dessas tarefas em condições anormais de operação da Usina torna-se cada vez mais difícil de serem realizadas devido ao grande número de instrumentos e a dinâmica da variação das medidas das grandezas associadas ao evento em curso, existe o potencial de que suas ações subsequentes causem degradação das condições de segurança da Usina, podendo transformar o que seria um simples transiente operacional em um acidente de grandes

proporções, como ocorreu na unidade 2 da Central Nuclear de Three Mile Island (TMI), onde iniciado por problemas mecânicos, foi exacerbado por uma combinação de erros por parte dos operadores, que ocorreram na tentativa de resposta a esses problemas.

Após o TMI várias modificações em projetos de Usinas Nucleares foram impostas pela Comissão de Regulamentação Nuclear (Nuclear Regulatory Commission, NRC) (NUREG, 1979). Uma delas foi à implementação de sistemas computadorizados de auxílio à operação na sala de controle das Usinas, genericamente denominados de Safety Parameter Display System (SPDS) (PEREIRA, SCHIRRU e MARTINEZ, 1998). Tais sistemas fornecem informações mais processadas e integradas do que aquelas disponíveis pela instrumentação convencional e, tem o papel de auxiliar a equipe da sala de controle na tomada de decisão. Os SPDS, além de permitir que a equipe da sala de controle tenham melhores decisões estratégicas durante a operação da Usina, possibilitam ao operador uma maior capacidade de gerenciamento e supervisão durante situações de emergência.

Um dos desafios para a solução do PDA consiste na determinação de um Sistema de Identificação e Diagnóstico de Acidentes (SIDA), que seja capaz de reconhecer em tempo real, o evento em curso e associá-lo a um evento conhecido (acidentes/transientes postulados no projeto da usina, por exemplo), em curto intervalo de tempo. No entanto, não basta que o SIDA seja rápido, mas que seja robusto e confiável frente a situações em que haja ruídos nos dados. Além disso, é de extrema importância que o SIDA seja capaz de fornecer a resposta “Não Sei” para eventos desconhecidos (acidentes não postulados no projeto da Usina, por exemplo).

Ao longo dos anos várias técnicas de Inteligência Artificial (IA), tais como sistemas especialistas, redes neurais artificiais, lógicas nebulosas, algoritmos bio-inspirados e algoritmos com inspiração quântica, têm sido testados na solução do PRN e do PDA. Essas técnicas de IA são capazes de contornar de forma eficaz o problema da complexidade do espaço de busca, não necessitando das condições de continuidade e existência de derivadas, normalmente exigida pelos métodos clássicos. Observa-se que os algoritmos de inspiração quântica estão entre as melhores alternativas para lidar com esses tipos de problema, uma vez que apresentam um potencial de redução no tempo

computacional. (NICOLAU, SCHIRRU e MENESES, (2011), DA SILVA et. al. (2010) e, DA SILVA e SCHIRRU (2011)).

Os algoritmos evolucionários de inspiração quântica são baseados nos principais conceitos e teorias de duas importantes áreas da computação: a computação quântica e a computação evolucionária.

A computação quântica foi proposta por Paul Benioff (1980) e começou a ganhar força em 1989 quando David Deutsch desenvolveu o algoritmo quântico chamado: “Problema de dois bits de Deutsch”. A partir daí deixou de ser uma curiosidade e devido a pesquisas realizadas por cientistas como Peter Shor e Lov Grover tomou forma e mostrou seu potencial. (BERNARDO e LIMA, 2005). Baseada nos princípios de superposição, interferência e emaranhamento de estados da mecânica quântica (EISBERG e RESNICK, 1994) a principal vantagem da computação quântica é o chamado “paralelismo quântico” proveniente da estrutura *qubit* - bit quântico, que foi desenvolvido com base no princípio de superposição de estados e pode assumir simultaneamente os valores “0” e “1” de um bit clássico, ou um estado de superposição destes dois valores.

O “paralelismo quântico” permite resolver em tempo eficiente alguns problemas que na computação clássica seriam impraticáveis, em função do tempo de processamento, como por exemplo, a fatoração em primos de números naturais e o problema do logaritmo discreto. A redução do tempo de resolução destes problemas possibilitaria a quebra da maioria dos sistemas de criptografia usados atualmente, tais como: cifras RSA, ElGammal e Diffie-Helman (MENDES, 2007) que são utilizadas para proteger páginas web seguras, email encriptado e muitos outros tipos de dados. A quebra destes códigos poderia ter um impacto significativo na sociedade.

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, uma vez que as interferências são grandes e o tempo de coerência dos estados da partícula pequeno. Além disso, existe a grande dificuldade de se criar

algoritmos que tirem proveito da capacidade de processamento em paralelo desses computadores.

A computação evolucionária por sua vez, foi proposta na década de 50 por biólogos e geneticistas, e atraiu interesse da comunidade científica em 1975 devido aos trabalhos realizados por um grupo de cientistas, onde o nome de HOLLAND (1975) se destaca no desenvolvimento de um algoritmo baseado no conceito da evolução da espécie de DARWIN (1859). Neste algoritmo uma população de n indivíduos foi implementada, onde cada indivíduo é caracterizado por um genótipo, sujeito a operações de seleção, recombinação e mutação. Tal estudo foi modelado e passou a ser conhecido como Algoritmo Genético (AG) o qual se popularizou através dos estudos de GOLDBERG (1989), e atualmente é um dos algoritmos de computação evolucionária mais utilizado na otimização de problemas complexos.

Emergente da Inteligência Artificial a computação evolucionária é inspirada na biologia evolutiva e é formada por um conjunto de algoritmos de busca e otimização, que fornecem um mecanismo de busca paralela e adaptativa baseados no princípio de sobrevivência dos mais aptos e na reprodução. O mecanismo de busca é obtido a partir de uma população de indivíduos (soluções), representados por cromossomos (string binários), cada um associado a uma aptidão (avaliação da solução no problema), que são submetidos a um processo de evolução (seleção, reprodução, cruzamento e mutação) por vários ciclos. O problema a ser resolvido por um algoritmo da computação evolucionária é visto como o ambiente, e cada indivíduo da população é associado a uma solução candidata. Assim, um indivíduo vai estar mais adaptado ao ambiente sempre que ele corresponder a uma solução mais eficaz para o problema. Com a evolução, espera-se que a cada geração o algoritmo encontre soluções candidatas mais eficazes, embora não exista a garantia de se chegar à solução ótima do problema ao final do processo evolutivo. A computação evolucionária tem como vantagem a capacidade de resolver de forma eficiente problemas de otimização complexos, N- completos e de alta dimensionalidade do espaço de busca, sem exigir o cálculo de derivadas, necessitando apenas de uma forma de avaliação do resultado.

Pesquisas no sentido de unir os conceitos teóricos da computação evolucionária e da computação quântica iniciaram-se no final da década de 90, com a finalidade de

desenvolver algoritmos baseados tanto no conceito de evolução das espécies da computação evolucionária, quanto no conceito de processamento em paralelo da computação quântica objetivando melhorar a eficiência e a velocidade de algoritmos evolucionários já existentes. Embora, os algoritmos criados nesse ambiente de união usem fundamentos da computação quântica, estes são desenvolvidos para serem implementados em computadores clássicos, e por isso são chamados de algoritmos de inspiração quântica. A vantagem desses algoritmos é que resolvem em tempo eficiente problemas com grandes espaços de busca e de difícil modelagem.

Observa-se ao longo dos anos o surgimento de diferentes algoritmos de inspiração quântica e suas aplicações nas mais diversas áreas de pesquisa tem demonstrado resultados superiores as suas contrapartidas clássicas. Como exemplo, podemos citar o Algoritmo Evolucionário Quântico, do inglês Quantum Evolutionary Algorithm (QEA) desenvolvido por HAN e KIM (2002). Semelhante aos algoritmos evolucionários, mas especificamente o AG, o QEA é caracterizado por um cromossomo, uma função avaliação e uma dinâmica populacional. Entretanto, ao invés de uma representação binária convencional utiliza a representação *qubit* da computação quântica como sua unidade fundamental de informação, e ao invés de operadores genéticos, utiliza como forma de aprendizado um operador variação chamado de portão quântico (*Q-Gate*).

Neste trabalho o QEA proposto por HAN e KIM (2002), foi modificado e implementado em dois proeminentes problemas da área nuclear: o Problema da Recarga do Combustível Nuclear (PRN) e o Problema de Identificação e Diagnóstico de Acidentes de uma Usina Nuclear (PDA).

O objetivo de aplicação do QEA ao PRN e ao PDA, dentro do contexto desta tese é o de mostrar a viabilidade da utilização do algoritmo como ferramenta de otimização de problemas reais da área nuclear de natureza combinatória e contínua, na busca de soluções em espaço de busca multimodais complexos, de alta dimensão e de alto custo computacional. Cabe ressaltar que a aplicação do QEA ao PRN tem como objetivo avaliar o comportamento do método desenvolvido, investigando suas vantagens e dificuldades em termos de eficiência e robustez em relação às técnicas de inteligência artificial existentes na literatura.

Por outro lado, a aplicação do QEA ao PDA tem como objetivo dar continuidade ao desenvolvimento do Sistema protótipo de Identificação e Diagnóstico de Acidentes desenvolvido no mestrado, buscando o desenvolvimento de um método de classificação de acidentes com a resposta “Não Sei” para eventos desconhecidos, sem a necessidade de um evento iniciador que indicasse a ocorrência de uma condição anormal, SCRAM do reator, por exemplo. Cabe ressaltar que a metodologia desenvolvida para a resposta “Não Sei” é inédita e foi desenvolvida com base na teoria de Compartilhamento de arestas de Voronoi (Lopes, 2008).

O modelo de SIDA proposto utilizará como referência as mesmas condições de operação usadas no Sistema Integrado de Computadores de Angra 1 – SICA (SCHIRRU e PEREIRA, 2004) desenvolvido pelo Laboratório de Monitoração de Processos (LMP) da COPPE, o qual é o responsável pela monitoração em tempo real dos parâmetros essenciais para a determinação do estado de segurança da Usina no caso de uma situação de emergência, bem como para o acompanhamento do funcionamento da mesma durante sua operação normal. Além disso, o SICA é responsável pelos procedimentos operacionais requeridos para o retorno da usina à condição de operação normal, quando da ocorrência de transientes que possam afetar a sua segurança. Desta forma, a importância de se classificar corretamente tais condições de operação (LOCA - *Loss of Coolant on the primary loop*, SGTR - *Steam Generator's Tubes Rupture* e MFWBR - *Main feed Water Rupture*), reside no fato de que os mesmos definem os gráficos de limitação de segurança, que são usados pelo SICA no caso de ocorrência dos mesmos.

Assim, pode-se dizer que a aplicação do QEA ao PDA visa não só desenvolver um SIDA com a resposta “Não Sei” para eventos desconhecidos, mas sim propor método de classificação de acidente que possa ser implementado ao SICA de Angra 1 para a determinação dos gráficos de limitação de segurança, no caso de ocorrência de um dos acidentes LOCA, SGRT ou MFWBR.

Para apresentar os métodos propostos, seus fundamentos teóricos e os resultados obtidos, este trabalho foi organizado em oito capítulos descritos sumariamente a seguir.

No presente capítulo foi apresentada uma breve descrição dos principais fundamentos da computação quântica, da computação evolucionária, e da criação dos algoritmos de inspiração quântica em especial do QEA. Além disso, são apresentados os objetivos e organização deste trabalho.

O capítulo 2 apresenta uma descrição dos principais fundamentos teóricos que embasaram o desenvolvimento deste trabalho. Inicialmente são introduzidos os principais aspectos da mecânica quântica, bem como, seus principais conceitos teóricos que são importantes para o entendimento de estruturas fundamentais da computação quântica. Em seguida são apresentados os principais fundamentos da computação quântica e da computação evolucionária, além de uma breve descrição do AG.

O capítulo 3 apresenta uma descrição do Algoritmo Evolucionário Quântico - QEA, abordando de forma detalhada suas principais estruturas, em especial: a estrutura *qubit*, a representação da população e o operador quântico - responsável pelo aprendizado do algoritmo. Além de outros detalhes importantes referentes ao processo de otimização realizado pelo QEA.

No capítulo 4 são apresentados os resultados dos testes realizados com o QEA com a implementação do portão quântico H_g , na otimização de 4 funções multimodais. Primeiramente são apresentadas as características de cada função selecionada, e em seguida é apresentado a modelagem do QEA desenvolvida e os resultados obtidos.

No capítulo 5 são apresentadas as características do PRN, destacando suas particularidades e tomando como base a Usina Nuclear de Angra 1. Além disso, serão apresentados o modelo de QEA desenvolvido para o ciclo 7 da Usina Nuclear Angra 1, bem como os testes e resultados da implementação deste modelo.

No capítulo 6 serão apresentadas as principais características do PDA, os principais transientes operacionais e acidentes de base de projeto postulados para a Usina Nuclear Angra 2, bem como as principais características de um Sistema de Suporte ao operador da sala de controle de uma Usina Nuclear.

No capítulo 7 serão apresentadas as principais características do Sistema de Identificação e Diagnóstico de Acidentes (SIDA) proposto nesta tese, bem como a metodologia desenvolvida para a resposta “Não Sei”, todos os testes realizados e os resultados obtidos.

E finalmente no capítulo 8 serão apresentadas as conclusões finais e as sugestões de trabalhos futuros.

Capítulo 2

Fundamentação Teórica

Neste capítulo será feita uma breve descrição dos principais fundamentos teóricos que embasaram o desenvolvimento desta dissertação. Inicialmente serão introduzidos os principais aspectos da mecânica quântica, bem como, seus principais postulados e conceitos importantes para o entendimento de estruturas fundamentais da computação quântica. Em seguida serão apresentados os principais fundamentos da computação quântica e da computação evolucionária, além de uma breve descrição do Algoritmo genético.

2.1 Mecânica Quântica

A mecânica quântica é a área do conhecimento que fornece os recursos teóricos necessários para descrever o comportamento fundamental de sistemas físicos, cujas dimensões são próximas ou abaixo da escala atômica, tais como: moléculas, átomos e partículas subatômicas. Além disso, introduz os conceitos necessários para se entender a luz e outras formas de radiação e, contudo, é a base teórica e experimental de vários campos da Física, Química, Cosmologia, Biologia estrutural e de tecnologias como a eletrônica, tecnologia da informação e nanotecnologia.

Os alicerces da mecânica quântica foram estabelecidos durante a primeira metade do século XX por Max Planck, Albert Einstein, Niels Bohr, Louis de Broglie, Erwin Schrödinger, Werner Heisenberg, Richard Feynman entre outros, na tentativa de explicar fenômenos físicos originados de resultados experimentais que não podiam ser descritos pela teoria clássica. Os principais fenômenos explicados pela teoria quântica (EISBERG e RESNICK, 1983) foram:

- espectro de radiação do corpo negro - explicado por Max Planck em 1900, com a hipótese de que haveria uma limitação energética na vibração de osciladores causadores da radiação. Para Planck, um oscilador não vibraria com qualquer

energia, mas apenas com energias “discretizadas” ou “quantizadas”, ou seja, em forma de pacotes, que Max Planck denominou de *quantum*;

- efeito fotoelétrico – explicado por Albert Einstein em 1905, onde confirma a idéia de *quantum* de Planck e, assume que não só a radiação eletromagnética troca energia de forma quantizada, mas que a própria radiação era formada por pacotes de energia (posteriormente denominados de fótons). Além disso, Einstein concluiu que, em determinados processos, as ondas se comportavam como corpúsculo;

- estabilidade atômica e a natureza discreta das raias espectrais – explicados por Bohr em 1924, pelo seu modelo quantizado do átomo, o qual mostrou que a energia dos elétrons nos átomos também era quantizada, postulando desta forma a quantização dos níveis de energia para o átomo de hidrogênio.

- dualidade onda-partícula – enunciada pela primeira vez por De Broglie em 1924, onde baseado nas hipóteses de Einstein e Planck sugere que os elétrons apresentavam características tanto ondulatórias, quanto corpusculares comportando-se ora de um modo, ora por outro modo dependendo do experimento realizado. A hipótese de De Broglie foi demonstrada em 1927 por Davisson e Germer em um experimento no qual se observava a difração de um feixe de elétrons através de um cristal de níquel.

A hipótese de De Broglie, seguida por Heisenberg, Schrödinger, Born Jordan, Dirac e outros, abrem caminho para uma compreensão do mundo do átomo. Com efeito, o objetivo básico da mecânica quântica é utilizar a idéia ondulatória e corpuscular de forma tal que se possa estudar quantitativamente os fenômenos atômicos evitando utilizar modelos específicos para estes fenômenos.

Os principais conceitos teóricos no qual se baseia a mecânica quântica são: dualidade onda-partícula, princípio da incerteza de Heisenberg, superposição de estados, e emaranhamento de estados quânticos. Neste capítulo serão apresentados de forma mais detalhada os dois últimos conceitos teóricos, uma vez que o entendimento dos mesmos será de grande relevância para compreender o funcionamento de estruturas

fundamentais da computação quântica e, utilizadas no modelo de algoritmo de inspiração quântica estudado nesta tese.

2.1.1 Superposição de Estados

Em física, chama-se estado uma quantidade matemática que determina os valores das propriedades físicas do sistema em um dado instante de tempo, ou as probabilidades de cada um de seus possíveis valores serem medidos, quando se trata de uma teoria probabilística. Em outras palavras, todas as informações possíveis de se saber (medir) de um sistema constituem seu estado.

Na mecânica clássica conhece-se o estado de uma partícula quando são conhecidas sua posição e seu momento. Uma vez determinado essas duas quantidades em um determinado instante t e, as forças que agem sobre a partícula neste mesmo instante é possível prever a posição e o momento da mesma em qualquer instante futuro. Por outro lado, na mecânica quântica tal descrição se torna impossível, pois de acordo com o princípio da incerteza de Heisenberg (EISBERG e RESNICK, 1983): “não é possível ter simultaneamente a certeza da posição e do momento de uma partícula e, quanto maior for a precisão com que se conhece uma delas, menor será a precisão com que se pode conhecer a outra”. Isto acontece porque para medir qualquer um desses valores acabamos os alterando e isto não é uma questão de medição, mas sim de física quântica e da natureza das partículas.

Devido ao problema da incerteza de Heisenberg, na mecânica quântica, os valores das grandezas físicas associadas a uma partícula são calculados em termos de probabilidade através de uma função matemática, chamada de função de onda e representada por ψ . Tal função, nos fornece todas as informações físicas a respeito do estado de uma partícula e, o seu módulo quadrado $|\psi|^2$ nos fornece a amplitude de probabilidade de encontrar tal partícula numa determinada região. Assim, a probabilidade de se encontrar a partícula em uma certa região $a < x < b$, no instante t , é dada pela equação (1).

$$p(x, t) = \int_b^a |\psi(x, t)|^2 dx \quad (1)$$

onde, $p(x, t)$ é real e positiva em qualquer intervalo considerado. Assim, por se tratar de uma função de onda, tem-se que a sua normalização natural garante que a probabilidade de se encontrar a partícula em qualquer região do espaço, num dado instante de tempo t , deve ser igual a 1 e representada pela equação (2).

$$\int_{-\infty}^{+\infty} |\psi(x, t)|^2 dx = 1 \quad (2)$$

A evolução temporal da função de onda é regida pela equação fundamental da mecânica quântica a equação de Erwin Schrödinger (EISBERG e RESNICK, 1983), representada pela equação (3).

$$i\hbar \frac{\partial \psi}{\partial t} = -\frac{\hbar^2}{2m} \frac{\partial^2 \psi}{\partial x^2} + V(x, t)\psi \quad (3)$$

Tem-se que, se $\psi_1(x, t)$ e $\psi_2(x, t)$ são duas funções de onda diferentes, uma combinação linear destas funções será dada pela equação (4).

$$\psi = c_1\psi_1 + c_2\psi_2 \quad (4)$$

onde, c_1 e c_2 são constantes complexas arbitrárias. Assim, se ψ_1 e ψ_2 são duas soluções da equação de Schrödinger, então ψ também é uma solução. Tal resultado vale para combinações lineares de um número arbitrário de soluções. Desta forma, considerando S um sistema físico que pode existir tanto num estado de função de onda ψ_1 como no estado de função de onda ψ_2 . A medida de uma quantidade física F , de tal sistema S dará, por hipótese, o resultado ψ_1 , com probabilidade igual a 1, se o sistema estiver em ψ_1 , e o resultado ψ_2 , também com probabilidade igual a 1, se o sistema estiver em ψ_2 . Sendo assim, diz-se que o sistema S encontrava-se em um estado de

superposição quântica e no ato da medida o mesmo se colapsa para um único estado sobreposto.

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, ao se medir o estado da moeda, o mesmo colapsaria para um dos seus estados sobrepostos e permaneceria neste estado medido. Uma vez realizada a medida o outro estado deixa de existir, e não é mais possível conhecer simultaneamente todos os seus estados sobrepostos.

Para ilustrar a ideia que os estados sobrepostos possuem apenas probabilidades de existirem e que ao ser medido eles desaparecem, Schrodinger em 1900 propôs um experimento mental, no qual 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 em uma superposição destes estados, ou seja, morto e vivo ao mesmo tempo. Somente quando a caixa fosse aberta e o estado do gato fosse medido (avaliado), é que seu estado se colapsaria em “morto” ou “vivo”.

O experimento de Schrodinger é puramente teórico e o esquema proposto jamais poderá ser construído. No entanto, atualmente efeitos análogos possuem uso prático em computação quântica e criptografia quântica (SCARANE e KURTSIEFER, 2009).

2.1.2 Emaranhamento de Estados

O emaranhamento quântico (EISBERG e RESNICK, 1983) é um fenômeno da mecânica quântica que permite que dois ou mais objetos estejam de alguma forma tão ligados, que um objeto não possa ser corretamente descrito sem que a sua contra-parte seja mencionada - mesmo que os objetos possam estar espacialmente separados.

A situação típica de estados emaranhados é que o estado do sistema global é conhecido, mas os estados das partes que o compõem são incertos, desta forma, considerando um sistema composto por duas partículas, cada uma com posição e momento (q_i, p_i) , que encontram-se em um estado com posição relativa bem definida $q = q_1 - q_2$ e momento total definido por $p = p_1 + p_2$, pode-se mostrar que, embora não se possa ter q_i e p_i bem definidos para uma mesma partícula, ao mesmo tempo, devido ao princípio da incerteza de Heizenberg, é possível que se tenha para q e p . Assim, é importante observar que somente quantidades relativas ao conjunto das partículas estão bem definidas e, que a posição e o momento de cada partícula permanecem indefinidos, ligados apenas pela condição de que a soma dos momentos deve ser igual a p e a diferença de posições igual a q .

Supõe-se então que a partícula 1 é observada muito depois das duas partículas terem interagido, quando estão muito distantes uma da outra. Como q é bem definido, se medirmos a posição da partícula 1 poderemos saber a posição da partícula 2, sem interagir diretamente com esta partícula. Por outro lado, poderíamos também medir o momento da partícula 1 e, assim determinar o momento da partícula 2 sem interagir com ela.

Essas fortes correlações fazem com que as medidas realizadas num sistema pareçam influenciar instantaneamente outros sistemas que estão emaranhados com ele e sugerem que alguma influência propaga-se instantaneamente entre os sistemas, mesmo que eles estejam separados. Porém, o emaranhamento quântico não permite a transmissão de informação a uma velocidade superior à da velocidade da luz, porque de acordo com Einstein “nenhuma informação útil pode ser transmitida desse modo”.

O emaranhamento quântico é a base das tecnologias emergentes, tais como: computação quântica e criptografia quântica e, têm sido usado para experiências como o teletransporte quântico. Ao mesmo tempo, produz alguns dos aspectos teóricos e filosóficos mais questionados da teoria quântica, já que as correlações previstas pela mecânica quântica são inconsistentes com o princípio intuitivo do realismo local, que

diz que cada partícula deve ter um estado bem definido, sem que seja necessário fazer referência a outros sistemas distantes.

2.2 *Computação Quântica*

A computação quântica é uma área de pesquisa que envolve principalmente investigações sobre a mecânica de computadores quânticos e algoritmos quânticos.

Um computador quântico é em princípio um dispositivo que utiliza conceitos da mecânica quântica, tais como: superposição e emaranhamentos de estados quânticos. Diferente de um computador clássico, que codifica a informação através de uma sequência de bits, formados pelos estados básicos 0 e 1, um computador quântico processa a informação através de bits quânticos, mais comumente chamados de *qubits*. Similar ao bit clássico, um *qubit* também é formado pelos estados básicos 0 e 1, porém, diferente do bit clássico, um *qubit* assume esses dois estados, simultaneamente. Assim, enquanto um registrador clássico de 8 bits pode armazenar um número de 0 a 255, um registrador quântico de 8 *qubits*, não só pode armazenar os mesmo números de 0 a 255, mas todos eles simultaneamente, fazendo com que a memória de um computador quântico seja exponencialmente maior que a sua memória física, permitindo um ganho exponencial de velocidade dos computadores quânticos em relação aos computadores clássicos.

Essa sobreposição de *qubits* é o que dá aos computadores quânticos seu paralelismo inerente, de acordo com o físico DEUTSH, (1985), esse paralelismo permite que um computador quântico realize 1 milhão de cálculos ao mesmo tempo, enquanto os computadores clássicos fazem apenas um.

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.

DEUTSCH (1985) foi o primeiro a levantar o questionamento da real capacidade de processamento dos computadores quânticos em relação aos computadores clássicos. Com esta questão, ele estendeu a teoria da computação 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.

Peter Shor (1994) construiu um algoritmo que permitia a um computador quântico fatorar números inteiros rapidamente. O algoritmo criado por Shor era capaz de resolver tanto o problema da fatoração, quanto o problema de logaritmo discreto. Assim um número poderia ser fatorado mais rapidamente do que com o uso de máquinas clássicas. Desta forma, 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 Jozsan (CHRISTOFOLETTI e MELO, 2003). Enquanto o número de algoritmos quânticos cresciam, os esforços no sentido de produzir um hardware quântico também aumentavam.

Embora a computação quântica ofereça uma boa promessa em termos de capacidade de processamento a principal dificuldade enfrentada na construção de um computador quântico é a alta incidência de erros. Entre as causas dos erros está o próprio ambiente, onde a influência do meio sobre o computador quântico pode causar a alteração de *qubits* e, tais erros podem causar incoerência no sistema, invalidando toda a computação.

Outra dificuldade encontrada na construção de computadores quânticos está no problema da medida de um estado quântico, o qual se sabe que qualquer manipulação no sistema altera o estado do mesmo. Desta forma, se for feita uma leitura dos dados durante a execução do programa em um computador quântico, todo o processamento será perdido. Assim, para que se tenha um funcionamento eficaz do computador quântico é necessário determinar maneiras de medir, indiretamente, de modo a preservar

a integridade do sistema. A resposta para tal problema pode ser encontrada na idéia do princípio de entrelaçamento quântico, explicado na seção anterior, que permite que se conheça o estado de uma partícula sem precisar observá-las diretamente.

A computação quântica tem um potencial muito grande de revolucionar a resolução de problemas de alta complexidade na computação clássica. Porém, as dificuldades em lidar com os fenômenos da teoria quântica e principalmente conseguir uma arquitetura que opere de forma eficaz, deixam ainda muita incerteza quanto ao sucesso destas máquinas. Os computadores quânticos mais avançados ainda não foram além da manipulação de mais de 16 *qubits* (CHRISTOFOLETTI e MELO, 2003), o que significa que eles ainda não podem ter aplicação prática e a maioria das pesquisas em informática quântica ainda é muito teórica. Permanece, portanto, o potencial dos computadores quânticos de realizar com facilidade e rapidez cálculos que demandam uma grande quantidade de tempo em computadores clássicos.

2.2.1 A estrutura *qubit*

O bit quântico, comumente referenciado como *qubit* é a unidade básica de informação da mecânica quântica e, é definido como sendo uma versão quântica do tradicional bit utilizado em computadores clássicos. Similar ao bit clássico, um *qubit* também é escrito pelos estados básicos 0 e 1, porém, diferente do bit clássico que assume cada estado separadamente, um *qubit* pode assumir esses dois estados, simultaneamente. Ou seja, um computador clássico com três bits de memória pode armazenar dois estados básicos (0 ou 1) e, em um determinado momento, pode conter os padrões “000” ou “001” ou “010” ou “011” ou “100” ou “101” ou “110” ou “111”, assumindo um desses padrões de cada vez. Um computador quântico, por outro lado, pode armazenar todos esses padrões simultaneamente, pois os estados básicos 0 e 1 de um bit são substituídos por vetores estados $|0\rangle$ e $|1\rangle$, que podem ser representados por:

$$|0\rangle = \begin{bmatrix} 1 \\ 0 \end{bmatrix} \quad e \quad |1\rangle = \begin{bmatrix} 0 \\ 1 \end{bmatrix} \quad (5)$$

Assim, um *qubit* genérico $|\psi\rangle$ pode ser escrito como a combinação linear dos vetores estados $|0\rangle$ e $|1\rangle$, como a equação (6).

$$|\psi\rangle = \alpha|0\rangle + \beta|1\rangle \quad (6)$$

onde, α e β são números complexos que especificam as amplitudes de probabilidade dos estados correspondente, ou seja, $|\alpha|^2$ especifica a probabilidade do *qubit* estar no estado $|0\rangle$, quando observado e, $|\beta|^2$ especifica a probabilidade do *qubit* estar no estado $|1\rangle$, quando observado. Esta relação entre α e β pode ser visualizada graficamente na figura 1, onde a parte imaginária foi omitida e $|\psi\rangle$ é um vetor normalizado no espaço bidimensional, que garante $|\alpha|^2 + |\beta|^2 = 1$.




Figura 1. Representação gráfica de um *qubit* $|\psi\rangle$ genérico.

Parametrizado a equação (6) a partir dos ângulos θ e φ e fazendo-se $\alpha = \cos(\theta/2)$ e $\beta = e^{i\varphi} \sin(\theta/2)$, a equação (1) pode ser reescrita como a equação (7).

$$|\psi\rangle = \cos(\theta/2)|0\rangle + e^{i\varphi} \sin(\theta/2)|1\rangle \quad (7)$$

Ao reescrever o estado do *qubit* como a equação (7), podemos visualizar o estado de um *qubit* como um ponto sobre a superfície da esfera de Bloch (PORTUGAL et. al.,

2004), o qual traduz a idéia de superposição do *qubit* genérico $|\psi\rangle$ e mostra que o mesmo pode ser encontrado em qualquer ponto dessa esfera. (Figura 2.1)




Figura 2. Esfera de Bloch

Para tornar a informação do *qubit* genérico $|\psi\rangle$, em superposição de estados, acessível no nível clássico é necessário que se faça uma medida. Essa medida tem como resultado probabilístico um único valor contido na superposição. Assim, a superposição que existia antes é irreversivelmente alterada (e perdida). Em resumo, apesar do *qubit* existir em uma superposição de estados, quando se faz uma observação de um estado, o mesmo se colapsa para um único estado.

2.3 Algoritmos Evolucionários

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 possuirão chances de sobreviver e, conseqüentemente, reproduzir-se. 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.

As primeiras pesquisas no campo da computação evolucionária foram feitas por biólogos e geneticistas, que tinham interesse em simular os processos vitais de um ser humano em um computador. Na década de 60, um grupo de cientistas em que o nome de Holland se destaca, iniciou-se um estudo em que era implementada uma população de n indivíduos, onde cada um possuía um genótipo e estava sujeito a operações de seleção, mutação e recombinação. Tal estudo foi modelado e passou a ser conhecido como Algoritmos Genéticos (GOLDBERG, 1989).

2.3.1 Algoritmos Genéticos

Os algoritmos genéticos (AG's) são uma família de modelos computacionais inspirados no mecanismo de seleção natural e genética natural de Darwin. Desenvolvidos por HOLLAND, (1975) e popularizados por GOLDBERG, (1989) são implementados como uma simulação computacional, que consiste em gerar através de regras de transições probabilísticas um grande número de indivíduos (população), de forma a promover uma varredura tão extensa quanto necessária do espaço de soluções. Normalmente, incorporam uma solução potencial numa estrutura semelhante à de um cromossomo, onde cada cromossomo representa um ponto no espaço de soluções do problema de otimização.

Os algoritmos genéticos diferem basicamente dos algoritmos tradicionais de otimização em quatro aspectos: a) baseiam-se em uma codificação do conjunto de soluções possíveis e não nos parâmetros da otimização em si; b) os resultados são apresentados como uma população de soluções e não como uma única solução; c) não necessitam de nenhum conhecimento derivado do problema, apenas de uma forma de avaliação do resultado (função objetivo); d) usam transições probabilísticas e não regras determinísticas.

Os principais conceitos dos algoritmos genéticos são:

- Cromossomo (genótipo) – possível solução para o problema e pode ser representado de forma: binária, inteira ou real. É composto de l genes

específicos, onde cada i -ésimo gene tem um conjunto de k_i alelos (HOLLAND, 1975).

- Gene – representação codificada de cada parâmetro de acordo com o alfabeto utilizado (binário inteiro ou real);
- Fenótipo – cromossomo decodificado;
- População - conjunto de pontos (cromossomos) no espaço de busca;
- Geração - iteração completa do algoritmo genético que gera uma nova população;
- Aptidão bruta - saída gerada pela função objetivo para um cromossomo da população;
- Aptidão normalizada - aptidão bruta normalizada, entrada para o algoritmo de seleção;
- Aptidão máxima - melhor cromossomo da população corrente ;
- Aptidão média - aptidão média da população corrente.

O procedimento de evolução do algoritmo genético a cada iteração corresponde à aplicação de um conjunto de quatro operações básicas, são elas:

- Cálculo da função objetivo.

A função objetivo incorpora os parâmetros envolvidos no problema a ser otimizado. Com o cálculo da função objetivo tem-se uma medida de aptidão de cada cromossomo para a solução do problema e, este valor será usado na fase de seleção dos cromossomos para a reprodução.

- Seleção.

O processo de seleção consiste em selecionar cromossomos de melhores aptidões para gerar, através do processo de cruzamento, novos cromossomos que irão compor a próxima geração. São muitos os métodos para selecionar o melhor

cromossomo, pode-se citar, por exemplo, a seleção de Boltzman, a seleção pelo método da roleta, a seleção por campeonato, a seleção por classificação, a seleção por estado estacionário, entre outras (GOLDBERG, 1989). Um dos métodos mais usados nos algoritmos genéticos simples para a implementação do método de seleção é o método de seleção por roleta. Neste método cada cromossomo ocupa, em uma roleta, uma área proporcional ao valor de sua aptidão. Assim, obtém-se uma aptidão relativa que pode ser interpretada como a probabilidade de seleção de um cromossomo.

- Cruzamento.

O processo de cruzamento nos AG's tem como principal objetivo perpetuar o material genético (bits) dos cromossomos mais aptos e consiste na recombinação de alelos através da troca de segmentos entre pares de cromossomos. O processo de cruzamento é aplicado aos cromossomos com uma probabilidade determinada pela taxa de cruzamento p_c . Este processo pode ser implementado de vários modos, sendo os mais comuns o cruzamento de um ponto e o cruzamento de dois pontos. A diferença entre o cruzamento de dois pontos e o cruzamento de um ponto é que ao invés de escolher apenas um ponto de cruzamento escolhe-se randomicamente dois. O cruzamento de um ponto é realizado da seguinte forma: primeiramente dois cromossomos da população atual são selecionados, a seguir seleciona-se (de forma aleatória) um ponto de cruzamento sobre a sequência de bits (cromossomo) e, em seguida a troca de segmentos é realizada a direita do ponto de cruzamento escolhido. O resultado deste processo é a criação de dois novos cromossomos que apresentam características dos cromossomos que os geraram.

- Mutação.

O processo de mutação nos AG's tem o papel de introduzir e manter a diversidade genética da população. Desta forma, pode ser definido como um distúrbio introduzido no gene, que altera a direção de busca do algoritmo. Tem por objetivo assegurar uma maior varredura do espaço de busca e prevenir o aprisionamento da população em falsos ótimos locais. O operador de mutação é aplicado aos cromossomos com uma probabilidade dada pela taxa de mutação

p_{mr} , geralmente se utiliza uma taxa de mutação pequena, para que o algoritmo não seja transformado em um processo de busca aleatória. O processo de mutação é realizado da seguinte forma: primeiramente seleciona-se aleatoriamente um cromossomo da população atual; em seguida seleciona-se (também de forma aleatória) um alelo deste cromossomo e altera-se o valor do alelo selecionado. O resultado deste processo é a criação de indivíduos formados por alelos não previamente testados.

Ao longo da evolução do algoritmo genético percebe-se que certos padrões (bits) que possuem aptidões mais altas tendem a aumentar sua representatividade de geração para geração, seguindo um teorema que se baseia nas probabilidades de “sobreviverem” ao cruzamento e mutação. Um grupo de padrões que representa determinada classe de cromossomos é chamado de esquemas ou modelo de similaridade. A representação de um esquema: é feita através do alfabeto ternário $\{0, 1, *\}$ onde o $*$ é um “don’t care” e, pode significar tanto o 0, quanto o 1 na posição indicada.

A Teoria dos Esquemas dão origem ao Teorema Fundamental dos Algoritmos Genéticos (8), e rege a evolução dos esquemas considerando os processos de seleção, cruzamento e mutação. A equação 8 descreve a Teoria dos Esquemas,

$$m(H, t+1) \geq m(H, t) \cdot \frac{f(H)}{\bar{f}} \cdot \left[1 - p_c \cdot \frac{d(H)}{l-1} - o(H) \cdot p_m \right] \quad (8)$$

onde, $m(H, t)$ é a quantidade de indivíduos representados pelo esquema H na geração t , $f(H)$ é a aptidão bruta do cromossomo, \bar{f} é a aptidão média da população, p_c é a taxa de cruzamento, l é o comprimento dos cromossomos e, $l-1$ é o número máximo de pontos de corte de um cromossomo de comprimento l , $d(H)$ é o comprimento definido do esquema, $o(H)$ é a ordem do esquema e, p_m é a probabilidade de mutação considerando um ponto de corte.

Capítulo 3

Algoritmo Evolucionário de Inspiração Quântica

Neste capítulo será apresentado uma descrição do Algoritmo Evolucionário Quântico, do inglês Quantum Evolutionary Algorithm (QEA), utilizado como ferramenta de otimização desta tese, bem como uma descrição detalhada de suas principais estruturas, tais como: a estrutura *qubit*, representação da população, o operador quântico e, outros detalhes importantes referentes ao seu processo de otimização.

3.1 Introdução

A computação quântica inspirada está situada na interseção de duas sub-áreas da computação científica: a computação quântica e a computação evolucionária. Sendo assim, os algoritmos de inspiração quântica foram criados com base nos conceitos de *qubit* e interferência de estados quânticos da computação quântica, bem como no conceito de evolução das espécies da computação evolucionária e, diferente dos verdadeiros algoritmos quânticos são desenvolvidos para serem implementados em computadores clássicos.

MOORE (1995) apresenta uma metodologia para a formulação inicial de algoritmos com inspiração quântica que consiste nos seguintes passos:

- 1º. O problema deve ter uma representação numérica, caso não tenha um método para sua conversão em representação numérica deve ser empregado;
- 2º. A configuração inicial deve ser determinada;
- 3º. 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 interação 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.

MOORE (1995), afirma ainda que a significativa característica dos algoritmos de inspiração quântica é a representação das soluções, pois diferentemente dos tradicionais algoritmos evolucionários a população nos algoritmos de inspiração quântica é representada por *qubits* e consiste de distribuição de probabilidades das amostras no espaço de busca, ao invés de pontos exatos no espaço. No entanto, quando medido, um indivíduo quântico pode indicar um elemento exato do espaço de busca. Esta generalização traz uma “nova filosofia” para os algoritmos evolucionários e, na forma de como a otimização de processos pode ser feita.

Pode-se dizer que os algoritmos de inspiração quântica foram criados com a tentativa de se beneficiar dos recursos da computação quântica no intuito de melhorar a eficiência e a velocidade de alguns algoritmos evolucionários clássicos. Nos últimos anos tem-se testemunhado o surgimento de diferentes algoritmos de inspiração quântica baseados em algoritmos clássicos e suas aplicações nas mais diversas áreas de pesquisa tem apresentado resultados superiores as suas contrapartidas clássicas.

No presente capítulo será apresentado o Algoritmo Evolucionário Quântico - QEA, proposto por HAN e KIM, (2002). O QEA é um algoritmo de inspiração quântica

que foi desenvolvido com base nos conceitos de *qubit* e superposição de estados da computação quântica, bem como no conceito de evolução das espécies da computação evolucionária. Embora o QEA use a estrutura *qubit* e seja baseado nos princípios de superposição e interferência de estados da Mecânica Quântica o QEA não é um algoritmo quântico, mas sim um novo algoritmo evolucionário criado para ser implementado em computadores clássicos.

3.2 *Quantum Evolutionary Algorithm (QEA)*

Proposto por HAN e Kim (2002) o QEA pertence a uma nova classe de metaheurísticas de otimização conhecida como Algoritmos Evolucionários de Inspiração Quântica. Por se tratar de um algoritmo evolucionário é caracterizado por um cromossomo, uma função avaliação e uma dinâmica populacional. Por outro lado, ao ser considerado de inspiração quântica baseia-se na estrutura *qubit* e nos conceitos de superposição e interferência de estados quânticos provenientes da computação quântica.

Diferentemente dos algoritmos evolucionários tradicionais no QEA cada indivíduo é representado de duas formas distintas durante a evolução do algoritmo. No primeiro passo do algoritmo os indivíduos são meramente quânticos caracterizados por cromossomos $q_i(t)$ compostos de *qubits*, no qual existe a coexistência dos estados $|0\rangle$ e $|1\rangle$ com suas respectivas probabilidades de serem observados. No segundo passo do algoritmo, cada indivíduo quântico é transformado em um indivíduo clássico representado por um cromossomo $X_i(t)$, formado por bits, e só então é avaliado pela função objetivo. A outra diferença em relação aos algoritmos evolucionários tradicionais é que ao invés de operadores evolucionários, tais como: mutação, recombinação, seleção e etc., o QEA utiliza como operador de evolução um portão quântico, chamado *Q-gate*, que tem a função de guiar a população na direção da melhor solução. Desta forma, podemos dizer que o QEA trabalha com uma população quântica no início do algoritmo, onde o indivíduo quântico $q_i(t)$ representa a superposição linear de todos os possíveis estados com a mesma probabilidade e, na sequência do algoritmo à população quântica se transforma em uma população clássica, onde o fenômeno de superposição de estados desaparece e o indivíduo colapsa para um único estado.

Comparado com o algoritmo genético o QEA apresenta melhores performances, tanto em funções de teste (HAN e KIM, 2002, NICOLAU^c e SCHIRRU, 2010), quanto em problemas reais da engenharia nuclear (NICOLAU, SCHIRRU e MENESES, 2011, NICOLAU e SCHIRRU, 2012) no que se refere ao tempo de processamento da informação, pois apresenta maior diversidade da população no início do programa o que possibilita uma maior probabilidade de escapar de ótimos locais. (Nowotniak, R. e Kucharski, J., 2010)

3.2.1 A Estrutura qubit no QEA

Assim como nos algoritmos quânticos, no QEA o *qubit* também é definido como a menor unidade de informação e, é descrito como um estado em um sistema quântico de dois níveis e formalmente equivale a um espaço vetorial bidimensional de números complexos (α, β) , onde cada um desses estados (ou vetores) é convencionalmente representados como estados $|0\rangle$ e $|1\rangle$ e pode ser escrito como a combinação linear dos estados $|0\rangle$ e $|1\rangle$, de acordo com (9).

$$|\Psi\rangle = \alpha|0\rangle + \beta|1\rangle \quad (9)$$

onde, α e β são números complexos que especificam as amplitudes de probabilidade dos estados correspondente, ou seja, $|\alpha|^2$ especifica a probabilidade do *qubit* ser observado no estado $|0\rangle$ e, $|\beta|^2$ especifica a probabilidade do *qubit* ser observado no estado $|1\rangle$. Esta relação entre α e β pode ser visualizada graficamente na figura 2.1 do capítulo 2, onde a normalização unitária desses estados garante (10).

$$|\alpha|^2 + |\beta|^2 = 1. \quad (10)$$

Assim, um conjunto de n *qubits* pode ser colocado na superposição de 2^n estados e, cada um desses estados corresponde a *qubits* tanto no estado $|0\rangle$, quanto no estado $|1\rangle$, tais como (000...0), (100...0), (010...0), (111...0), (111...1), onde esses estados

codificam todos os possíveis números representados pelos n bits, permitindo o cálculo computacional simultâneo de todos os possíveis estados simultaneamente.

Desta forma, a informação armazenada em $|\psi\rangle$ é a combinação de todos os possíveis estados $|0\rangle$ e $|1\rangle$. Para que a informação de $|\psi\rangle$ seja acessível no nível clássico é necessário que se faça uma observação, ou seja, uma medida. Esta medida tem como resultado um único estado da superposição. Assim, mesmo existindo uma superposição de estados quando um *qubit* é observado o mesmo colapsa para um único estado. Ou seja, quando $|\psi\rangle$ é medido, o estado $|0\rangle$ poderá ser observado com uma probabilidade $|\alpha|^2$ ou o estado $|1\rangle$ poderá ser observado com uma probabilidade $|\beta|^2$. Em geral, os algoritmos de inspiração quântica processam o *qubit* em um estado híbrido. E a convergência do bit para os valores “0” ou “1” ocorre somente no final das iterações.

3.2.2 Representação da população no QEA

A população no QEA é representada de duas formas distintas durante a evolução do algoritmo, em uma primeira fase a população é totalmente quântica representada por cromossomos formados por *qubits* e atualizados pelo portão quântico. Em uma segunda fase, esta mesma população é transformada em uma população clássica, representada por cromossomos formados por bits e avaliados por uma função objetivo. As seções 3.2.3 e 3.2.4 mostram com detalhes cada procedimento realizado pelo QEA na população quântica e na população clássica, respectivamente.

• População Quântica

A população quântica do QEA é representada por $Q(t) = \{q_1(t), q_2(t), \dots, q_n(t)\}$, onde n é o tamanho da população e, $q_i(t)$ é o i -ésimo cromossomo quântico, representado por m *qubits* definido pela equação (11).

$$q_i(t) = \begin{bmatrix} \alpha_{i1}(t) & \alpha_{i2}(t) & \alpha_{im}(t) \\ \beta_{i1}(t) & \beta_{i2}(t) & \beta_{im}(t) \end{bmatrix}, \quad i = 1, 2, \dots, n \quad (11)$$

onde, $|\alpha_{ij}(t)|^2 + |\beta_{ij}(t)|^2 = 1$. Na inicialização do algoritmo, os valores de α e β de $q_i(t)$ é igual a $\frac{\sqrt{2}}{2}$, isto faz com que na geração inicial, todos os genes dos indivíduos quânticos tenham a mesma probabilidade de serem gerados nos estados $|0\rangle$ ou $|1\rangle$.

Dado um cromossomo quântico $q_i(t)$ formado por três *qubits* como representado em (12).

$$q_j(t) = \begin{bmatrix} \frac{\sqrt{2}}{2} & \frac{\sqrt{2}}{2} & \frac{\sqrt{2}}{2} \\ \frac{2}{\sqrt{2}} & \frac{2}{\sqrt{2}} & \frac{2}{\sqrt{3}} \\ \frac{2}{2} & -\frac{2}{2} & \frac{2}{2} \end{bmatrix} \quad (12)$$

a amplitude de probabilidade de se observar o estado $|000\rangle$, pode ser calculada multiplicando-se as amplitudes de probabilidade de se observar o estado “0” em cada um dos bits ($\alpha_{i1}(t)$, $\alpha_{i2}(t)$ e $\alpha_{i3}(t)$). Da mesma forma, para se calcular a amplitude de probabilidade de se observar o estado $|001\rangle$, multiplica-se os bits ($\alpha_{i1}(t)$, $\alpha_{i2}(t)$ e $\beta_{i3}(t)$). Estendendo este procedimento para as outras possibilidades de observação dos estados, pode-se representar a superposição dos mesmos como em (13).

$$\frac{1}{2\sqrt{2}}|000\rangle - \frac{1}{2\sqrt{2}}|010\rangle + \frac{\sqrt{3}}{2\sqrt{2}}|001\rangle - \frac{\sqrt{3}}{4}|011\rangle - \frac{\sqrt{3}}{4}|111\rangle + \frac{1}{2\sqrt{2}}|100\rangle - \frac{1}{2\sqrt{2}}|110\rangle + \frac{\sqrt{2}}{4}|101\rangle \quad (13)$$

O resultado em (13) significa que as probabilidades de representação dos estados $|000\rangle, |010\rangle, |001\rangle, |011\rangle, |111\rangle, |100\rangle, |110\rangle$, e $|101\rangle$ são $\frac{1}{8}, \frac{1}{8}, \frac{3}{8}, \frac{3}{16}, \frac{3}{16}, \frac{1}{8}, \frac{1}{8}$ e $\frac{2}{16}$, respectivamente. Sendo assim, pode-se dizer que um único cromossomo formado por 3 *qubits*, tal como (12) é suficiente para representar oito estados simultaneamente, diferentemente de um algoritmo evolucionário tradicional, tal como o algoritmo genético, no qual seriam necessários oito cromossomos. Essa característica é uma das principais vantagens do QEA em relação aos algoritmos evolucionários tradicionais,

pois permite que o QEA tenha uma significativa diversidade da população, utilizando poucos indivíduos.

• *População Clássica*

A população clássica do QEA é representada por $P(t) = \{X_1(t), X_2(t), \dots, X_n(t)\}$, onde cada indivíduo clássico $X_n(t)$ é formado pela observação do indivíduo quântico $q_i(t)$. O fenômeno da observação é uma característica adotada da mecânica quântica pelos algoritmos evolucionários de inspiração quântica e é ilustrado pelo gato de Schrödinger (EISBERG e RESNICK, 1994). Durante a observação, cada *qubit* colapsa para um único estado e a superposição de estados desaparece. Assim, o indivíduo quântico passa a ser visto como um indivíduo clássico e não sofre mais os efeitos da mecânica quântica, passando a partir de então a trabalhar com os conceitos da computação evolucionária.

O i -ésimo indivíduo clássico $X_i(t)$, com m bits, o qual é avaliado pela função objetivo, é representado por $X_i(t) = \{x_{i1}(t), x_{i2}(t), \dots, x_{im}(t)\}$, onde $x_{ij}(t)$ é o bit observado. Cada bit $x_{ij}(t)$ é obtido pela observação dos *qubits* do indivíduo quântico no passo de construção da população $P(t)$. Quando todos os estados dos *qubits* dos indivíduos quânticos da população $Q(t)$ são observados, o valor $|x_{ij}| = 0$ ou $|x_{ij}| = 1$ de $P(t)$ é determinado pelas probabilidades $|\alpha_{ij}|^2$ ou $|\beta_{ij}|^2$. Desta forma, a cada nova observação dos *qubits* do indivíduo quântico é criado um novo indivíduo clássico. O pseudocódigo de criação de $P(t)$ é mostrado na figura 3.

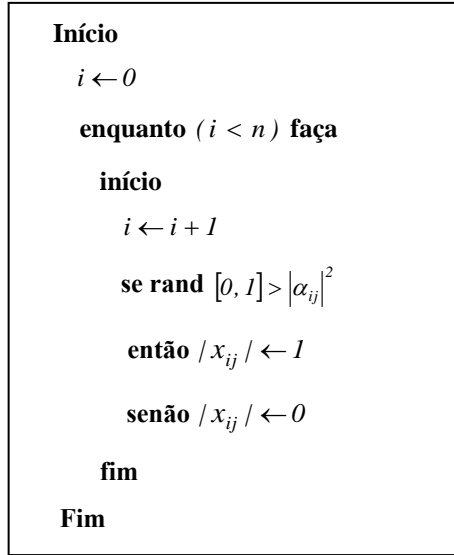


Figura 3. Pseudocódigo de criação de $P(t)$

3.2.3 O operador portão quântico Q -gate

A atualização da população no QEA e que representa o aprendizado do algoritmo é realizado pelo operador portão quântico Q -gate. Tal operador é definido pela matriz de rotação $U(\Delta\theta_{ij})$ dada pela equação (14).

$$U(\Delta\theta_{ij}) = \begin{vmatrix} \cos(\xi(\Delta\theta_{ij})) & -\sin(\xi(\Delta\theta_{ij})) \\ \sin(\xi(\Delta\theta_{ij})) & \cos(\xi(\Delta\theta_{ij})) \end{vmatrix} \quad (14)$$

onde,

$$\xi(\Delta\theta_{ij}) = S(\alpha_{ij}, \beta_{ij}) * \Delta\theta_{ij} \quad (15)$$

$S(\alpha_{ij}, \beta_{ij})$ e $\Delta\theta_{ij}$ representam, respectivamente, a direção de rotação e a magnitude de rotação ângulo. Os valores de $\Delta\theta_{ij}$ são definidos através da tabela (1) e são definidos de acordo com o problema em questão.

Tabela 1. Aplicação do portão quântico Q -gate.

x_{ij}	b_j	$f(X_i(t)) > f(B(t))$	$\Delta\theta_{ij}$	$S(\alpha_{ij}\beta_{ij})$			
				$\alpha_{ij}\beta_{ij} > 0$	$\alpha_{ij}\beta_{ij} < 0$	$\alpha_{ij} = 0$	$\beta_{ij} = 0$
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

A matriz de rotação $U(\Delta\theta_{ij})$ deve ser capaz de modificar os valores de α_{ij} e β_{ij} no sentido de aumentar as chances de sobrevivência dos melhores valores para os bits (b_j) e diminuir as chances de sobrevivência dos piores valores para os bits. Cabe ressaltar, que os melhores valores dos bits são armazenados na estrutura Best ($B(t)$) que é atualizada a cada nova geração.

A atualização dos bits feita por $U(\Delta\theta_{ij})$ será feita multiplicando cada uma das colunas de cada indivíduo da população quântica. Para isso, cada par de valores α_{ij} e β_{ij} são tratados como vetores bi-dimensionais e são rotacionados usando $U(\Delta\theta_{ij})$, de acordo com a equação (16).

$$\begin{pmatrix} \alpha_{ij}(t+1) \\ \beta_{ij}(t+1) \end{pmatrix} = U(\Delta\theta_{ij}) * \begin{pmatrix} \alpha_{ij}(t) \\ \beta_{ij}(t) \end{pmatrix} \quad (16)$$

Em outras palavras, considerando-se o indivíduo quântico $q_j(t) = \{(\alpha_{j1}(t), \beta_{j1}(t)), (\alpha_{j2}(t), \beta_{j2}(t)), \dots, (\alpha_{jm}(t), \beta_{jm}(t))\}$, a atualização deste indivíduo será feita de acordo com o pseudocódigo da figura 4.

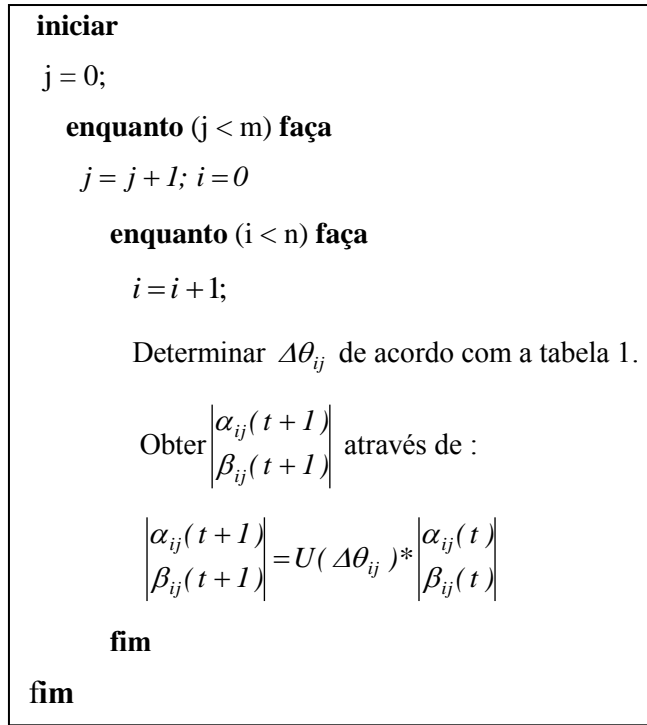


Figura 4. Pseudocódigo de atualização do qubit.

Como mencionado anteriormente os valores de $S(\alpha_{ij}, \beta_{ij})$ e $\Delta\theta_{ij}$ são obtidos de acordo com a tabela 1. Esses valores dependem basicamente das possíveis combinações de $x_{ij}(t)$, $b_j(t)$ e da expressão $f(X_i(t)) > f(B(t))$. Em um problema de maximização, por exemplo, de acordo com a tabela 1, quando $b_j = 1$ e $x_{ij} = 0$ se $f(B(t)) > f(X_i(t))$, tem-se que o bit x_{ij} da solução candidata terá sua probabilidade de assumir o valor 1 (um) aumentada, uma vez que, a melhor solução encontrada até o momento possui o valor 1 (um) para o bit em questão. Tal processo pode ser visualizado na figura 5, onde considerou-se um círculo de raio 1 com as representações dos estados $|0\rangle$ e $|1\rangle$ e, α_{ij} e β_{ij} como números reais normalizados no espaço bidimensional. Assim, se α_{ij} e β_{ij} pertencerem ao primeiro quadrante, a direção de rotação será o sentido anti-horário, isto é, aumentando a probabilidade de se observar o estado $|1\rangle$, por outro lado, se α_{ij} e β_{ij} pertencerem ao segundo quadrante, a direção de rotação será no sentido horário.




Figura 5. Processo de atualização do *qubit* através do portão quântico *Q-gate*.

Na equação (6), $|\Psi\rangle$ representa a função de onda no espaço de Hilbert (EISBERG e RESNICK, 1994). Sendo assim, podemos dizer que o QEA evolui de acordo com um modelo dinâmico baseado na operação de interferência de estados quânticos, realizado pelo portão quântico $U(\Delta\theta_{ij})$. Como vimos anteriormente esta operação aumenta a amplitude de probabilidade da melhor solução e diminui a amplitude de probabilidade da pior solução. Desta forma, o portão quântico basicamente move o estado de cada *qubit* na direção do valor do bit correspondente da melhor solução encontrada até o momento da atualização. Os procedimentos realizados durante a evolução do QEA são apresentados no pseudocódigo da figura 6.

```

iniciar
  inicializar  $Q(0)$  em  $t = 0$ 
  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  $\Delta\theta_{ij}$ 
  armazenar a melhor solução de  $P(t)$  em  $B(t)$ 
fim
fim

```

Figura 6. Pseudocódigo do QEA.

Observa-se no pseudocódigo do QEA que o melhor candidato solução de $P(t)$, a cada iteração t , é armazenado na estrutura $B(t) = [b_1(t) \ b_2(t) \ ... \ b_m(t)]$, onde $b_j(t)$ representa os bits da melhor solução. Sendo assim, 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. O objetivo é encontrar um indivíduo que represente a melhor solução para o problema considerado.

O algoritmo QEA foi usado com sucesso em problemas de otimização combinatória (HAN 2000; HAN 2002) e em problemas reais da engenharia nuclear (NICOLAU, SCHIRRU e MENESES, 2011; NICOLAU e SCHIRRU, 2012), apresentando resultados superiores aos algoritmos genéticos tradicionais em termos de tempo de convergência e qualidade das soluções encontradas. Uma descrição mais detalhada deste algoritmo QEA pode ser encontrada em (HAN, 2002).

3.2.4 O operador portão quântico H_ϵ

O portão quântico Q -gate, usado no QEA original, pode induzir a convergência prematura de cada *qubit* (NICOLAU^a e SCHIRRU, 2010) para os estados $|0\rangle$ ou $|1\rangle$, dificultando que o *qubit* escape de ótimos locais por si só, mesmo com uma pequena probabilidade desses estados serem mudados por uma atualização. Desta forma, para evitar a convergência prematura do *qubit*, HAN e KIM (2004), propuseram o portão quântico H_ϵ . O portão quântico H_ϵ é definido pela equação (17).

$$\begin{bmatrix} \alpha_{ij}(t+1) \\ \beta_{ij}(t+1) \end{bmatrix} = H(\alpha_{ij}(t), \beta_{ij}(t), \Delta\theta_{ij}) \quad (17)$$

Durante a aplicação do H_ϵ , a rotação

$$\begin{bmatrix} \alpha'_{ij} \\ \beta'_{ij} \end{bmatrix} = U(\Delta\theta_{ij}) * \begin{bmatrix} \alpha_{ij}(t) \\ \beta_{ij}(t) \end{bmatrix} \quad (18)$$

é calculado como um passo intermediário e a atualização final depende do valor da constante ε , de acordo com (i) ou (ii) ou (iii):

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

$$\begin{bmatrix} \alpha'_{ij} \\ \beta'_{ij} \end{bmatrix}^T = \begin{bmatrix} \sqrt{\varepsilon} * \sqrt{1 - \varepsilon} \end{bmatrix}^T$$

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

$$\begin{bmatrix} \alpha'_{ij} \\ \beta'_{ij} \end{bmatrix}^T = \begin{bmatrix} \sqrt{1 - \varepsilon} * \sqrt{\varepsilon} \end{bmatrix}^T$$

(iii) Outros casos

$$\begin{bmatrix} \alpha'_{ij} \\ \beta'_{ij} \end{bmatrix}^T = \begin{bmatrix} \alpha''_{ij} \\ \beta''_{ij} \end{bmatrix}^T$$

onde, $0 < \varepsilon < 1$ e $\Delta\theta_{ij}$ é o ângulo de rotação para o *qubit* na direção do estado $|0\rangle$ ou $|1\rangle$, dependendo do seu sinal.

A figura 7 mostra o portão quântico *H-gate* e o portão quântico *Q-gate*. Onde, $\lim_{t \rightarrow 0} H_e$ é o portão quântico de rotação original. Enquanto, o portão quântico *Q-gate* faz a probabilidade para $|\alpha_{ij}|^2$ ou $|\beta_{ij}|^2$ convergir para 0 ou 1, o portão quântico *H-gate* faz convergir para ε ou $1 - \varepsilon$. Cabe ressaltar que se o valor de ε for alto, a tendência de convergência do indivíduo quântico pode desaparecer.




Figura 7. Portão quântico H_ϵ baseado no portão quântico Q -gate.

Capítulo 4

QEA - Otimização de Funções

Contínuas e Discretas

Neste capítulo serão apresentados os resultados dos testes realizados com o QEA com a implementação do portão quântico H_ϵ na otimização de 4 funções multimodais. Primeiramente, serão apresentadas as características de cada função selecionada. Em seguida, serão apresentados à modelagem do QEA desenvolvida para a otimização das funções consideradas e os resultados obtidos.

4.1 Funções contínuas e discretas

O objetivo deste capítulo é estudar o comportamento do QEA com a implementação do portão quântico H_ϵ na otimização de 4 funções multimodais de natureza contínua ou discreta, chamadas neste capítulo por funções de teste. Além disso, verificar a influência do parâmetro ϵ (do portão quântico H_ϵ) na convergência do algoritmo. Para isso, foram selecionadas as funções Schaffer, Esfera, Rastringin e Rosenbrock.

- **A Função Schaffer**

A função Schaffer é bidimensional e apresenta vários mínimos locais. Sua representação analítica é dada pela equação (19) e sua forma é representada na figura 8.

$$f_1(\vec{x}) = 0.5 + \frac{\sin^2(\sqrt{x_1^2 + x_2^2}) - 0.5}{(1 + 0.001(x_1^2 + x_2^2))^2}, \quad (19)$$




Figura 8. Função Schaffer

Neste trabalho, adotou-se a função Schaffer com dimensão $n = 2$, e o espaço de busca delimitado no intervalo $\vec{x} = [-100, 100]$. Esta função apresenta mínimo global zero (0) e a solução ótima encontrada na literatura é $\vec{x}_{opt} = (x_1, x_2, \dots, x_n) = (0, 0, \dots, 0)$.

- **A Função Esfera**

A função Esfera é uma função contínua, convexa, unimodal e simétrica. Não possui restrições quanto ao número de variáveis consideradas e, por isso sua complexidade aumenta a medida que o número de parâmetros considerados aumenta. Sua representação analítica é dada pela equação (20) e sua forma é representada na figura 9.

$$f_2(\vec{x}) = \sum_{i=1}^n x_i^2, \quad (20)$$

onde, n é o número de parâmetros da função e representa a dimensão do problema.




Figura 9. Função Esfera.

Neste trabalho, adotou-se a função Esfera com dimensões $n = 10$ e $n = 30$, e o espaço de busca delimitado no intervalo $\vec{x} = [-50, 50]$. Esta função apresenta mínimo global zero (0) e a solução ótima encontrada na literatura é $\vec{x}_{opt} = (x_1, x_2, \dots, x_n) = (0, 0, \dots, 0)$.

- **A Função Rastrigin**

A função Rastrigin foi formulada com base na função Esfera com a adição do módulo cosseno, que produz vários mínimos locais, fazendo da função Rastrigin uma função não linear e multimodal. Sua representação analítica é dada pela equação (21) e sua forma é representada na figura 10.

$$f_3(x) = \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i) + 10), \quad (21)$$

onde, n é o número de parâmetros da função e representa a dimensão do problema.




Figura 10. Função Rastrigin

Neste trabalho, adotou-se a função Rastrigin com dimensões de $n = 10$ e $n = 30$ e o espaço de busca delimitado no intervalo $\vec{x} = [-2.56, 2.56]$. Esta função apresenta mínimo global zero (0) e a solução ótima encontrada na literatura é $\vec{x}_{opt} = (x_1, x_2, \dots, x_n) = (0, 0, \dots, 0)$.

- **A Função Rosenbrock**

A função Rosenbrock é uma função não convexa e unimodal. Seu ótimo local está situado dentro de um vale em forma de parábola, onde as variáveis são fortemente dependentes, o que dificulta o processo de convergência para este ponto. Sua representação analítica é dada pela equação (22) e sua forma é representada na figura 11.

$$f_4(x) = \sum_{i=1}^{n-1} 100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2, \quad (22)$$

onde, n é o número de parâmetros da função e representa a dimensão do problema.




Figura 11. Função Rosenbrock

Neste trabalho, utilizou-se a função Rosenbrock será usada com dimensões de $n = 10$ e $n = 30$ e o espaço de busca delimitado no intervalo $x = [-15,15]$. Esta função apresenta mínimo global zero (0) e a solução ótima encontrada na literatura é $\vec{x}_{opt} = (x_1, x_2, \dots, x_n) = (1, 1, \dots, 1)$.

4.2 Modelagem do QEA

O modelo do QEA desenvolvido para a otimização das funções de teste apresentadas na seção 4.1, corresponde basicamente ao modelo apresentado no capítulo 3 com a implementação do portão quântico H_ϵ e com as seguintes alterações: a) mudanças no valor do passo Δ ; b) mudanças no valor do parâmetro ϵ do portão quântico H_ϵ ; c) mudança na forma de construção da população $P(t)$ e, d) implementação do Código Gray (GRAY F., 1953). Na implementação do algoritmo QEA, fez-se: $\text{rand}[0,1] > |\alpha_{ji}(t)|^2$ igual a um (1) e, $\text{rand}[0,1] > |\beta_{ji}(t)|^2$ igual a zero (0). (Figura 12)

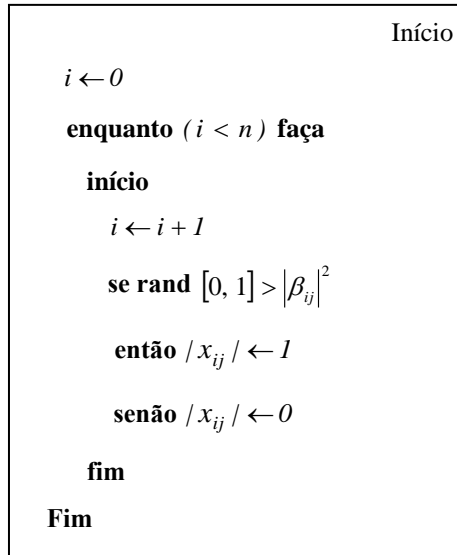


Figura 12. Pseudocódigo de geração de $P(t)$.

Como mencionado no capítulo 3, no QEA cada solução candidata $X_i(t)$ da população clássica $P(t)$ (gerado no passo de observação do indivíduo quântico $q_i(t)$ (figura 12)) é representada por um cromossomo binário. Sabe-se que por se tratar de um cromossomo binário a forma como esse cromossomo é decodificado influencia de forma significativa o resultado final da otimização. Desta forma, com o objetivo de tornar a decodificação de cada indivíduo do QEA mais precisa, foi implementado o Código Gray (Gray, F., 1953). A grande vantagem do uso do Código Gray é que este representa números consecutivos como vetores binários que diferem apenas por um bit, ou seja, na passagem do número 11 para 12, por exemplo, apenas o segundo dígito é mudado, enquanto que no código binário três dígitos (segundo, terceiro e quarto) serão mudados.

Nos testes realizados neste capítulo, o indivíduo quântico da população $Q(t)$ foi inicializado em $t=0$, com $Q(0) = \{q_1(0), q_2(0), \dots, q_n(0)\}$, de tal forma que $\alpha_{ij}(0) = \beta_{ij}(0) = \frac{\sqrt{2}}{2} \quad \forall \quad i = 1, 2, \dots, n \quad \text{e} \quad j = 1, 2, \dots, m$, o que garante $|\alpha_{ij}|^2 = |\beta_{ij}|^2 = \frac{1}{2}$, ou seja, os *qubits* terão a mesma probabilidade de serem encontrados nos estados $|0\rangle$ ou $|1\rangle$ no início do processo. Além disso, o valor do parâmetro A foi fixado em 0.005π (o mesmo usado em NICOLAU, SCHIRRU e MENESES (2011)), e o valor do parâmetro ε foi escolhido através de testes realizados com a função Esfera ($f_2(\vec{x})$), como apresentado na seção seguinte.

4.2.1 Escolha do valor do parâmetro ϵ

O parâmetro ϵ do portão quântico H_ϵ tem a função de diminuir a convergência prematura do algoritmo e reduzir a probabilidade de estagnação do algoritmo em ótimos locais.

Com o objetivo de avaliar a influência do valor usado para o parâmetro ϵ na convergência do QEA, e por consequência determinar um valor de ϵ para ser utilizado na otimização das funções de teste. Foram selecionados diferentes valores para o parâmetro ϵ e tomou-se como referência a função Esfera ($f_2(\vec{x})$). Além disso, utilizou-se uma população de 80 indivíduos, e critério de parada 1000 gerações, dimensão $n = 30$ e fixou-se a semente em 1111. A tabela 2 mostra os resultados do teste realizado.

Tabela 2. Testes com diferentes valores para o parâmetro ϵ

ϵ	<i>QEA</i>
0.000	1.17E-5
0.005	1.17E-5
0.010	9.94E-6
0.020	1.34E-5
0.040	3.32E-5
0.100	9.50E-3
0.200	3.26E-1

Observa-se na tabela 2, que valores de $\epsilon < 0.01$ permitem que o algoritmo encontre melhores resultados na otimização da função $f_2(\vec{x})$ permitindo que o algoritmo escape de mínimos locais. Desta forma, escolheu-se o valor de $\epsilon = 0.01$, para ser usado na otimização das outras funções de teste referenciadas na seção 4.1.

4.3 Testes e Resultados experimentais.

O critério de parada utilizado nos testes realizados foi o número de máximo de iterações, onde usou-se 1000 gerações para a dimensões $n = 10$ e, 2000 gerações para a dimensão $n = 30$. Cada teste foi rodado 10 vezes, com sementes geradas randomicamente, com uma população de 80 indivíduos.

A tabela 3 mostra os melhores resultados experimentais (**Best**) encontrados pelo QEA e o desvio padrão (**St.Dev**) de cada amostra, além disso são destacados a dimensão (Dim) e a geração máxima (Gmax) utilizados.

Tabela 3. Resultados encontrados pelo QEA

<i>Funções</i>	<i>Dim</i>	<i>Gmax</i>	<i>QEA</i>	
			<i>Best</i>	<i>St.Dev.</i>
$f_1(\vec{x})$	2	2000	$1.1*10^{-15}$	$4.7*10^{-3}$
$f_2(\vec{x})$	10	1000	$1.2*10^{-4}$	$9.1*10^{-5}$
	30	2000	$6.1*10^{-2}$	$1.1*10^{-1}$
$f_3(\vec{x})$	10	1000	$1.2*10^{-2}$	1.60E-2
	30	2000	$1.7*10^1$	4.95E+0
$f_4(\vec{x})$	10	1000	$2.0*10^0$	$2.7*10^0$
	30	2000	$4.0*10^1$	$2.5*10^1$

Observa-se na tabela 3 que o QEA apresentou resultados satisfatórios na otimização das 4 funções de teste consideradas, encontrando resultados que se aproximam do ótimo de cada função. E, como era de se esperar o algoritmo apresentou melhor precisão nos resultados, quando se considerou o número de parâmetros $n = 10$.

As figuras 13, 14, 15 e 16 apresentam gráficos que correspondem ao teste mostrado na tabela 3 e mostra o comportamento obtido pela melhor solução para cada função utilizada.




Figura 13. Melhor resultado do QEA para a função Schaffer com $n = 30$

Observa-se na figura 13 que o QEA converge rapidamente (antes da geração 100) para o melhor resultado e que o processo de busca é realizado sem que o algoritmo fique preso em ótimos locais, o que mostra a velocidade de convergência do algoritmo e sua robustez.




Figura 14. Melhor resultado do QEA para a função Esfera com $n = 10$ e $n = 30$.




Figura 15. Melhor resultado do QEA para a função Rastringin com $n = 10$ e $n = 30$




Figura 16. Melhor resultado do QEA para a função Rosenbrock com $n = 10$ e $n = 30$

Observa-se nas figuras 14, 15 e 16 que o QEA converge mais rapidamente para o melhor resultado quando é utilizado um menor número de parâmetros ($n = 10$), porém o mesmo é capaz de convergir para o melhor resultado de cada função sem dificuldades, exceto para a função Rastrigin, o que é verificado também em outros trabalhos da literatura (HAN, K.H., e KIM, J.H., 2004, SUN, J., et. al., (2004), SUN, J., et. al., (2005)).

4.3.1 Comparação entre os resultados obtidos pelo QEA com os do PSO (Particle Swarm Optimization)

Os resultados do QEA para as funções de teste descritas na seção 4.1, foram comparados com os resultados mostrados no artigo de JU SUN et. al., (2005) que utilizou o PSO (KENNEDY e EBERHART, 1995), onde os melhores resultados (*Best*) e o desvio padrão (*St.Dev*) dos resultados encontrados, por cada algoritmo, foram apresentados na tabela 4, onde *M* representa o tamanho da população, *Dim* a dimensão usada para cada função e, *Gmax* o número máximo de gerações utilizado como critério de parada em ambos os algoritmos.

Tabela 4. Comparação dos resultados do QEA com os do PSO.

<i>Functions</i>	<i>M</i>	<i>Dim</i>	<i>Gmax</i>	<i>PSO</i>		<i>QEA</i>	
				<i>Best</i>	<i>St.Dev.</i>	<i>Best</i>	<i>St.Dev.</i>
$f_1(\vec{x})$	80	2	2000	$2.6*10^{-10}$	$3.1*10^{-10}$	$1.1*10^{-15}$	$4.7*10^{-3}$
$f_2(\vec{x})$	80	10	1000	$6.1*10^{-28}$	$2.6*10^{-27}$	$1.2*10^{-4}$	$9.1*10^{-5}$
		30	2000	$2.4*10^{-12}$	$7.2*10^{-12}$	$6.1*10^{-2}$	$1.1*10^{-1}$
$f_3(\vec{x})$	80	10	1000	$2.6*10^0$	2.12 E+0	$1.2*10^{-2}$	$1.6*10^{-2}$
		30	2000	$2.8*10^1$	$1.0*10^1$	$1.6*10^1$	$4.9*10^0$
$f_4(\vec{x})$	80	10	1000	$3.7*10^1$	$5.7*10^1$	$1.9*10^0$	$2.7*10^0$
		30	2000	$2.0*10^2$	$2.9*10^2$	$4.0*10^1$	$2.4*10^1$

Os resultados da tabela 4 mostram que o QEA apresentou performance significativamente melhor que o PSO, em termos de habilidade de busca global e velocidade de convergência para as funções $f_1(\vec{x})$, $f_3(\vec{x})$ e $f_4(\vec{x})$, exceto para a função $f_2(\vec{x})$, provavelmente devido a semente usada no PSO e, além disso obteve o mínimo de todas as funções consideradas.

Capítulo 5

Otimização do Problema da do Combustível Nuclear (PRN)

Neste capítulo serão apresentadas as características do PRN, destacando suas particularidades e tomando como base a Usina Nuclear Angra 1. Além disso, serão apresentados a modelagem do PRN desenvolvido com o algoritmo QEA, para o ciclo 7 de operação da Usina Nuclear Angra 1, bem como os testes e resultados da implementação deste modelo.

5.1 O Problema

Os reatores nucleares do tipo PWR - do inglês Pressurized Water Reactor - geram energia através de reações de fissão nuclear em condições controladas. Estes são projetados para conseguir uma reação em cadeia auto-sustentada utilizando o processo de fissão dos átomos de urânio ($^{92}\text{U}_{235}$ enriquecido a cerca 3%). A principal finalidade é a produção de energia utilizável na forma de eletricidade.

Enquanto for possível sustentar a reação em cadeia mantendo o reator crítico, pode-se dizer que a Usina está operando a sua plena potência. Caso contrário, torna-se necessário o seu desligamento para que o núcleo seja reabastecido. Este procedimento é denominado recarga do combustível nuclear e, ocorre sempre que a queima dos Elementos Combustíveis (EC) no núcleo do reator atinge certos níveis em que não é mais possível manter a Usina operando a plena potência. Neste momento, os EC são descarregados do núcleo e armazenados em uma piscina de combustíveis usados, onde os EC com baixa concentração de $^{92}\text{U}_{235}$ são mantidos definitivamente nesta piscina, enquanto que os EC com maiores concentrações de $^{92}\text{U}_{235}$ remanescentes do ciclo anterior, juntamente com EC novos irão compor o núcleo do ciclo seguinte, respeitando os critérios operacionais e de segurança da Usina. Na operação de recarga de um reator PWR, por exemplo, ao final de um ciclo de operação, aproximadamente 1/3 dos EC são

substituídos por elementos novos, que juntamente com os 2/3 restantes irão formar um novo padrão de carregamento.

O problema relacionado com a operação de recarga, aqui chamado de PRN, consiste na determinação de como os EC novos e reutilizados deverão ser combinados e redistribuídos no núcleo do reator de modo a otimizar o próximo ciclo de operação. Isso ocorre porque a queima dos EC não ocorre de maneira homogênea, sendo necessário encontrar uma configuração ótima de embaralhamento dos mesmos.

No entanto, este processo é altamente complexo e pertencente à classe dos problema não polinomiais (NP) completos, onde a dificuldade cresce exponencialmente de acordo com o número de EC considerados. No caso particular da Usina Nuclear Angra 1, localizada no sudeste do Rio de Janeiro, o núcleo do reator é composto por 121 EC, resultando em aproximadamente 10^{200} possíveis combinações de padrões de carregamento, que devido à existência de restrições de posicionamento dos EC, relacionadas com a geometria do núcleo, pode ser reduzido para um total de aproximadamente 10^{25} possíveis combinações de padrões de carregamento. Desta forma, com o uso de computadores e códigos de física de reatores atuais seriam necessários cerca de $5,8 \times 10^{19}$ anos para que todas essas combinações fossem testadas.

Além disso, avaliar uma única combinação de EC também tem sua complexidade, pois é necessário o uso de códigos de físicas de reatores que demandam tempo computacional considerável. Tais códigos são responsáveis por realizarem os cálculos numéricos provenientes de sistemas e equações diferenciais de transporte e difusão de nêutrons, para que sejam determinados entre outras coisas, os valores de distribuição de potência e queima do EC, informações essas necessárias para que seja feita a análise e previsão do funcionamento da Usina (MENESES, 2010).

A procura por uma configuração ótima de recarga é dependente dos objetivos que se quer alcançar no final do processo. Um dos objetivos mais desejados é o de um padrão de carregamento que maximize a vida útil do combustível nuclear permitindo um aumento do ciclo de queima do combustível e, conseqüentemente um aumento de lucros para a Usina. Por exemplo, um padrão de carregamento que forneça um dia a mais de operação para a Usina Nuclear Angra 1, trará ganhos de centenas de milhares

de dólares. Desta forma, o PRN é, portanto um problema de grande interesse econômico e de extrema relevância para a área nuclear.

Durante décadas o processo da recarga foi realizado somente através da otimização manual, onde especialistas utilizavam seus conhecimentos e experiências para construírem padrões de carregamento, testando-os para verificar se os mesmos atendiam as restrições de segurança da Usina. A partir da década de 80, vários trabalhos foram propostos com o intuito de automatizar este processo da recarga, ou seja no sentido de construir sistemas de computador que fosse capaz de otimizar o processo da recarga sem a participação direta de especialistas.

Um trabalho de grande relevância desenvolvido no início dos anos 90, que demonstrou a viabilidade de uma otimização automatizada, foi o código computacional FORMOSA (Fuel Optimization for Reloads) desenvolvido por KROPACKZEK e TURINSKY, (1991). O código FORMOSA, utilizou a técnica SA (Simulated Annealing) para orientar a busca de padrões carregamento e, além de apresentar bons resultados foi comercializado por seus autores.

Uma nova abordagem para o código FORMOSA foi proposta por POON e PARKS, (1992). Nesta abordagem a técnica SA foi substituída pelo algoritmo genético no processo de otimização. Tal trabalho não só confirmou a viabilidade de automatizar o processo da recarga através de técnicas de otimização, como também mostrou que, embora fosse necessário aprofundar as pesquisas o algoritmo genético tendia a superar o desempenho do algoritmo SA, particularmente em ambientes de processamento em paralelo.

DECHANE e FELTRUS, (1995) desenvolveram o código CIGARO (Code Independent Genetic Algorithms Reactor Optimization System), baseado no algoritmo genético. O código CIGARO mostrou que os algoritmo genético eram ferramentas promissoras para a solução de problemas complexos, em especial o PRN.

A SIEMES/KWU (1999) emitiu um boletim de divulgação informando que tinha desenvolvido um sistema automático para otimizar o processo da recarga para reatores

do tipo PWR, chamado de PRIMO. Tal código era baseado no algoritmo genético e foi incorporado ao sistema de cálculos neutrônicos daquela corporação.

CHAPOT et. al., (1999) desenvolveram um sistema inovador para a otimização do processo da recarga. O sistema desenvolvido foi baseado no algoritmo genético e apresentava um modelo de lista para gerar padrões de recarga válido evitando desta forma, o uso de operadores de crossover heurísticos utilizados nos modelos anteriores.

Desde então, diversos métodos de otimização têm sido desenvolvidos e simulados para o PRN na tentativa de automatizar o processo da recarga. Ao longo dos anos, observa-se que a aplicação de técnicas de Inteligência Computacional tais como: Aprendizado Incremental Baseado em Populações (Population-Based Incremental Learning, PBIL) ((MACHADO, 1999; MACHADO, 2005; SCHIRRU et. al., 2006), Ant Colony Optimization (ACO) (MACHADO E SCHIRRU, 2002; DE LIMA, 2005), Ant Colony Connective Networks (ACCN) (DE LIMA et. al., 2008), Free Population-Based Incremental Learning (FPBIL) (CALDAS et. al., 2008) e Particle Swarm Optimization (PSO) (MENESES et. al., 2009, WAINTRAUB et. al., 2009) têm apresentado bons resultados para a solução do problema.

Nos últimos anos, novas pesquisas (NICOLAU, SCHIRRU e MENESES, 2011 (Quantum Evolutionary Algorithm (QEA)), DA SILVA et. al., 2010 (Quantum Ant Colony Optimization (QACO)), e DA SILVA e SCHIRRU, 2011 (Quantum Populational-Based Incremental Learning (QPBIL)) têm mostrado que algoritmos evolucionários de inspiração quântica estão entre as melhores alternativas para lidar com problemas de otimização em Engenharia Nuclear, uma vez que apresentam um potencial de redução no tempo computacional.

Devido à dificuldade e importância de resolver o PRN, o mesmo tornou-se um problema de destaque no meio acadêmico, no sentido de desafio de desenvolver novos algoritmos para encontrar soluções ótimas com o menor número de avaliações possíveis, dentro das restrições operacionais e de segurança impostas.

Dentro deste contexto, neste trabalho foi desenvolvido uma modelagem com o algoritmo QEA, para o ciclo 7 de operação da Usina nuclear Angra 1, com o objetivo de

analisar o comportamento do QEA frente aos resultados apresentados por outros métodos da literatura. Onde buscou-se encontrar padrões de recarga, ou seja combinações de EC, que maximizem o tamanho do ciclo de recarga. Cabe ressaltar que o tamanho do ciclo da recarga é medido em função do número de dias em que a Usina permanece em atividade a plena potência e que esses números de dias são calculados em função da concentração de boro (C_B) no moderador. Assim, a metodologia desenvolvida neste trabalho teve como objetivo encontrar padrões de recarga que forneçam valores altos de C_B , respeitando os limites técnicos e de segurança da Usina.

5.2 A Usina Nuclear Angra 1

A Usina Nuclear Angra 1 é do tipo PWR de dois loops e está localizada na praia de Itaorna em Angra dos Reis no sudeste do Rio de Janeiro, Brasil. Inaugurada em 1984, é atualmente operada pela Eletronuclear e em plena potência fornece ao sistema elétrico brasileiro cerca de 640MW de energia diário.

Desenvolvido pela Westinghouse, o núcleo de Angra 1 é formado por 121 EC, onde cada EC é composto de 235 varetas combustíveis, que são sustentadas por uma estrutura composta de 20 tubos guias de barra de controle, 1 tubo de instrumentação nuclear, 8 grades espaçadoras e 1 bocal em cada extremidade. A figura 5 mostra uma representação da vista superior do núcleo do reator da Usina Nuclear Angra 1, com seus respectivos 121 EC.




Figura 17. Representação do núcleo do reator de Angra 2.

Observa-se na figura 17 que o núcleo do reator é dividido por dois eixos principais, chamados de eixos de simetria de 1/4, que dividem o núcleo em quatro regiões e, por dois eixos secundários, chamados de eixos de simetria de 1/8, que dividem o núcleo em oito regiões. Verifica-se que, geometricamente, o núcleo do reator é simétrico sob reflexões em relação a cada um desses eixos. Consequentemente, a posição de cada EC localizado fora dos eixos possui outras 7 posições simétricas, onde cada EC localizado em uma dessas posições é chamado de octeto. Por outro lado, a posição de cada EC localizado sobre apenas um dos eixos possui somente outras 3 posições simétricas, e cada um desses EC é chamado de quarteto. Chama-se elemento central o EC que ocupa a posição sobre os 4 eixos simultaneamente. (CALDAS, 2006)

No sentido de desenvolver modelos mais simples para o núcleo do reator os eixos de simetria são utilizados e possibilitam uma redução do número de EC a serem combinados. Neste trabalho, assim como em trabalhos anteriores da literatura, utilizou-se o modelo de 1/8 de núcleo ou simetria de octeto. Neste modelo, somente 20 EC são permutados, sendo 10 EC de quarteto e 10 EC de octeto. Embora, a simetria de octeto possibilite uma redução da complexidade do problema, pois o número de EC passa de 121 para 20, o problema continua sendo extremamente complexo, uma vez que possui um número de $20!$ soluções possíveis. A figura 18 mostra uma representação da vista superior do núcleo do reator de Angra 1 com a simetria de octeto.




Figura 18. Representação da simetria de 1/8 de núcleo do reator de Angra 1

5.3 Modelagem do QEA

No modelo de QEA desenvolvido para a otimização do ciclo 7 de operação da Usina Nuclear Angra 1, cada solução candidata $X_i(t)$ da população clássica $P(t)$, gerado no passo de observação do indivíduo quântico $q_i(t)$, é um cromossomo binário com 240 bits, dividido em 20 segmentos de 12 bits. Este cromossomo é convertido em sequências de números reais pelo Código Gray (Gray, F., 1953), com o objetivo de representar os 20 EC (10 EC de quarteto e 10 EC de octeto) que irão ocupar o núcleo do reator Angra 1, com simetria de octeto. A figura 19 mostra o procedimento de construção do EC a partir do indivíduo quântico.

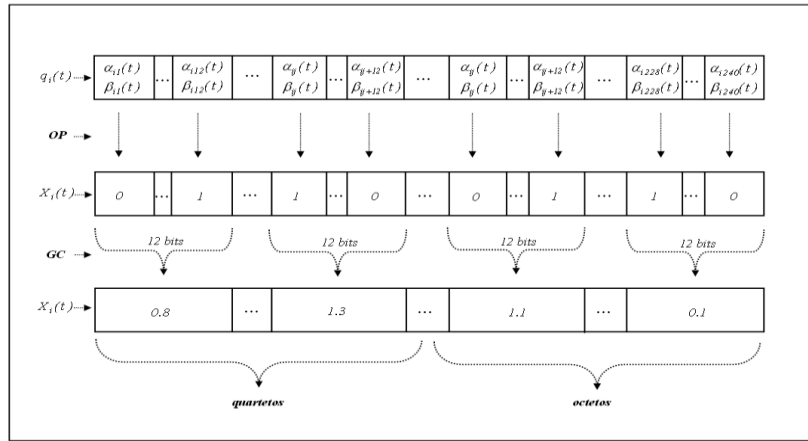


Figura 19. Procedimento de construção do EC a partir do indivíduo quântico

No entanto, durante este processo de conversão pode ocorrer a repetição de algum desses valores (EC), porém, um padrão de carregamento gerado com repetição de EC não é considerado válido, pois um mesmo EC não pode ocupar mais de uma posição no núcleo. Desta forma, para evitar que ocorra repetição de EC usamos o Modelo de chaves aleatórias, conhecido na literatura por Random Keys. (BEAN, 1994).

O Modelo de chaves aleatórias (também usado em outros trabalhos da literatura) mapeia um vetor de números reais em um vetor solução de números inteiros não repetidos, permitindo desta forma, a formulação de um padrão de carregamento válido. Para exemplificar o principio de funcionamento da metodologia de chaves aleatórias, tomemos com exemplo uma solução candidata $X_i(t)$ gerada pelo QEA, de 20 posições (onde, as primeiras 10 posições são ocupadas por EC de quarteto, e as outras 10

posições restantes são ocupadas por EC de octeto). Primeiramente, localiza-se em cada uma dessas 10 posições (posições de quarteto e de octeto) o EC de menor valor, de forma independente. Em seguida, representa-se tal EC em um vetor solução $X'_i(t)$ (também de 20 posições), utilizando o número de sua posição no vetor $X_i(t)$. O mesmo procedimento é repetido para o segundo EC de menor valor e, assim sucessivamente. Cabe ressaltar que tal procedimento foi realizado nesta abordagem, separadamente para os EC de quarteto e, para os EC de octeto, respeitando suas posições no vetor $X_i(t)$. A figura 20 mostra esse procedimento de forma detalhada.




Figura 20. Procedimento realizado pelo Random Keys

Desta forma, através da implementação do Modelo de chaves aleatórias uma solução candidata $X_i(t)$ gerada pelo QEA não apresentará repetição de EC. Porém, para que a Usina seja operada dentro das restrições de segurança, cada solução candidata gerada pelo QEA deve ser avaliada por um Código Nodal de Física de Reatores.

Um Código Nodal de Física de Reatores, de uso comercial para estudos de otimização de recargas de reatores, deve conter os seguintes módulos: fluxo-potência-reatividade; queima de combustível, pesquisa de criticalidade com boro solúvel, modelos de realimentação, onde se incluem a correção de densidade do moderador e a realimentação Doppler, entre outros e a reconstrução da distribuição de densidade de potência pino a pino, para que se possa determinar o fator de pico de potência radial (Fxy) das varetas combustíveis.

Em nossa aplicação o Código de Física de Reatores usado para avaliar cada candidato a solução, gerado pelo QEA, foi o Código Nodal de Física de Reatores RECNOd, desenvolvido por CHAPOT (2000) que utiliza uma variação do método de expansão de fluxo criado por LANGENBUCH et. al. (1977). O RECNOd não possui os módulos com os modelos de realimentação termohidráulica e nem aquele para a reconstrução da distribuição de potência pino a pino, necessário para o cálculo do fator de pico de potência radial. Por isso, o fator de pico de potência radial foi substituído pela máxima potência média relativa (P_{rm}), parâmetro este que segundo CHAPOT (2000), pode substituir o fator de pico de potência radial com erro de $\pm 2\%$. Em termos computacionais esse fato não é relevante, pois o foco é a otimização e, a variação deste parâmetro equivale ao comportamento não linear do fator de pico de potência radial. Porém, em termos físicos CHAPOT (2000) demonstra que a limitação da potência média relativa em 1.395 para o caso considerado (ciclo 7 de operação da Usina Nuclear Angra 1) garante que o fator de pico de potência radial é mantido abaixo de 1.435 (limite dado na Especificação Técnica de Angra 1) .

Os parâmetros avaliados pelo RECNOd são: a concentração de boro (C_B) e a máxima potência média relativa dos EC (P_{rm}). Neste caso, o P_{rm} substituí o fator de pico de energia e é usado como um parâmetro de segurança, uma vez que o RECNOd não calcula o fator de pico de potência radial. No entanto, o uso do P_{rm} implica na não violação das especificações técnicas de centrais nucleares e seu valor limite é de 1.395, para o ciclo 7 da Usina Nuclear Angra 1. Por outro lado, a C_B fornecida pelo RECNOd é dado no equilíbrio do Xenônio, o qual é um outro aspecto que reduz o custo computacional do processo sem afetar a validade do propósito da otimização. CHAPOT, (2000) demonstra que é possível extrapolar e prever o tamanho do ciclo do reator baseado no valor da C_B e no nível do Xenônio.

A função objetivo (23) desenvolvida por (DE LIMA et. al., 2008) foi utilizada neste trabalho para avaliar cada indivíduo clássico do QEA. Observa-se que essa função leva em consideração dois parâmetros fundamentais: a concentração de boro (C_B) e a potência média (P_{rm}) no EC, parâmetros esses fornecidos pelo RECNOd.

$$Fitness = \begin{cases} \frac{1}{C_B}, & \text{se } P_{rm} \leq 1.395 \\ P_{rm}, & \text{caso contrário} \end{cases}, \quad (23)$$

Observa-se na função objetivo que, enquanto o valor de $P_{rm} > 1.395$ a função agirá no sentido de minimizar este valor independentemente do valor da C_B e só após encontrar um padrão de recarga válido passará a maximizar o valor da C_B .

5.4 Metodologia

Com o objetivo de avaliar o desempenho do algoritmo QEA na solução do PRN, o ciclo 7 de operação da Usina Nuclear Angra 1 foi tomado como referência. Nesta abordagem, não foram usados venenos queimáveis na simulação e, os EC de quarteto somente podem trocar de posição com os EC de quarteto e o mesmo é válido para os EC de octeto, além disso, o elemento central não participa da permutação. Tais restrições foram usadas para efeito de comparação com trabalhos anteriores da literatura.

O método proposto foi implementado no MatLab 6.5, onde cada solução candidata $X_i(t)$ gerada pelo QEA foi decodificada em um padrão de recarga válido através do modelo de chaves aleatórias, processada pelo código RECNOD e em seguida, avaliada pela função objetivo. O método desenvolvido foi usado como ferramenta de otimização para determinar a C_B em 30 experimentos com 30 sementes diferentes, com uma população de 200 indivíduos e, critério de parada 1.000 gerações, num total de $2.0 \cdot 10^5$ avaliações para cada execução do algoritmo.

O indivíduo quântico da população $Q(t)$ foi inicializado em $t=0$ com $Q(0) = \{q_1(0), q_2(0), \dots, q_n(0)\}$, de tal forma que $\alpha_{ij}(0) = \beta_{ij}(0) = \frac{\sqrt{2}}{2} \quad \forall \quad i = 1, 2, \dots, n$ and $j = 1, 2, \dots, m$. Como consequência $|\alpha_{ij}|^2 = |\beta_{ij}|^2 = \frac{1}{2}$, o que significa que os *qubits* terão a mesma probabilidade de serem encontrados nos estados $|0\rangle$ ou $|1\rangle$ no início do processo. Além disso, foi usado o parâmetro $\Delta = 0.003 \cdot \pi$ e $\varepsilon = 0.01$, por serem estes os que mais se adaptaram ao problema.

5.5 Testes e Resultados experimentais

A tabela 5 apresenta os resultados experimentais encontrados pelo método desenvolvido, destacando as sementes usadas nos testes realizados e o número de avaliações em que o resultado foi encontrado.

Tabela 5. Resultados do QEA

<i>Semente</i>	<i>Concentração de Boro (C_B)</i>	<i>Avaliações</i>
9999	1431	95.400
0000	1416	128.800
2501	1409	122.000
7777	1407	142.200
2011	1406	106.800
5555	1402	130.400
1487	1402	119.000
6975	1401	100.600
9586	1401	68.000
4444	1400	98.600
1364	1431	70.400^a
1253	1402	143.200
1223	1402	198.400
1255	1402	118.400
9912	1409	99.800
1989	1403	120.000
1115	1405	157.200
6666	1398	72.800
1154	1396	95.800
1405	1392	160.600
1265	1371	168.800
1515	1353	78.400
1258	1315	58.000
8888	1333	188.400
1111	1315	185.200
2548	1311	92.800
1234	1351	83.000
1118	1328	77.689
Média	1385	117.167
Std*	35.54	38.95

^a Melhor valor encontrado na geração 352, com $P_{rm} = 1.393$

*Std = desvio padrão.

Pode-se observar na tabela 5, que o melhor valor encontrado para a C_B foi 1431 ppm com $P_{rm} = 1.394$. Levando em consideração que a Usina Nuclear Angra 1 produz uma média de 627 MW por dia e, que aproximadamente 4 ppm de boro são consumidos em um dia efetivo a plena potência. Pode-se dizer que com 1431 ppm de boro encontrada com o método desenvolvido, ter-se-ia aproximadamente 358 dias efetivos de operação a plena potência para a Usina. Além disso, ainda na tabela 5, pode-se observar que independente da semente usada o QEA converge para valores de C_B perto de 1400 ppm e que o melhor valor de C_B foi encontrado três vezes em 30 rodadas, o que ressalta a robustez do método desenvolvido e, o bom desempenho do algoritmo QEA no processo de busca de um padrão de recarga “próximo do ótimo”.

Na figura 21 é apresentada a curva de evolução do QEA para o melhor valor da C_B apresentado na tabela 5.




Figura 21. Curva de evolução do QEA para o melhor valor da C_B mostrado na tabela 5

Observa-se na figura 21 uma rápida convergência do QEA, onde os valores para a C_B crescem gradualmente e perto da geração 400 o algoritmo converge para o melhor resultado - 1431 ppm de boro. Uma vez que no PRN o número de avaliações é um fator crucial, devido ao seu alto custo computacional, pode-se dizer com os resultados encontrados que o QEA é um promissor algoritmo de otimização para o PRN, pois em poucas gerações é capaz de encontrar resultados satisfatórios.

As características nucleares (queima e K_∞) dos EC da melhor solução encontrada pelo QEA, em destaque na tabela 5, são apresentados na tabela 6.

Tabela 6. Valores de queima e de K_∞

EC	queima (MWD/TU)	K_∞
1	9603	1.069
2	13.045	0.906
3	7882	1.087
4	13.006	0.906
5	0	1.187
6	13.012	0.906
7	14.650	1.037
8	8622	1.079
9	13.181	0.903
10	0	1.193
11	14.068	1.026
12	13.115	0.906
13	13.135	0.904
14	0	1.188
15	0	1.194
16	11.404	1.050
17	7873	1.099
18	0	1.191
19	0	1.188
20	13.258	0.907

Observa-se na tabela 6, uma sensível diferença nos valores do K_∞ dos EC novos, onde a maior delas é de 0.007. Tal diferença ocorre devido a aproximações numéricas, pois o código de Física Reatores RECNOD realiza o cálculo da seção de choque de cada EC posicionados dentro do núcleo do reator.

5.5.1 Comparação entre os resultados obtidos pelo QEA com os do AG

O principal objetivo desta seção é comparar o valor da C_B encontrada pelo método desenvolvido neste trabalho com o QEA, com os resultados de C_B encontrados por sua contrapartida clássica o AG, desenvolvido por CHAPOT et. al. (1999). A tabela 7 mostra essa comparação, onde é apresentado o melhor valor para C_B encontrado por cada algoritmo, bem como o valor do P_{rm} , a média e o desvio padrão dos resultados.

Na tabela 7 o valor C_B encontrado para o processo da recarga por especialistas, ou seja, de forma manual é mostrado com o intuito de comparar a diferença nos valores encontrados por padrões de carregamento feitos de forma automática com aqueles feitos de forma manual.

Tabela 7. Resultados da C_B obtidos pelo QEA e pelo GA

<i>Meraheurística</i>	C_B	Média(C_B)	*Std	P_{rm}
Manual	955	(---)	(---)	1.366
AG	1197	703	381.95	1.373
QEA	1431	1385	35.54	1.393

*Std = desvio padrão da C_B , (---) Resultado não conhecido,

Pode-se observar na tabela 7 que ambos os algoritmos QEA e AG são capazes de encontrar padrões de recarga que fornecem valores para a C_B melhores que o padrão de recarga feito de forma manual. Além disso, uma vez que a Usina Nuclear Angra 1 consome cerca de 4 ppm de boro a cada dia de operação, o valor da C_B encontrada pelo QEA quando comparada com o valor da C_B encontrada por sua contrapartida clássica o GA, é capaz de proporcionar 60 dias (2 meses) a mais para duração do ciclo 7 de

operação da Usina Nuclear Angra 1. E por sua vez, quando comparado com o padrão de carregamento manual, o valor da C_B fornecida pelo QEA permite 119 dias a mais na duração do ciclo 7 de operação da Usina. A figura 22 mostra a representação dos EC fornecido pelos métodos desenvolvidos com o QEA e com o AG para o melhor padrão de carregamento em destaque na tabela 7.

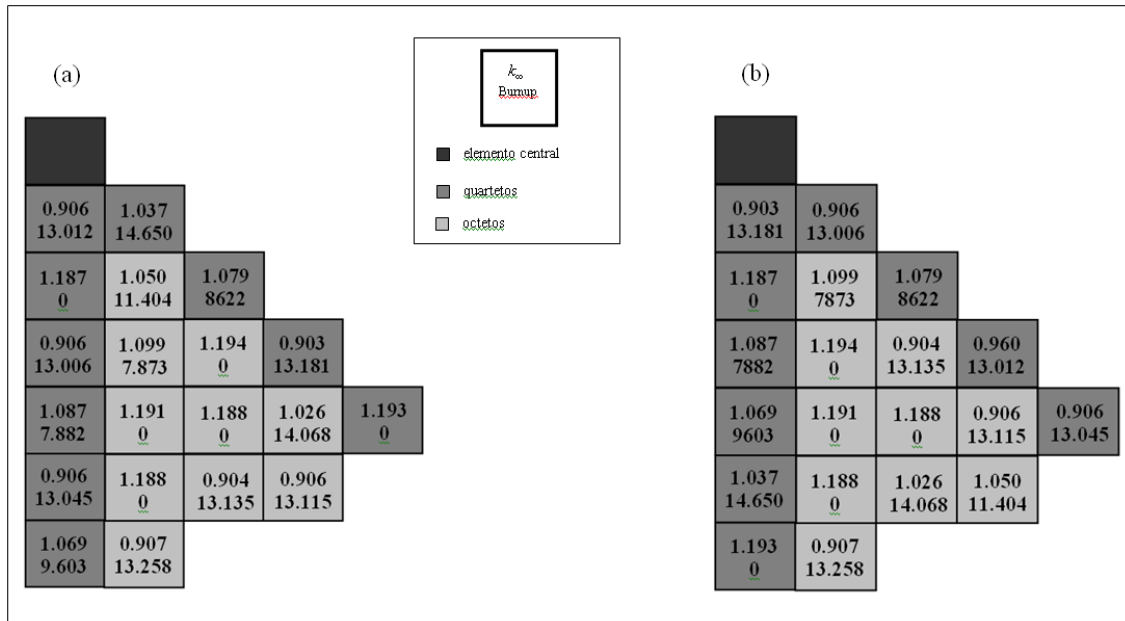


Figura 22. Representação de simetria de 1/8 de núcleo para o resultado obtido pelo GA (a) e para o resultado obtido pelo QEA (b), mostrados na tabela 7

5.5.2 Comparação entre os resultados obtidos pelo QEA com de outras metaheurísticas da literatura

O PRN mais especificamente a maximização do ciclo 7 de operação da Usina Nuclear Angra 1, vem sendo ao longo dos anos um problema de otimização largamente estudado por diversos pesquisadores brasileiros e, uma vasta gama de algoritmos de IA vem sendo implementados ao problema, fazendo com que o mesmo se torne um benchmark no Brasil.

Modelos de otimização para o ciclo 7 de operação da Usina Nuclear Angra 1, utilizando diferentes algoritmos de IA, tais como: PBIL-MO², ACS, PSO, QACO e QPBIL, foram propostos nos últimos anos. A tabela 8 mostra os resultados das

implementações desses algoritmos. Cabe ressaltar que, todas esses modelos foram desenvolvidos nas mesmas condições do método desenvolvido nesta tese, onde os resultados mostrados na tabela 8 foram analisados levando em consideração o melhor valor encontrado para a C_B e o número de avaliações gasto na otimização.

Tabela 8. Resultados obtidos por diferentes algoritmos na otimização do ciclo 7 de operação da Usina Nuclear Angra 1

Referências	Metaheurística	C_B	média (C_B)	Std	Avaliações
MACHADO e SCHIRRU, 2002	Ant-Q	1297	1098	94	200
MACHADO et. al., 2005	PBIL-MO ²	1305	1004	71	10000
DE LIMA et. al., 2008	ACCN	1424	1350	45	329000
CALDAS E SCHIRRU, 2008	FPBIL	1428	1353	65	430364
MENESES et. al., 2009	PSORK	1394	1168	95	4000
DA SILVA et. al., 2010	QACO	1415	1330	71	99240
DA SILVA et. al., 2011	QPBIL	1413	1383	45	49680
<i>Presente trabalho</i>	<i>QEA</i>	<i>1431</i>	<i>1385</i>	<i>35</i>	<i>70.400</i>

Analisando a tabela 8, pode-se observar que o QEA encontrou valores superiores para a C_B em um menor número de avaliações, que os algoritmos de otimização Ant-Q, PBIL-MO, ACCN, FPBIL e PSORK e, além disso, foi capaz de encontrar resultados similares aos encontrados pelos algoritmos de inspiração quântica QPBIL e QACO. Pode-se dizer que existem duas principais razões para isso. A primeira razão, é que a codificação quântica das soluções candidatas reduz consideravelmente o número necessário de cromossomos para que se tenha uma boa diversidade no processo de busca, pois cada cromossomo é capaz de representar, ao mesmo tempo, várias soluções possíveis. E a segunda razão, é que o fenômeno de interferência quântica utilizado pelos

algoritmos de inspiração quântica reforça a busca de melhores soluções na vizinhança da solução atual.

Ainda de acordo com a tabela 8, a média dos valores da C_B obtidos com o método desenvolvido com o QEA é melhor que de todos os outros métodos da literatura considerados, embora o QPBIL tenha apresentado resultados similares. Sendo assim, pode-se dizer que os resultados apresentados na tabela 8 não só confirmam a robustez do QEA como também mostram que os algoritmos de inspiração quântica são potenciais ferramentas de otimização para o PRN.

Capítulo 6

Otimização do Problema de Identificação e Diagnóstico de Acidentes de uma Usina Nuclear (PDA)

Neste capítulo serão apresentadas as principais características do PDA, os principais transientes operacionais e, acidentes de base de projeto postulados para a Usina Nuclear Angra 2, bem como as principais características de um Sistema de Suporte a equipe da sala de controle de uma Usina Nuclear.

6.1 O Problema

Uma central nuclear é um sistema complexo composto de muitos sistemas e milhares de componentes, cuja filosofia de segurança está dirigida no sentido de que sejam projetadas, construídas e operadas com os mais elevados padrões de qualidade e confiabilidade.

A operação de uma central nuclear envolve o controle e monitoração de seus sistemas e milhares de componentes, cujas falhas podem provocar o aparecimento de situações anormais, que devem ser identificadas, diagnosticadas e corrigidas a tempo, para que a integridade da Usina seja preservada.

As tarefas de monitoração, identificação e tomada de decisão, no caso de ocorrência de eventos anormais em uma central nuclear, são realizadas pela equipe da sala de controle. O desempenho dos operadores em uma situação de emergência, atualmente depende fundamentalmente da capacidade dos mesmos em identificar corretamente o evento em curso e tomar ações corretivas com a máxima certeza associada e em curto intervalo de tempo. No entanto, a realização dessas tarefas em

condições anormais de operação da Usina, torna-se cada vez mais difícil de serem realizadas devido a diversos fatores.

Um desses fatores está relacionado com o amplo escopo das atividades de identificação e diagnóstico que abrangem uma variedade de anomalias, tais como falhas nas unidades de processo, degradação dos processos da unidade, desvios de parâmetros das variáveis de processo, entre outros. No caso de ocorrência de um evento anormal, as atividades de identificação e diagnóstico, tornam-se ainda mais difíceis e complexas de serem realizadas, pois o operador é levado a analisar uma grande quantidade de informações oriundas de instrumentos de medidas e alarmes inerentes da planta. Tais medidas, por sua vez, podem por muitas vezes serem insuficientes, incompletas ou não confiáveis devido a diversos fatores como, por exemplo, desvio ou falhas em algum instrumento de medida, o que poderá agravar ainda mais a situação da equipe da sala de controle.

Devido à complexidade e dificuldade da realização das tarefas de identificação e diagnóstico do evento em curso, no caso de situações anormais da planta, não é de grande surpresa, que mesmo sendo submetidos a um árduo treinamento e que possuam um grande conhecimento sobre a operação da Usina, a equipe da sala de controle tenha dificuldades e, até mesmo venha cometer falhas na realização de suas tarefas. Caso um evento em curso, seja diagnosticado de forma incorreta, existe o potencial de que as ações subsequentes realizadas pela equipe da sala de controle, na tentativa de conter o evento em curso, causem degradação das condições de segurança da planta, podendo transformar, por exemplo, o que seria um simples transiente operacional, em um acidente de grandes proporções, como ocorreu na unidade 2 da Central Nuclear de Three Mile Island (TMI), onde iniciado por problemas mecânicos, foi exacerbado por uma combinação de erros por parte da equipe da sala de controle na tentativa de respostas a esses problemas.

Desta forma, as tarefas realizadas pela equipe da sala de controle em situações de emergência são consideradas complexas, não somente pela alta dimensionalidade do espaço de busca, mas também, pela dificuldade de monitoração do comportamento de um grande número de variáveis associadas ao evento em curso. No entanto, as tarefas realizadas caracterizam um problema real da engenharia nuclear, conhecido como

Problema de Identificação e Diagnóstico de eventos anormais/transientes/acidentes em uma Usina Nuclear, que vem sendo estudado a décadas e ainda encontra-se sem solução definitiva.

A solução deste proeminente problema afeta diretamente não só a segurança da Usina, como também a segurança do público e do meio ambiente. Além disso, é de extrema relevância, no que concerne a diminuição da sobrecarga cognitiva a que a equipe da sala de controle fica submetida no caso de ocorrência de situações anormais na operação da Usina.

6.2 *Sistemas de suporte ao operador*

Na tentativa de solucionar o Problema de Identificação e Diagnóstico de eventos anormais em uma Usina Nuclear e, desta forma, facilitar e auxiliar a equipe da sala de controle na realização de suas tarefas, uma vasta gama de sistemas de suporte, principalmente na monitoração das condições da instalação e na tomada de decisões, tem sido proposto ao longo dos anos.

As principais tarefas desses sistemas de suporte são: a detecção e o isolamento de falhas. As falhas representam o desvio de comportamento de algum sistema ou componente da Usina em relação à situação esperada. Estas falhas podem ser um acidente de base de projeto, um transiente operacional postulado ou até mesmo um evento desconhecido. A detecção da falha é feita em tempo real e consiste na geração de sintomas para os indicadores e avaliadores de falhas no momento da detecção. O isolamento de falhas determina a partir de um conjunto de sintomas o tipo e a localização da falha primária e, relaciona-o com um componente físico, cujo comportamento não é consistente.

No caso de ocorrência de um evento anormal durante a operação de uma Usina Nuclear é possível observar a evolução temporal das variáveis de processo envolvidas, através de instrumentos de monitoração da Usina, a partir de um estado estacionário, uma vez que a evolução de cada variável envolvida no evento apresenta um padrão bem definido (curvas) e esses padrões são únicos no que diz respeito ao tipo de evento. Desta

forma, é possível distinguir o evento em curso através da seleção adequada de parâmetros de processo da planta. Porém, tal solução não é tão fácil, pois como mencionado uma Central Nuclear é um sistema extremamente complexo e, o seu funcionamento envolve a monitoração de muitas variáveis de processo.

Uma forma que os pesquisadores tem encontrado para diminuir a complexidade do PDA, é desenvolver sistemas de suporte utilizando as curvas de variáveis de processo de acidentes de base de projeto, como uma forma de separar características específicas de cada evento conhecido e, a partir dessas características identificar/classificar eventos desconhecidos como sendo similares ou diferentes a esses padrões conhecidos. Um sistema de suporte desenvolvido nesses moldes utiliza um modelo de classificação e reconhecimento de padrões e, é baseado em processamento de dados ou conhecimento especializado sobre o comportamento de algum sistema ou componente importante da Usina, onde variáveis de estado relevantes são selecionadas para representarem um conjunto de falhas conhecidas. Desta forma, podem simplesmente diagnosticar e classificar a falha, como também podem indicar ações a serem tomadas.

Um sistema de suporte ao operador baseado no modelo de classificação e reconhecimento de padrões deve ser capaz de reconhecer em tempo real o evento em curso, representado por novos vetores de variáveis de estado e associá-lo somente a uma das falhas conhecidas em curto intervalo de tempo. No entanto, não basta apenas que o sistema seja rápido, a identificação também deve ser robusta e confiável com relação a ruídos nos dados. Além disso, é de extrema importância que o sistema seja capaz de fornecer uma resposta “Não Sei” para eventos desconhecidos, isto é, eventos não pertencentes ao conjunto de treinamento.

Dessa forma, o problema de identificação e diagnóstico de acidentes de uma Usina Nuclear, pode ser visto como um problema de separação de dados baseado em classes, onde a principal finalidade do sistema é identificar semelhanças ou não semelhanças com alguns padrões já definidos, ou seja, verificar que dados de um mesmo grupo (evento) apresentam mais características em comum entre si, do que com dados pertencentes a outro grupo.

Ao longo dos anos técnicas de Inteligência Artificial (IA), tais como sistemas especialistas, redes neurais artificiais, lógicas nebulosas, algoritmos bioinspirados e algoritmos com inspiração quântica têm sido utilizados na construção de modelos de sistemas de suporte a equipe da sala de controle de uma Usina Nuclear, baseado em modelos de classificação e reconhecimento de padrões. Essas técnicas de IA são capazes de contornar de forma eficaz o problema da complexidade do espaço de busca, não necessitando das condições de continuidade e existência de derivadas, normalmente exigida pelos métodos clássicos e, são na maioria deles utilizados como técnicas de clusterização, onde são responsáveis por verificar similaridades entre os padrões apresentados.

Um dos primeiros modelos protótipos de sistemas de suporte a equipe da sala de controle de uma Usina Nuclear foi um modelo baseado em técnicas de inteligência artificial, proposto por BARTLETT e UHRIG (1992), onde foram utilizadas redes neurais para o diagnóstico de falhas. Tal modelo foi apresentado no trabalho: “Nuclear Power Plant Diagnostics Using an Artificial Neural Network”.

Em 1994, BASU e BARTLETT aperfeiçoaram 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 protótipo 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 obtidas em instantes anteriores eram 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 das variáveis selecionadas e produz na saída a melhor classificação parcial 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. Porém, a dificuldade ocorre nos casos para os quais a função discriminação (critério de classificação) depende de muitas variáveis, onde é necessário uma análise da interação entre duas ou mais variáveis.

Um método alternativo de sistema de suporte para identificação de transiente foi proposto por JEONG, FURUTA e KONDO, (1996), usando o que eles chamaram de “*adaptive template matching*”. Tal método é baseado em redes neurais 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, que eram capazes de avaliar as distâncias das amostras às classes do conjunto de treinamento. Já no terceiro método, foi usado um tipo especial de rede neural 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 (“*Adaptive 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 associada.

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 protótipo de classificação de acidentes baseado em medidas diretas de distância euclidiana. O método proposto denominado “Conjunto Mínimo de Centróides (CMC)”, utiliza o algoritmo genético para particionar o espaço de busca do problema e, têm 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 conjuntos nebulosos. O critério de pertinências possibilística permitiu uma 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 feita com base na acumulação de evidências das classificações realizadas em instantes anteriores.

Em sua tese de doutorado MOL, (2002) propôs um sistema protótipo de identificação de transientes baseado em redes neurais artificiais, com a capacidade da resposta “Não Sei” na identificação dinâmica de eventos desconhecidos, ou melhor, para eventos não pertencentes ao conjunto de aprendizado. Nesse método foram utilizadas duas redes neurais, 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 foi treinada acrescentando ruído aos dados de treinamento, onde foram consideradas 17 variáveis, sendo o 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 protótipo de diagnóstico que classifica um evento anômalo dentro das assinaturas desses transientes, postulados para a Usina Nuclear Angra2. Tal sistema calcula 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 projeto, onde o PSO foi usado como ferramenta de otimização, para encontrar a melhor posição dos centróides (Vetores de Voranoí) dos transientes de base de projeto, que maximizam o número de classificações corretas e minimizavam o número de partições do espaço de busca.

EVSUKOFF A. e GENTIL S., (2005), propuseram um modelo de sistema protótipo de detecção e isolamento de falhas baseado em redes neurais fuzzy para reatores nucleares do tipo PWR. Neste modelo um método de fuzificação foi conectado ao um módulo de rede neural adaptada para o reconhecimento da evolução dinâmica das variáveis de estado de falhas conhecidas. O processamento de dados foi então fuzificado para valorizar dados qualitativos no lugar de quantitativos, onde cada atributo fuzificado foi usado para alimentar a rede. Nesta abordagem duas topologias de rede neurais foram usadas: uma topologia do tipo *feed-foward* e uma do tipo recorrente, onde as entradas adicionais foram usadas para ativação das unidades de saída.

NICOLAU (2010) aprimorou o modelo proposto por MEDEIROS (2005), porém ao invés de usar o algoritmo de otimização PSO, utilizou o algoritmo de inspiração quântica *Quantum Inspired Evolutionary Algorithm* (QEA) como ferramenta de otimização e, além disso utilizou apenas uma partição para o espaço de busca o que torna o problema ainda mais complexo. O modelo de sistema protótipo desenvolvido por NICOLAU mostrou pela primeira vez a viabilidade e robustez da técnica de inspiração quântica QEA na área da engenharia nuclear, mas especificamente no Problema de Identificação e Diagnóstico de Acidentes em uma Usina Nuclear do tipo PWR . Tal modelo, apresentou resultados compatíveis e até superiores aos encontrados na literatura, no que concerne ao número máximo de classificações corretas e tempo de convergência.

HSIAO T., LIN C., e YUANN Y. R., (2010) desenvolveram um método de reconhecimento de padrão capaz de reconhecer um conjunto de transientes simulados para uma Usina Nuclear PWR, baseado no monitoramento de apenas três parâmetros da Usina: pressão, média de temperatura e diferença de temperatura entre a perna quente e fria do sistema refrigerante do reator. Tais parâmetros foram chamados de parâmetros chaves. Neste método as informações dos conjuntos de dados de cada evento de referência guardavam a informação da tendência e das faixas de variação de cada parâmetro durante os primeiros segundos de ocorrência de cada evento. Onde, a classificação de uma falha foi feita através do cálculo de distância de similaridade entre a tendência e as faixas de variação de cada parâmetro chave com o evento em curso. A trajetória de um ponto representando o estado atual do processo foi então projetada em uma tela de pressão-temperatura. Neste espaço faixas de variação de diferentes domínios correspondendo a diferentes situações de falha da Usina foram representadas. As vantagens de tal representação encontra-se dentro de sua habilidade de mostrar o ponto atual relativo ao estado normal de operação da Usina e a partir dele indicar a ocorrência de uma situação anormal. Desta forma, um evento anormal pode ser monitorado a partir da inflexão da trajetória do ponto.

VILAS BÔAS (2011) em sua dissertação de mestrado aprimorou o método de sistema protótipo desenvolvido por MEDEIROS (2005). Porém ao invés de utilizar a métrica euclidiana como medida de similaridade entre o conjunto de variáveis do evento anômalo, em um determinado instante t , e o vetor protótipo das variáveis dos acidentes/transientes de base de projeto, utilizou pela primeira vez a métrica de Minkowski. Além disso, o cálculo do acerto foi feito comparando o grau de similaridade entre os transientes/acidentes em todos os tempos simultaneamente e não tempo a tempo, como realizado por MEDEIROS (2005).

LIN C. e CHANG H., (2011) propuseram um modelo de sistema protótipo de identificação de transientes de uma central nuclear do tipo PWR, baseado na programação dinâmica. Neste modelo um conjunto de transientes de referência foi transformado em um vetor de sequências características, cujos elementos são valores discretos. Uma função custo foi definida como medida de distância entre o conjunto de transiente de teste e os transientes de referência, armazenados no vetor de sequência característica. A programação dinâmica foi aplicada para obter o mínimo da função de

custo, para o qual um valor limite foi definido para que os transientes de teste pudessem ser identificados como um transiente do conjunto de referência.

Y.G. No, et. al., (2012) propuseram um método de identificação para acidentes severos para usinas do tipo PWR, que usa quatro tipo de técnica de IA: SVC (Support Vector Classification), PNN (Probabilistic Neural Network), GMDH (Group Method of Data Handling) e FNN (fuzzy neural network). Tal método foi desenvolvido para identificar três tipos de eventos inicializadores: perna quente do LOCA, perna fria do LOCA e SGTR. Onde, as técnicas SVC e o PNN foram usadas para a classificação do evento e, as técnicas GMDH e FNN foram utilizadas para prever com precisão o momento de início de cada acidente severo. O método foi testado utilizando dados do código MAAP4 do APR1400 (Advanced Power Reactor 1400), desenvolvido pelo Korea Hydro & Nuclear Power Company (KHNP). Os resultados mostram que a acurácia na predição dos três tipos de acidentes são suficientes para prever acidentes severos.

Em BAKHSHAYESH, K., M., e GHOFRANI, M., B., (2013) é feito uma revisão dos diferentes tipos de sistemas protótipos de identificação de acidentes da literatura. Neste trabalho encontra-se uma coletânea de modelos de sistema de Identificação, com a aplicação de diferentes técnicas de IA, tais como: Neural Network, Sistemas Fuzzy, Algoritmos Genéticos, Algoritmos de Inspiração Quântica, Enxame de Partículas, Modelos de Markov, entre outros. Tal trabalho apresenta de forma clara as principais diferenças entre os métodos destacados.

CHANG, H., et. al., (2013), propuseram um novo método para a Identificação de acidentes em NPPs, chamado de Representação Linear de transiente e Solução Dispersa. Tal método modela diretamente os transientes em um espaço linear que é representado por uma matriz, ao invés de processos de treinamento. Assim, um transiente pode ser representado pela combinação linear de colunas dessa matriz, onde a codificação do vetor de coeficiente identifica o transiente. Para obter o vetor de coeficiente, adotou-se o algoritmo SLO (Smoothed l^0 -norm Optimization), onde o método TSVD (Truncated Singular Value Decomposition) é combinado para melhorar a estabilidade. O método proposto foi testado via HTR-PM (Pebble-bed Modular High Temperature gás-cooled) desenvolvido pelo Instituto Nuclear e Novas Tecnologias de Energia com a

Universidade Tsinghua e foi aplicado a 17 tipos de transientes. Os resultados da aplicação mostraram que o método proposto foi capaz de identificar os tipos de transientes e distinguir os de tipo desconhecido.

6.3 Principais Transiente operacionais e Acidentes de base de projeto, postulados para a Usina Nuclear Angra 2.

A Usina Nuclear de Angra 2 possui um reator do tipo PWR de 4 circuitos térmicos independentes e está localizado na praia de Itaorna em Angra dos Reis, Rio de Janeiro, Brasil. Foi inaugurada em 2000 e está sendo atualmente operada pela Eletronuclear contribuindo para o sistema elétrico brasileiro com 1350.

Projetada pela Siemens, o núcleo de Angra 2 é composto por 193 elementos combustíveis, com um total de 45000 varetas combustíveis. O núcleo do reator é dividido em dois eixos principais de simetria, dividindo o mesmo em quatro regiões chamadas de simetria de $\frac{1}{4}$ e com dois eixos diagonais secundários, dividindo o núcleo em oito regiões chamadas de simetria de $\frac{1}{8}$. Cada um desses eixos de simetrias são compostos por 10 elementos combustíveis, onde os elementos pertencentes às regiões de simetria de $\frac{1}{4}$ são chamados de quartetos e os pertencentes às regiões de simetria de $\frac{1}{8}$ são chamados de octetos. A figura 23 mostra o modelo do núcleo do reator e suas simetrias, visto de cima.




Figura 23. Representação do modelo do núcleo do reator de Angra 2

Como parte do processo de licenciamento de uma Usina Nuclear é exigido a elaboração de um documento normativo que avalie 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 desses objetivos são classificados em três categorias de eventos em função da frequência de ocorrência. Essas categorias de evento são classificadas em: transientes operacionais; acidentes de base de projeto e transientes antecipados com falha no desligamento rápido do reator.

No caso específico da Usina Nuclear de Angra 2, este documento normativo é denominado Relatório Final de Análise de Segurança - FSAR (FSAR, 2007). No capítulo 15, deste documento existem descrições de uma série de transientes operacionais, acidentes de base de projeto e transientes antecipados com falha no desligamento rápido do reator. Esses transientes/acidentes podem ocorrer, tanto no sistema de arrefecimento 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. A figura 24 mostra a representação de um ciclo da Usina Nuclear de Angra 2.

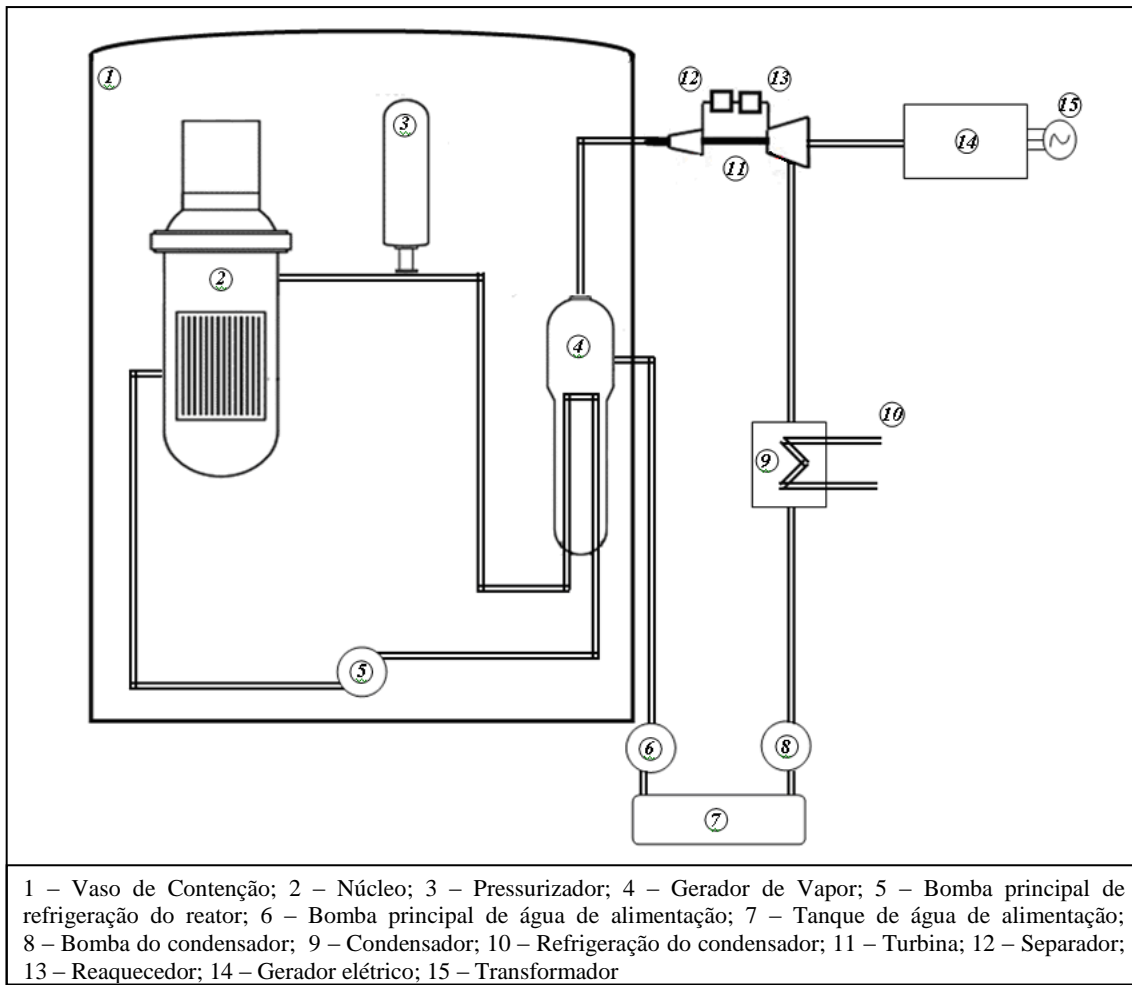


Figura 24. Representação de um ciclo da Usina Nuclear de Angra 2

No caso de ocorrência 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;
- e evitar a liberação de radioatividade para o meio ambiente fora dos limites permitidos para a operação normal.

De acordo com MOL (2002) 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;
- e evitar a liberação de radioatividade para o meio ambiente fora dos limites permitidos para a condição de acidente.

De acordo com MOL (2002), 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, uma elevação da temperatura e da pressão no circuito primário, em consequência, ocorre a 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 em 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 (MOL, 2002). 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.

Capítulo 7

Modelo de Sistema de Identificação e Diagnóstico de Acidentes proposto

Neste capítulo serão apresentadas as principais características do Sistema de Identificação e Diagnóstico de Acidentes (SIDA) proposto nesta tese, bem a metodologia desenvolvida para a resposta “Não sei”, todos os testes realizados e os resultados obtidos.

7.1 O Modelo proposto

Baseado no modelo de SIDA desenvolvido em trabalho anterior (Nicolau, A. S., 2010), o modelo proposto nesta tese tem como objetivo identificar dentre um conjunto de condições de operação postulados para a Usina Nuclear Angra 2, qual melhor caracteriza o evento em curso e além disso, fornecer a resposta ‘Não Sei’ para eventos desconhecidos.

Assim como em Nicolau, A. S., 2010, o Sistema ora proposto utiliza a ferramenta de inspiração quântica QEA como ferramenta de otimização responsável por encontrar os vetores protótipos (vetores representantes de cada condição de operação de referência) e a melhor posição destes, de modo que, essas posições maximizam o número de classificações corretas. Onde, a classificação do evento anômalo, como pertencente a uma das condições de operação de referência, será feita considerando a menor distância entre os vetores protótipos gerados pelo QEA e, a assinatura das variáveis de estado do evento em curso. Por outro lado, a resposta “Não Sei” será dada quando o evento em curso não for reconhecido como nenhuma das condições de referência e estiver fora de uma certa “região de influência” definida.

Sendo assim, para desenvolver o modelo de SIDA proposto, várias mudanças e testes no modelo original, desenvolvido no mestrado, foram necessários. Nas seções a

seguir serão apresentados o modelo original de SIDA desenvolvido em trabalhos anteriores (Nicolau A.S., 2010), todas as mudanças e testes realizados até se alcançar o modelo proposto.

7.2 *O modelo original*

O modelo de SIDA desenvolvido em Nicolau A.S., 2010, aqui chamado de SIDA1, foi capaz de classificar um evento anômalo, em relação a assinatura de um conjunto de três condições de acidentes de base de projeto, postulados para a Usina Nuclear Angra2, (*Loss of Coolant on the primary loop - LOCA*, *Steam Generator's Tubes Rupture- SGTR*, *External power blackout – BLACKOUT*), qual melhor representa o evento em curso. O SIDA1 compara a distância euclidiana entre o conjunto de variáveis do evento anômalo, em um dado instante t , e os vetores protótipos de cada condição de operação de referência. A menor distância irá indicar a condição de acidente que evento anômalo pertence. Desta forma, o SIDA1 pode ser visto como um sistema de reconhecimento de padrões, onde sua principal finalidade é a de identificar similaridades entre eventos (amostras) de mesmas condições de operação (classes).

A ferramenta de inspiração quântica QEA foi utilizada como ferramenta de otimização responsável por encontrar a melhor posição dos vetores protótipos de cada classe, de modo que essas posições maximizam o número de classificações corretas. Cada vetor protótipo, gerado pelo QEA, pode ser visto como um vetor gerador de Voronoi (Haykin, S., 1994), pois é aquele que melhor representa a classe considerada e sua posição no espaço é tal que, qualquer amostra pertencente a uma determinada classe, estará sempre mais próxima de seu vetor gerador, do que de qualquer outro vetor gerador do espaço. Assim, quanto menor a distância entre a amostra e o seu vetor representante, maior é o grau de similaridade entre ambos. A figura 25 ilustra o processo de identificação realizado pelo SIDA original.




Figura 25. Exemplo do processo de classificação realizado pelo SIDA1.

Os acidentes de base de projeto usados como referência no SIDA1 constam no capítulo 15 do Relatório Final de Análise de Acidentes (FSAR) e foram representados pela evolução temporal do conjunto de variáveis de estado mais a variável tempo, apresentadas na tabela 9.

Tabela 9. Variáveis de estado

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)

A simulação da variação temporal de cada variável de estado da tabela 9 foi programada em linguagem MATLAB-4.0, por ALVARENGA (1997) e, o tempo total da amostragem foi de 61 segundos, onde o primeiro segundo corresponde à condição normal de potência e o segundo seguinte o TRIP do reator. O tempo de 61 segundos foi usado, pois considerou-se que o mesmo era suficiente para que os acidentes pudessem ser destacados uns dos outros, devido à evolução particular de uma ou mais variáveis de estado, consideradas como aquelas que mais contribuem para a caracterização dos acidentes/transientes em questão.

• *Modelagem do QEA*

No modelo de QEA implementado no SIDA1 o indivíduo quântico da população $Q(t)$ do QEA foi inicializado em $t = 0$, com $Q(0) = \{q_1(0), q_2(0), \dots, q_n(0)\}$, de tal forma que, $\alpha_{ij}(0) = \beta_{ij}(0) = \frac{\sqrt{2}}{2} \quad \forall \quad i = 1, 2, \dots, n \quad \text{e} \quad j = 1, 2, \dots, m$, o que garante $|\alpha_{ij}|^2 = |\beta_{ij}|^2 = \frac{1}{2}$. Além disso, o valor do parâmetro ε das funções (19) e (20) do capítulo 3, foi fixado em 0.01 e o valor do parâmetro Δ em $0.005 * \pi$.

Cada solução candidata $X_i(t)$ da população clássica $P(t)$, gerado no passo de observação do indivíduo quântico $q_i(t)$, é um cromossomo binário com 648 bits, dividido em 54 segmentos de 12 bits que representa os vetores protótipos de cada acidente de referência. Tal cromossomo foi convertido em sequências de números reais pelo Código Gray (Gray, F., 1953) e, em seguida avaliado pela função objetivo. A figura 26 mostra o processo de conversão realizado pelo Código Gray e a representação final do indivíduo $X_i(t)$.

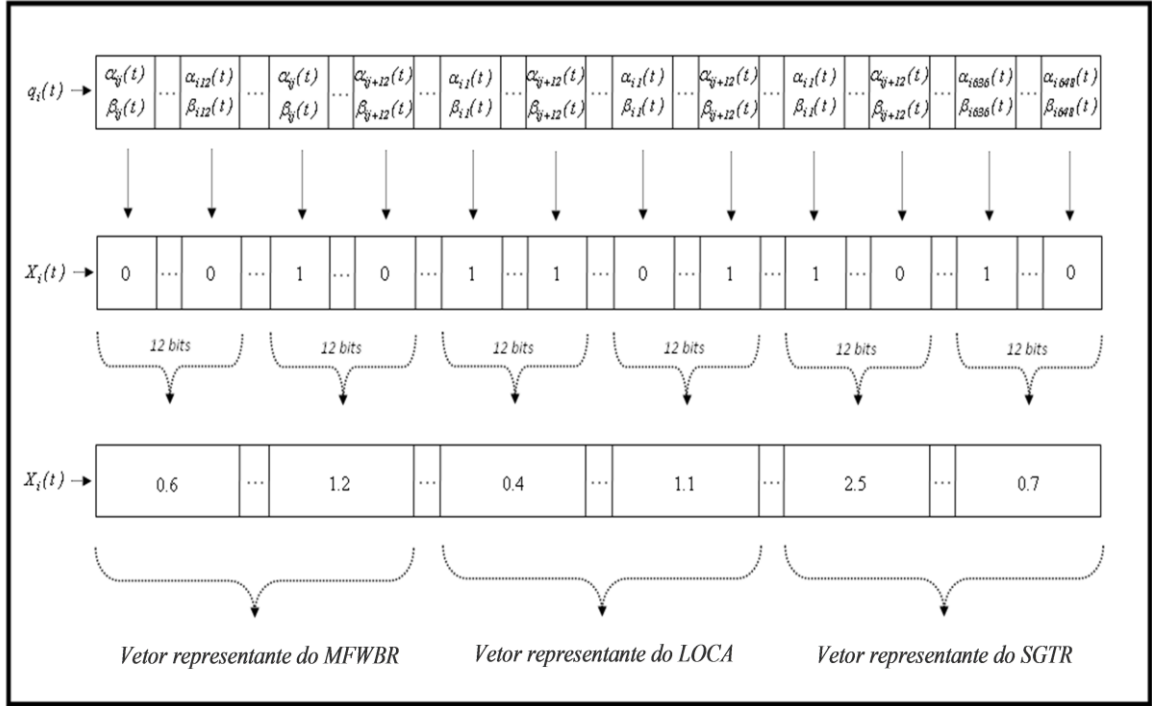


Figura 26. Processo de conversão realizado pelo Código Gray.

A função objetivo usada no SIDA1 teve como propósito ponderar favoravelmente o número de classificações corretas e, os dados de cada condição de referência foram normalizados utilizando o método MAX-MIN Equalizado (THOME, 2008). Este método faz uso dos valores máximos e mínimos das variáveis da tabela 9, com o intuito de normalizar linearmente os dados entre [0,1], de acordo com a equação abaixo:

$$N(x) = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (24)$$

onde, $N(x)$ é o valor normalizado da variável x , $\min(x)$ é o menor dos valores da variável x e, $\max(x)$ é o maior valor para a variável x .

7.2.1 Independência da variável tempo e Influência do parâmetro ε

Como propósito de verificar a influência da variável tempo (12º variável de estado da tabela 9) e, a influência do valor usado para o parâmetro ε , do portão quântico H_ε , no comportamento do SIDA1, foram utilizados diferentes valores para a variável

tempo e diferentes valores para o parâmetro ε foram utilizados. Além disso, utilizou-se 59 pontos (pontos de particionamento referentes ao eixo do tempo), ao invés de 61 pontos como no SIDA1. Pois, ao analisar as tabelas de evolução temporal das 18 variáveis da tabela 9, observou-se que as duas primeiras linhas (referentes aos dois primeiros segundos) de cada condição de acidente eram exatamente iguais. Desta forma, o número máximo de classificações corretas dadas pelo sistema será de igual a 177 ($59(\text{pontos}) * 3(\text{condições de operação}) = 177$).

- ***Testes com diferentes valores para o parâmetro ε***

A tabela 10 mostra os resultados dos testes realizados, onde são destacados os valores usados para o parâmetro ε , o número de avaliações em que resultado foi encontrado e o número de classificações corretas obtidos pelo SIDA1.

Tabela 10. Testes com diferentes valores para o parâmetro ε

<i>Valores de ε</i>	<i>Avaliações</i>	<i>Classificações corretas</i>
0.000	$1.9*10^4$	177
0.005	$1.9*10^4$	177
0.010	$1.2*10^4$	177
0.050	$1.9*10^4$	177
0.100	$5.5*10^4$	177
0.200	$6.2*10^4$	177

Observa-se na tabela 10 que o SIDA1 foi capaz de alcançar o resultado esperado (177 classificações corretas) com todos os valores usados para o parâmetro ε , porém observa-se que com o uso do parâmetro ε igual a 0.01 o SIDA1 foi capaz de encontrar o resultado esperado com menor esforço computacional ($1.2*10^4$ avaliações). Desta forma, pode-se dizer que o melhor valor a ser usado para o parâmetro ε é 0.01, uma vez que o número de avaliações é um fator crucial no processo de otimização deste tipo de problema.

- ***Testes com diferentes valores para a variável tempo***

Com o objetivo de avaliar o comportamento do SIDA1, com diferentes valores fixados para a variável tempo (variável 12 da tabela 9), utilizou-se uma população de 100 indivíduos e, os valores dos parâmetros Δ e ε fixados em $0.005*\pi$ e 0.01, respectivamente. A tabela 11 mostra os resultados dos testes realizados, onde são destacados os valores selecionados para a variável tempo, o número de avaliações em que o resultado foi encontrado e o número de classificações corretas obtido pelo sistema em cada caso considerado.

Tabela 11. Testes com diferentes valores para a variável tempo

<i>Valores de tempo</i>	<i>Convergência Gerações</i>	<i>Classificações corretas</i>
5	$2.0*10^3$	177
10	$2.0*10^3$	177
20	$2.0*10^3$	177
40	$2.0*10^3$	177
60	$2.0*10^3$	177

Pode-se observar na tabela 11 que o SIDA1 foi capaz de encontrar o resultado esperado independente do valor usado para a variável tempo. Além disso, ao fixarmos um valor para a variável tempo o QEA convergiu mais rapidamente para o resultado esperado, do que se deixarmos o valor da variável tempo livre, como nos resultados mostrados na tabela 6.

Os resultados da tabela 11 levantaram evidências de que o SIDA1 trabalha de forma eficaz sem a variável tempo (variável 12 da tabela 9). Desta forma, com o objetivo de verificar o comportamento do mesmo sem a variável tempo, 10 testes foram realizados com diferentes sementes, com uma população de 100 indivíduos, e com os parâmetros Δ e ε fixos em $0.005*\pi$ e 0.01, respectivamente.

Com a eliminação da variável tempo, o SIDA1 passa a utilizar 17 variáveis de estado mostradas na tabela 9 e, conseqüentemente cada indivíduo do QEA passa a ser

representado por um cromossomo de 612 bits ((17 variáveis* 3 acidentes)*12bits). A tabela 12 mostra os resultados dos testes realizados.

Tabela 12. Resultados do QEA

<i>Semente</i>	<i>Avaliações</i>	<i>Classificações corretas</i>
7777	$9.6*10^3$	177
1111	$7.6*10^3$	177
4945	$2.2*10^3$	177
2893	$1.5*10^3$	177
5455	$7.5*10^3$	177
7878	$4.5*10^3$	177
7845	$2.9*10^3$	177
7898	$3.5*10^3$	177
4444	$2.1*10^3$	177
1234	$2.6*10^3$	177

Os resultados da tabela 12, além de confirmar que o SIDA1 é capaz de encontrar o resultado esperado (177) sem o uso da variável tempo, mostram que com a eliminação da variável tempo o algoritmo realiza o processo de otimização mais rapidamente, ou seja, encontra o resultado esperado com menor número de avaliações.

- ***Classificação em tempo real***

Como mencionado anteriormente, cada vetor solução gerado pelo QEA é formado pelos vetores protótipos representantes de cada classe (condição de acidente). Com o objetivo de verificar a robustez dos vetores solução gerados pelo QEA mostrados na tabela 12 e, simular um sistema de identificação de acidentes em tempo real, ou seja, a cada instante de tempo classificar um evento anômalo como sendo uma das três condições de acidentes de referência. Foi desenvolvido um programa em MATLAB 6.5, aqui chamado de Prog_diagnóstico, no qual o melhor vetor solução gerado pelo QEA (tabela 12 – 4º linha) foi dividido em 3 vetores protótipos e, usados como vetores representantes das classes de referência para a classificação instantânea das amostras do

evento a ser classificado. Além disso, foram acrescentados na assinatura original de cada condição de referência ruídos gaussianos de 1% e 2% ($\sigma = 1\%, 2\%$).

A classificação do evento anômalo como pertencente a uma das classes de referência foi feita através do cálculo de distância de euclidiana, entre a nova assinatura (assinatura original + ruído) de cada classe e o seu respectivo vetor protótipo gerado pelo QEA. Espera-se que ao final de execução do programa o mesmo encontre 59 classificações corretas para cada classe considerada. A tabela 13 mostra os resultados obtidos, destacando o número de classificações corretas para cada classe de referência.

Tabela 13. Classificação em tempo real

Classe	Ruído(%)	Classificações corretas
BLAKOUT	0	100%
LOCA	0	100%
SGTR	0	100%
BLAKOUT	1	100%
LOCA	1	100%
SGTR	1	100%
BLAKOUT	2	100%
LOCA	2	100%
SGTR	2	93%

Observando os resultados da tabela 13, pode-se concluir que o QEA sem a variável tempo foi capaz de identificar as condições de operação de referência mesmo com a aplicação de ruído gaussianos de 1% e 2%, encontrando dessa forma, uma solução que se aproxima da solução ideal (Vetores de Voronoi) para a classificação dos acidentes de referência. Além disso, mostrou-se pouco sensível a ruídos dentro da faixa de teste, que equivale basicamente ao erro de instrumentação da Usina, permitindo uma eficaz classificação em tempo real.

7.2.2 Nova definição para os parâmetros ε e Δ do QEA

Os testes realizados nesta fase do trabalho, tiveram como objetivo verificar o comportamento do SIDA1, sem a variável tempo, quando os parâmetros ε e Δ do QEA são usados como funções linearmente decrescentes no tempo, diferente do modelo original do QEA, onde tais parâmetros são fixos (Han, K., Kim, J., 2000)

Desta forma, foram selecionados diferentes intervalos de valores para cada um dos parâmetros considerados, onde a influência de cada parâmetro no comportamento do SIDA1 foi analisado separadamente.

- **Análise do parâmetro Δ**

O parâmetro Δ do QEA, como mencionado no capítulo 3 deste trabalho, é fundamental para o desempenho do algoritmo, pois o mesmo é o responsável pelo equilíbrio entre a busca global e local da população quântica. Desta forma é o responsável pelo aprendizado da população quântica e, pela velocidade de convergência do QEA. Assim, com o objetivo de melhorar a habilidade de busca da população quântica do QEA no início e no final do processo de otimização e, diminuir o tempo de convergência do algoritmo, o parâmetro Δ foi usado como uma função linearmente decrescente no tempo.

A tabela 14 mostra os resultados de testes realizados sem a variável tempo, com diferentes valores para o parâmetro Δ e, o valor do parâmetro ε igual a 0.01. Por outro lado, a tabela 15 mostra os resultados dos testes realizados com o QEA sem a variável tempo, com o uso do parâmetro Δ como uma função decrescente linearmente no tempo. Os testes foram realizados em 10 experimentos com diferentes sementes.

Tabela 14. Resultados com o SIDA1 com Δ e ε fixos

Δ	ε	Média de convergência	Classificações corretas
$0.0005*\pi$	0.01	1269	177
$0.005*\pi$	0.01	183	177
$0.1*\pi$	0.01	82	177

Tabela 15. Resultados obtidos com o SIDA1 com Δ linearmente decrescente no tempo e o ε fixo

Δ	ε	Média de avaliações	Classificações corretas
$0.1*\pi \rightarrow 0.0005*\pi$	0.01	$1.0*10^4$	177
$0.1*\pi \rightarrow 0.03*\pi$	0.01	$1.0*10^4$	177
$0.1*\pi \rightarrow 0.05*\pi$	0.01	$1.3*10^4$	177

Comparando-se os resultados mostrados nas tabelas 14 e 15, observa-se que em ambos os casos o QEA foi capaz de encontrar o resultado esperado (177). Além disso, apresentou maior robustez nos resultados obtidos, mesmo considerando diferentes intervalos para o parâmetro Δ .

- **Análise do parâmetro ε**

Como mencionado no capítulo 3, o parâmetro ε do portão quântico H_ε do QEA tem o papel de diminuir a convergência prematura e, reduzir a probabilidade de estagnação do algoritmo em ótimos locais.

A tabela 16 mostra os resultados dos testes realizados com o QEA sem a variável tempo, no qual foram usados diferentes valores para o parâmetro ε e o valor do parâmetro Δ fixo em $0.005*\pi$. Por outro lado, a tabela 17 mostra os resultados dos testes realizados sem a variável tempo, com o uso do parâmetro ε como uma função decrescente linearmente no tempo, e o valor do parâmetro Δ fixo em $0.005*\pi$. Cada um dos testes foram realizados em 10 experimentos com diferentes sementes com uma população de 100 indivíduos.

Tabela 16. Resultados obtidos com SIDA1 com Δ e ε fixos

ε	Δ	Média de avaliações	Classificações corretas
0.005	$0.005*\pi$	$3.9*10^4$	177
0.05	$0.005*\pi$	$1.1*10^5$	177
0.1	$0.005*\pi$	$1.1*10^5$	177

Tabela 17. Resultados obtidos com o ε linearmente decrescente no tempo e Δ fixo

ε	Δ	Média de avaliações	Classificações corretas
0.08→0.05	0.005* π	4.0*10 ⁴	177
0.1 → 0.02	0.005* π	4.1*10 ⁴	177
1.0 → 0.03	0.005* π	7.0*10 ⁴	177

Comparando-se os resultados das tabelas 16 e 17, observa-se que em ambos os casos o QEA foi capaz de encontrar o resultado esperado (177), porém ao utilizar o parâmetro ε como uma função linearmente decrescente no tempo, apresentou maior velocidade de convergência em todos os casos considerados. Por outro lado, se compararmos os resultados da tabela 17 com os resultados da tabela 15, observamos que computacionalmente é mais vantajoso usar o parâmetro ε fixo e usarmos o parâmetros Δ como uma função linearmente decrescente no tempo, pois o SIDA1 obteve o resultado esperado com menor esforço computacional.

7.2.3 Mudanças nas condições de operação usadas como referência

Nesta fase do trabalho foi acrescentada a condição de operação normal da Usina de Angra 2 no modelo de SIDA1 e foi feita a substituição do acidente BLACKOUT pelo acidente MFWBR – Main Feed Water Rupture.

Tais mudanças tiveram por objetivo obter um modelo de SIDA, aqui chamado de SIDA2, que não necessitasse de um evento iniciador que indicasse a ocorrência de uma condição anormal, SCRAM do reator, por exemplo e além disso, utilizar como referência as mesmas condições de operação usadas no Sistema Integrado de Computadores de Angra 1 – SICA (SCHIRRU e PEREIRA, 2004) desenvolvido pelo Laboratório de Monitoração de Processos (LMP) da COPPE, o qual é o responsável pela monitoração em tempo real dos parâmetros essenciais para a determinação do estado de segurança da usina em caso de uma situação de emergência, bem como para o acompanhamento do funcionamento da mesma durante sua operação normal.

O SICA é responsável, também pelos procedimentos operacionais requeridos para o retorno da usina à condição de operação normal, quando da ocorrência de transientes que possam afetar a sua segurança. Desta forma, a importância de se classificar corretamente tais condições de operação (LOCA, SGTR e MFWBR), reside no fato de que os mesmos definem os gráficos de limitação de segurança, que são usados pelo SICA no caso de ocorrência dos mesmos.

A ferramenta de otimização de inspiração quântica QEA foi usada, assim como no SIDA1 para encontrar a os vetores protótipos e a melhor posição destes no espaço de busca, de modo que tais posições maximizam o número de classificações corretas.

A classificação do evento anômalo no SIDA2, assim como no SIDA anterior, é feita considerando a menor distância euclidiana entre os vetores protótipos gerados pelo QEA, e a assinatura das variáveis de estado do evento em curso, ou seja, da evolução temporal das variáveis de estado do evento anômalo. A figura 25 ilustra o processo de classificação realizado pelo SIDA2.




Figura 27. Exemplo do processo de classificação realizado pelo SIDA 2.

Como mostrado na figura 27, as condições de operação usadas como referência no SIDA2 foram:

- Perda de refrigerante do sistema primário (LOCA) – 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 pZR 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 o 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 e, os acumuladores não descarregam. Onde, 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, enquanto 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 será então interrompida pelo isolamento da ventilação do prédio de contenção.

- Rupturas de tubos do gerador de vapor (SGTR) – 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 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.

- Ruptura da linha de alimentação principal c/SCRAM (MFWBR) -

Uma ruptura da linha de alimentação principal pode interromper o suprimento de água para os geradores de vapor. No início do acidente há um aumento da remoção de calor seguida de uma diminuição do mesmo. O nível de água e pressão em todos os geradores de vapor diminui. O rápido decréscimo da pressão na linha de vapor faz com que o limite do sistema de proteção seja alcançado, causando o desligamento rápido do reator. O mesmo sinal que causa este desligamento do reator, também faz com que as válvulas que isolam as linhas de vapor sejam fechadas e as bombas das linhas de alimentação sejam desligadas. A remoção do calor de decaimento é assegurada pelas bombas das linhas de alimentação sejam desligadas. E por sua vez, a remoção do calor de decaimento assegura que as bombas de alimentação de emergência;

- Condição de operação normal da Usina (NORMAL);

• Modelagem do QEA e a Função Objetivo

O modelo de QEA implementado no SIDA2 foi o mesmo implementado no SIDA1, porém cada solução candidata $X_i(t)$ da população clássica $P(t)$ do QEA, gerada no passo de observação do indivíduo quântico $q_i(t)$, é um cromossomo binário

com 816 bits ((4condições de operação*17)*12 bits). E assim como no SIDA1, cada cromossomo foi convertido em sequências de números reais pelo Código Gray.

A função objetivo usada no SIDA2 teve como propósito ponderar favoravelmente o número de classificações corretas e além disso, fazer com que os vetores representantes gerados pelo QEA, fossem posicionados o mais distante possível um dos outros, na tentativa de garantir uma maior margem de segurança na classificação de um evento anômalo. Esse tipo de abordagem faz com que o modelo SIDA2 seja inovador frente aos modelos de SIDA encontrados na literatura e até mesmo frente ao SIDA1. Os testes foram realizados em 10 experimentos com 10 sementes diferentes, com uma população de 100 indivíduos e critério de parada 1.000 gerações, num total de $1.0 \cdot 10^5$ avaliações. Os valores dos parâmetros λ e ε foram fixados em $0.005 \cdot \pi$ e 0.01, respectivamente. Cada indivíduo quântico da população $Q(t)$ do QEA, assim como no SIDA1 foi inicializado em $t=0$, com $Q(0) = \{q_1(0), q_2(0), \dots, q_n(0)\}$, de tal forma que

$$\alpha_{ij}(0) = \beta_{ij}(0) = \frac{\sqrt{2}}{2} \quad \forall \quad i = 1, 2, \dots, n \quad \text{e} \quad j = 1, 2, \dots, m, \quad \text{o que garante} \quad |\alpha_{ij}|^2 = |\beta_{ij}|^2 = \frac{1}{2}.$$

• ***Testes e Resultados Experimentais***

Os testes realizados nesta fase do trabalho, com o SIDA2, tiveram como objetivo investigar o comportamento do QEA com diferentes conjuntos de variáveis de estado da tabela 9 e, além disso, verificar a robustez dos vetores protótipos gerados quando frente a ruídos gaussianos de 1% e 2%. A tabela 18 mostra os melhores vetores protótipos encontrados pelo QEA formados pelos diferentes conjuntos de variáveis da tabela 9, ou seja a tabela 18 mostra os vetores protótipos que alcançaram o número máximo de classificações corretas (236), em um menor número de avaliações.

Tabela 18. Melhores vetores representantes gerados pelo QEA

Conjunto de variáveis selecionadas	Condição de operação	Vetores protótipos	Geração
1,2,3,4,5,6,7,8,9,10,11,13,14,15,16,17,18	MFWBR	[0.3223 0.7145 0.2630 0.5553 0.5543 0.9228 0.1407 0.2784 0.8740 0.2303 0.4869 0.7827 0.3651 0.0120 0.7436 0.0557 0.1175]	331
	LOCA	[0.9934 0.8955 0.9941 0.1971 0.1690 0.6249 0.4222 0.6474 0.1580 0.9370 0.0024 0.7023 0.5570 0.4017 0.0537 0.0608 0.5817]	
	SGRT	[0.3131 0.2716 0.1050 0.9348 0.0564 0.5221 0.9651 0.3907 0.4051 0.4237 0.0186 0.0950 0.9429 0.9138 0.4823 0.6994 0.8752]	
	NORMAL	[0.9643 0.2039 0.0476 0.7136 0.9531 0.4781 0.2063 0.9939 0.3582 0.0039 0.0745 0.8518 0.1446 0.6476 0.7197 0.8718 0.0078]	
4,7,10, 16	MFWBR	[0.0078 0.0149 0.0017 0.6249]	164
	LOCA	[0.0005 0.7358 0.9961 0.0046]	
	SGRT	[0.9980 0.9971 0.9375 0.0042]	
	NORMAL	[0.9988 0.0012 0.0205 0.9861]	
4,7,10,13 16,18	MFWBR	[0.1206 0.6635 0.1126 0.7118 0.9055 0.1741]	184
	LOCA	[0.3226 0.4955 0.9839 0.5968 0.9924 0.7145]	
	SGRT	[0.8950 0.9856 0.9573 0.8847 0.3099 0.7228]	
	NORMAL	[0.9841 0.7453 0.0361 0.0408 0.8129 0.6017]	
2,4,5,7, 10,13,16	MFWBR	[0.6110 0.1533 0.5443 0.9485 0.1450 0.6801 0.4044]	123
	LOCA	[0.9257 0.3145 0.7892 0.6945 0.7526 0.1428 0.2422]	
	SGRT	[0.6491 0.9223 0.3289 0.0122 0.6259 0.2420 0.2980]	
	NORMAL	[0.9026 0.5091 0.9612 0.6210 0.1689 0.1653 0.9979]	
1,2,4,5,7, 8,10,13,16,18	MFWBR	[0.8027 0.7658 0.6042 0.1685 0.3289 0.0784 0.3179 0.5582 0.6173 0.7998]	161
	LOCA	[0.9177 0.3878 0.4278 0.9468 0.0435 0.2171 0.9690 0.0374 0.0845 0.6022]	
	SGTR	[0.9712 0.9856 0.3810 0.9368 0.6222 0.2696 0.8054 0.0418 0.0855 0.8178]	
	NORMAL	[0.7309 0.2342 0.8442 0.8938 0.7280 0.4794 0.1253 0.1673 0.3570 0.6046]	

Na tabela 18 podemos observar que o QEA foi capaz de encontrar vetores protótipos para cada uma das 4 condições de operação de referência, utilizando diferentes conjuntos de variáveis e, um fato que se destaca é que o QEA com um conjunto de apenas 4 variáveis de estado foi capaz de alcançar o resultado esperado com $1.6 \cdot 10^4$ avaliações. Desta forma, podemos dizer que não existe somente um único conjunto de variáveis de estado com o qual o SIDA2 é capaz de identificar os acidentes de referência e, sim que existem múltiplos conjuntos, não necessariamente mínimo, necessário e suficiente para que o QEA determine o número máximo de classificações corretas.

- ***Classificação em tempo real***

Como na fase Teste 1 (seção 7.2.1), nessa fase do trabalho foi utilizado o programa Prog_diagnóstico, para analisar a robustez do vetor solução gerado pelo QEA na seção anterior (tabela 21). Espera-se que ao final de execução do programa, o mesmo encontre 59 classificações corretas para cada acidente considerado.

A tabela 19 apresenta os resultados obtidos com os testes realizados com o SIDA2, destacando o número de classificações corretas e o valor do ruído implementado.

Tabela 19. Classificação em tempo real

Conjunto de variáveis	Condição de operação	Ruído (%)	Classificações corretas (%)	Ruído (%)	Classificações corretas (%)
4,7,10,16	MFWBR	1	100	2	100
	LOCA	1	100	2	100
	SGTR	1	100	2	100
	NORMAL	1	100	2	83,5
4,7,10,13 16,18	MFWBR	1	100	2	100
	LOCA	1	96,6	2	88,1
	SGTR	1	100	2	100
	NORMAL	1	67,8	2	50,8
2,4,5,7 10,13,16	MFWBR	1	100	2	100
	LOCA	1	98,3	2	93,2
	SGTR	1	86,4	2	83,0
	NORMAL	1	94,9	2	89,8
1,2,4,5,7 8, 10,13,16,18	MFWBR	1	100	2	100
	LOCA	1	94,9	2	93,2
	SGTR	1	98,3	2	96,6
	NORMAL	1	100	2	100
1,2,3,4,5 6,7,8, 9,10,11 13,14,15,16,17,18	MFWBR	1	100	2	100
	LOCA	1	100	2	96,6
	SGTR	1	100	2	96,6
	NORMAL	1	100	2	100

Pela análise da tabela 19, observa-se que os vetores protótipos encontrados pelo QEA, que menos foram sensíveis aos ruídos implementados, foram aqueles formados por conjuntos de 4 e 17 variáveis de estado. No entanto, o vetor solução formado pelo conjunto de apenas 4 variáveis foi mais robusto que todos os outros vetores encontrados, ou seja, aquele menos sensível aos ruídos implementados.

7.2.4 Métrica de Minkowski Generalizada

Os testes realizados nesta fase do trabalho, tiveram como objetivo avaliar o comportamento do SIDA2 com diferentes métricas de distância. Para isso, foi utilizada

a métrica de Minkowski generalizada [Jain, A. E Dubes, R., 1998] no cálculo de medida de similaridade/dissimilaridade entre os vetores representantes gerados pelo QEA e, a assinatura das variáveis de estado do evento em curso.

A métrica de Minkowski generalizada é muito utilizada no cálculo de similaridade ou dissimilaridade entre coordenadas de dois pontos no espaço. Considerando dois vetores reais $X = (x_1, x_2, \dots, x_n)$ e $Y = (y_1, y_2, \dots, y_n) \in R^n$, onde a soma desses vetores é dada por (25):

$$(x_1, x_2, \dots, x_n) + (y_1, y_2, \dots, y_n) = (x_1 + y_1, x_2 + y_2, \dots, x_n + y_n) \quad (25)$$

Tem-se que a distância de Minkowski generalizada entre os vetores X e Y é dada por (26):

$$d_{X \rightarrow Y} = \left(\sum_{i=1}^n |x_i - y_i|^p \right)^{1/p} \quad (26)$$

onde, p é um número real definido por $p \geq 1$. Sendo assim, $d_{X \rightarrow Y}$ fornece uma métrica concisa de distância que generaliza a maioria das métricas de distância da literatura. Ou seja, se o parâmetro p for fixado em $p=2$ em (26), tem-se que a função $d_{X \rightarrow Y}$ irá representar a métrica euclidiana, por outro lado, se o parâmetro p for fixado em $p=1$ em (26), tem-se que a função $d_{X \rightarrow Y}$ irá representar a métrica de Manhattan. Ainda nesta linha e extrapolando para o caso limite em que p tende para o infinito temos a métrica de Chebyshev definida como (27).

$$\lim_{p \rightarrow \infty} \left(\sum_{i=1}^n |x_i - y_i|^p \right)^{1/p} = \max_{i=1}^n |x_i - y_i| \quad (27)$$

A vantagem de se usar a métrica de Minkowski generalizada, ao invés de outras métricas de distância, está na facilidade de observar os resultados de um problema com o uso de diferentes métricas de distância, bastando para isso modificar o valor do parâmetro p e, utilizar aquele que melhor se adequar ao problema.

• *Testes e Resultados Experimentais*

A tabela 20 apresenta o número de classificações corretas encontrados pelo SIDA2, sem a variável tempo (variável 12 da tabela 9) e, com diferentes valores para o parâmetro p da métrica de Minkowski generalizada.

Tabela 20. Número de classificações corretas com o uso de diferentes valores para o parâmetro p

<i>Valores de p</i>	<i>Avaliações</i>	<i>Classificações corretas</i>
$p = 2$	$1.9 \cdot 10^4$	236
$p = 3$	$5.5 \cdot 10^4$	236
$p = 6$	$1.9 \cdot 10^4$	236
$p = 9$	(---)	(---)

(---) resultado não encontrado em $2.0 \cdot 10^5$ avaliações.

De acordo com a tabela 20, pode-se concluir que o QEA foi capaz de encontrar o resultado esperado na maioria dos casos considerados, menos quando parâmetro p da métrica de Minkowski generalizada é igual a 9. Além disso, pode-se observar na tabela 20, que o valor escolhido para o parâmetro p influencia no tempo de processamento do algoritmo.

A tabela 21 mostra os resultados obtidos com o SIDA2 com diferentes conjuntos de variáveis da tabela 9, e com diferentes valores para o parâmetro p .

Tabela 21. Resultado do SIDA2 com diferentes conjuntos de variáveis de estados e diferentes valores para o parâmetro p de Minkowski

<i>Valores de p</i>	<i>Conjunto de variáveis</i>	<i>Avaliações</i>	<i>Classificações corretas</i>
$p = 2$	4, 7, 10, 16	$1.3 \cdot 10^4$	236
	4, 7, 10, 13, 16, 18	$1.6 \cdot 10^4$	236
	2, 4, 5, 7, 10, 13, 16	$1.9 \cdot 10^4$	236
	1, 2, 4, 5, 7, 8, 10, 13, 16, 18	$1.9 \cdot 10^4$	236
	1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 13, 14, 15, 16, 17, 18	$1.8 \cdot 10^4$	236
$p = 3$	4, 7, 10, 16	$1.9 \cdot 10^4$	236
	4, 7, 10, 13, 16, 18	$1.8 \cdot 10^4$	236
	2, 4, 5, 7, 10, 13, 16	(---)	(---)
	1, 2, 4, 5, 7, 8, 10, 13, 16, 18	$2.3 \cdot 10^4$	236
	1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 13, 14, 15, 16, 17, 18	$5.5 \cdot 10^4$	236
$p = 6$	4, 7, 10, 16	$2.2 \cdot 10^4$	236
	4, 7, 10, 13, 16, 18	$7.3 \cdot 10^4$	236
	2, 4, 5, 7, 10, 13, 16	(---)	(---)
	1, 2, 4, 5, 7, 8, 10, 13, 16, 18	(---)	(---)
	1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 13, 14, 15, 16, 17, 18	$2.0 \cdot 10^4$	236
$p = 9$	4, 7, 10, 16	$2.4 \cdot 10^4$	236
	4, 7, 10, 13, 16, 18	$4.6 \cdot 10^4$	236
	2, 4, 5, 7, 10, 13, 16	$1.5 \cdot 10^4$	236
	1, 2, 4, 5, 7, 8, 10, 13, 16, 18	(---)	(---)
	1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 13, 14, 15, 16, 17, 18	(---)	(---)

(---) resultado não encontrado em $2.0 \cdot 10^5$ avaliações.

Pela análise dos resultados mostrados na tabela 21, observa-se que o SIDA2 encontrou o resultado esperado, ou seja o valor 236 de classificações corretas em todos os conjuntos considerados, apenas quando o com o parâmetro p foi fixado em $p = 2$, o que leva a concluir que a métrica euclidiana é a mais indicada para esse tipo de problema.

Pode-se observar ainda na tabela 20 que o segundo melhor resultado foi encontrado com o parâmetro $p = 3$, onde o algoritmo não alcançou o maior número de classificações corretas apenas com o conjunto formado por 7 variáveis (2, 4, 5, 7, 10, 13, 16). Cabe ressaltar ainda que, diferentemente dos resultados da tabela 20, o QEA encontrou o maior número de classificações corretas com o parâmetro $p = 9$, onde em um dos casos foi capaz de encontrar o resultado esperado em um menor número de avaliações que os casos $p = 3$ e $p = 6$.

Os resultados da tabela 21, além de mostrar que a métrica euclidiana é a mais indicada para o problema, mostra evidências de que o método desenvolvido com o QEA é capaz de encontrar o resultado esperado usando diferentes conjuntos de variáveis de estado. O que mostra que não existe um único conjunto mínimo/máximo suficiente para que o resultado seja encontrado.

- ***Classificação em tempo real***

Nesta fase do trabalho, assim como nas seções 7.2.1 e 7.2.3 foi utilizado o programa Prog_diagnóstico para analisar a robustez dos vetores protótipos gerados pelo QEA na seção anterior (tabela 21), quando submetidos a ruídos de 1% e 2% no sinal original de cada condição de referência. As tabela 22 e 23 apresentam os resultados obtidos nos testes realizados, destacando o conjunto das variáveis selecionadas, o valor do parâmetro p usado, o número de classificações corretas em percentagem e, o ruído implementado.

Tabela 22. Classificação em tempo real com ruído de 1%

Conjunto de variáveis	Condição de operação	Ruído (%)	Valores de p e classificações corretas (%)			
			$p=2$	$p=3$	$p=6$	$p=9$
4,7,10,16	MFWBR	1	100	100	100	100
	LOCA	1	100	100	100	96,61
	SGTR	1	100	100	100	100
	NORMAL	1	100	91,52	37,28	89,83
4,7,10,13, 16, 18	MFWBR	1	98,30	98,30	100	98,30
	LOCA	1	100	98,30	98,30	96,61
	SGTR	1	100	84,74	100	100
	NORMAL	1	100	100	61,01	86,44
2,4,5,7, 10,13,16	MFWBR	1	100			100
	LOCA	1	100			100
	SGTR	1	100	(---)	(---)	100
	NORMAL	1	88,13			67,79
1,2,4,5,7,8,10,13,16,18	MFWBR	1	100	100		
	LOCA	1	100	100		
	SGTR	1	100	100	(---)	(---)
	NORMAL	1	83,05	100		
1,2,3,4,5,6,7,8,9,10,11,13, 14,15,16,17,18	MFWBR	1	100	100	100	
	LOCA	1	100	93,22	93,22	
	SGTR	1	72,88	100	89,83	(---)
	NORMAL	1	100	79,66	89,83	
Todas as variáveis	MFWBR	1	100	100	100	100
	LOCA	1	100	96,61	94,91	91,52
	SGTR	1	100	98,30	88,13	83,05
	NORMAL	1	100	96,61	100	94,91

(---) resultado não encontrado em $2.0 \cdot 10^5$ avaliações.

Tabela 23. Classificação em tempo real com ruído de 2%

Conjunto de variáveis	Condição de operação	Ruído (%)	Valores de p e classificações corretas(%)			
			$p=2$	$p=3$	$p=6$	$p=9$
4,7,10,16	MFWBR	2	100	100	98,30	100
	LOCA	2	100	93,22	91,52	83,05
	SGTR	2	100	100	96,61	100
	NORMAL	2	83,05	59,32	32,20	66,10
4,7,10,13, 16, 18	MFWBR	2	98,30	98,30	96,61	98,30
	LOCA	2	98,30	96,61	96,61	91,52
	SGTR	2	98,30	74,57	94,91	98,30
	NORMAL	2	88,13	96,61	54,23	77,96
2,4,5,7, 10,13,16	MFWBR	2	100	(---)	100	100
	LOCA	2	100		100	100
	SGTR	2	98,30		100	96,61
	NORMAL	2	64,41		40,67	54,24
1,2,4,5,7,8,10,13,16,18	MFWBR	2	100	100	(---)	(---)
	LOCA	2	100	100		
	SGTR	2	96,61	94,91		
	NORMAL	2	69,49	94,91		
1,2,3,4,5,6,7,8,9,10,11,13, 14,15,16,17,18	MFWBR	2	100	100	100	(---)
	LOCA	2	100	86,44	76,27	
	SGTR	2	67,79	98,30	81,35	
	NORMAL	2	100	67,79	81,35	
All 17	MFWBR	2	100	100	98,30	100
	LOCA	2	96,61	79,66	83,05	86,44
	SGTR	2	89,83	98,30	74,57	74,57
	NORMAL	2	96,61	79,66	98,30	74,57

(---) resultado não encontrado em $2.0 \cdot 10^5$ avaliações.

Pela análise dos resultados mostrados nas tabelas 22 e 23, podemos observar que os melhores resultados foram obtidos com o parâmetro de Minkowski $p = 2$, ou seja, com o uso da métrica Euclidiana. Pois, o SIDA2 apresentou resultados menos sensíveis a ruídos e, mais robustos que os outros casos considerados. Além disso, o vetor

representante formado por um conjunto de apenas 4 variáveis de estado foi o menos sensível aos ruídos implementados, onde foi capaz de encontrar o maior valor de classificações corretas em 75% dos casos considerados na implementação do ruído de 1% e, em 43,75% dos casos considerados na implementação do ruído de 2%. Cabe ainda ressaltar que, mesmo no caso da implementação do ruído de 2% no sinal original de cada condição de referência o método proposto foi capaz de encontrar o resultado esperado (100% de classificações corretas) em 32% dos casos considerados, ou seja, o com diferentes valores para os parâmetro p e, com diferentes conjuntos de variáveis de estado.

7.2.5 Implementação da resposta “Não Sei” no SIDA2

Com o propósito de tornar o SIDA2 capaz de fornecer a resposta “NÃO SEI” para condições de operação fora das usadas como referência, foram implementadas as seguintes mudanças:

- nova normalização nos dados;
- implementação de um método para calcular “regiões de influência” de cada vetor representante gerado pelo QEA;
- nova função objetivo.

- ***Nova normalização dos dados***

A normalização dos dados no SIDA2 foi feita de forma similar a implementada no SIDA1, ou seja, utilizando o método MAX-MIN Equalizado, que faz uso dos valores máximos e mínimos das variáveis da tabela 9, porém ao invés de utilizar dados de apenas quatro condições de operação, utilizou-se dados de oito condições de operação: as quatro condições de referência utilizadas anteriormente (MFWBR, LOCA, SGTR e NORMAL) mais outras quatro condições de operação: BLACKOUT (*External Power Blackout*), MSTMISO (*Main Steam Water Isolation*), MFWISO (*Main feed water isolation*) e STMLIBR (*Main Steam Rupture*), que também fazem parte do grupo de acidentes de base de projeto postulados no FSAR para a Usina Nuclear Angra 2.

Uma vez que os gráficos de limitação de segurança do SICA são acionados pelo sinal do TRIP do reator, cabe ressaltar que as oito condições de operação usadas no SIDA2 foram selecionadas, pois as mesmas atuam o sinal de TRIP para a Usina.

- ***Cálculo da “região de influência” para cada vetor protótipo***

Com o objetivo de que o SIDA 2 fosse capaz de reconhecer as 4 condições de operação usadas como referência (MFWBR, LOCA, SGTR e NORMAL) e, além disso, identificar os eventos desconhecidos (condições de operação fora das condições de referência), como eventos ‘Não Sei’, surgiu a necessidade de definir um método para diferenciar cada condição de operação de referência e determinar uma forma de diferenciar os mesmos de eventos desconhecidos. Para isso, foi desenvolvida uma metodologia, baseada no Diagrama de Voronoi (Aurenhammer e Klein, 2000), que consiste em dividir o espaço de busca do problema em “áreas de influência” ao redor dos vetores representantes de cada condição de operação, gerados pelo QEA.

O Diagrama de Voronoi, também conhecido na literatura por Tesselação de Dirichlet consiste em definir regiões ao redor de pontos importantes, conhecidos como pontos geradores, onde a distância de um ponto qualquer da região ao redor do gerador do mesmo é sempre menor do que a distância para qualquer outro ponto gerador. Assim, para um dado conjunto de n pontos no plano, pode-se definir informalmente um Diagrama de Voronoi, como sendo a subdivisão do plano em n regiões, onde cada uma dessas regiões é formada pelo lugar geométrico dos pontos mais próximos de cada ponto do conjunto dado. Como mostra a figura 28 (Lopes, 2008)




Figura 28. Diagrama de Voronoi (LOPES, 2008)

O Diagrama de Voronoi é fundamentado em várias definições e teorias, que demonstram sua aplicação. Desta forma, para determinar a metodologia do cálculo da “área de influência” ao redor de cada vetor representante gerado pelo QEA, utilizou-se como base a teoria de compartilhamento de aresta de Voronoi, definida abaixo:

Definição:

Dado dois pontos p_i e p_j , o conjunto de pontos que estão mais próximos de p_i do que p_j estão no semi-plano que contém p_i , definido pela mediatriz do segmento de reta $p_i p_j$. Onde, $H(p_i, p_j)$ é o semi-plano que contém o ponto p_i . (figura 29).




Figura 29. Semi-plano que contém p_i .

A fronteira comum entre duas regiões de Voronoi é denominado por aresta de Voronoi. Porém, dois geradores de Voronoi só possuem aresta em comum, se e somente se, existe um círculo que contém apenas esses dois geradores. Ou seja, dados dois pontos p_i e p_j , os polígonos $V(p_i)$ e $V(p_j)$ possuem uma aresta comum, se e somente se, existem pontos que são equidistantes de p_i e p_j e, além disso, são mais próximos de p_i e p_j do que qualquer outro gerador. Isto implica que $V(p_i)$ e $V(p_j)$ têm uma aresta em comum, se e somente se, existe um círculo que contém p_i e p_j e excluem todos os demais geradores. (figura 30). Cabe ressaltar ainda que, se um círculo¹ $C(x)$

em que x é um ponto interior da aresta partilhada por $V(p_i)$ e $V(p_j)$, tem - se que o raio $d(x, p_i) = d(x, p_j)$ (Figura 30). (Lopes, 2008).




Figura 30. Círculo que contém p_i e p_j . (Lopes, 2008)

Desta forma, com base na definição acima, foi desenvolvido um método para a determinação de arestas entre os pares de vetores representantes vizinhos, gerados pelo QEA. Tal método consiste dos seguintes passos:

1º) Após a determinação dos vetores protótipos pelo QEA, escolhe-se aleatoriamente um. Como por exemplo, o vetor protótipo do acidente LOCA, que para simplificar ao longo do trabalho será chamado de VetLOCA;

2º) Em seguida, calcula-se a distância do vetor protótipo, escolhido no item 1, aos outros três vetores protótipos gerados (figura 31). Por exemplo, calcula-se as seguintes distâncias:

- distância do VetMFWBR ao vetor protótipo do LOCA, chamado aqui de VetLOCA;
- distância do VetMFWBR ao vetor protótipo do SGTR, chamado aqui de VetSGTR;
- e a distância do VetMFWBR ao vetor protótipo do NORMAL, chamado aqui de VetNORMAL.

1 Apesar da solução do problema em questão ser no espaço R^n (hiper-esfera) usamos a representação do círculo no espaço R^2 , sem a perda de generalização do conceito.




Figura 31. Representação do cálculo da distância entre os vetores protótipos

3º) Assim, guarda-se o valor da metade de cada distância calculada no item 2. Essa nova distância será vista como o raio do círculo formado por cada par de vetores protótipos, que irá definir a “área de influência” de cada vetor protótipo. Para simplificar ao longo do trabalho, essa nova distância será chamada de MetDist (). Por exemplo, o valor da metade da distância entre o VetLOCA e o VetSGTR será chamado de MetDist (VetLOCA _ VetSGTR), o valor da metade da distância entre o VetLOCA e o VetMFWBR será chamado de MetDist (VetLOCA _ VetMFWBR) e, assim por diante.

4º) Após o passo 3º, calcula-se o ponto médio entre cada par de vetores protótipos considerados no item 2 e 3. O ponto médio assim calculado pode ser visto como o centro do círculo que compreende o par de vetores representantes considerados. Para simplificar ao longo do trabalho, cada ponto médio determinado será chamado de PontMed(). Na figura 32, o ponto médio entre o VetMFWBR e o VetSGTR, ou seja, o PontMed(VetMFWBR_VetSGTR), foi representado como PontMed 1;

5º) De posse do ponto médio, calcula-se a distância do ponto médio considerado aos demais vetores protótipos não considerados, no cálculo do ponto médio. Por exemplo, dado o ponto médio: PontMed (VetMFWBR_VetSGTR) (PontMed1) calcula-se a distância do mesmo aos vetores: VetLOCA e VetNORMAL (Figura 32). E verifica-se se as distâncias calculadas são menores do que a MetDist (VetMFWBR_VetSGTR), se verdade diz-se que o par VetMFWBR_VetSGTR

não possuem aresta comum, se falso diz-se que o par VetMFWBR_VetSGTR possuem aresta comum.




Figura 32. Representação do cálculo da distância do PontMéd 1 aos outros vetores protótipos

6º) Repete-se todos os passos anteriores até que sejam encontrados todos os círculos formados entre os pares de vetores representantes que possuem arestas em comum. A figura 33 ilustra uma possível configuração encontrada no final do processo.




Figura 33. Representação de todos os pares de vetores representantes que possuem aresta em comum

Assim, no final do processo, ter-se-á a “área de influência” de cada vetor protótipo gerado pelo QEA, onde os pontos médios encontrados podem ser vistos como arestas em comum entre os pares de vetores representantes. A figura 34 ilustra uma possível configuração das “áreas de influência” determinadas no final dos 6 passos descritos acima.




Figura 34. Representação das áreas de influência

• Nova Função Objetivo

A nova função objetivo (fitness) para o SIDA 2, foi projetada de modo a ponderar favoravelmente o número de classificações corretas da seguinte maneira: $fitness = 236 - \text{número de acertos}$, onde o número de acertos foi concebido em duas fases distintas e, o valor máximo acumulado é 472, ou seja 2×236 (59 linha de tempo * 4 vetores representantes). Desta forma, o melhor vetor solução do QEA será aquele que tiver o valor da função objetivo = -236. Para isso será necessário que sua posição no espaço seja tal que, qualquer evento (amostra) pertencente a uma determinada condição de referência (classe) esteja sempre mais próximo de seu vetor protótipo do que de qualquer outro vetor protótipo e, além disso, a distância do evento ao seu vetor protótipo deve ser menor ou igual ao valor do “raio de influência” de seu vetor protótipo. Para isso, o melhor vetor candidato solução do QEA deverá receber 1 ponto em cada etapa considerada para alcançar o número de classificações corretas igual a - 236.

O primeiro passo para a solução candidata receber 1 ponto na fitness é :

- 1º) Calcula-se a distância do evento aos 4 vetores protótipos gerados pelo QEA;
- 2º) Verifica-se qual a menor distância encontrada;

3º) Se o evento estiver mais próximo do seu vetor protótipo, o mesmo ganha um ponto, por exemplo, se o evento considerado pertencer ao acidente LOCA o mesmo deverá estar mais próximo do VetLOCA do que de qualquer outro vetor representante e, assim por diante.

Os passos 1º, 2º e 3º são repetidos até que se tenha acumulado uma fitness igual a 236 pontos.

Após receber uma pontuação = 236 a solução candidata passa para a segunda etapa, onde irá receber os outros 236 pontos, da seguinte forma:

1º) Calcula-se a distância do evento aos pontos médios encontrados;

2º) Verifica-se qual a menor distância encontrada;

3º) Se a menor distância encontrada for menor ou igual ao valor do “raio de influência” do seu vetor protótipo, a solução candidata ganha um ponto, ou seja, por exemplo, se o evento considerado pertencer ao acidente LOCA o mesmo deve estar mais próximo do ponto médio mais próximo do VetLOCA do que de qualquer outro ponto médio. E, assim por diante.

Os passos 1º, 2º e 3º são repetidos até a solução candidata do QEA tenha acumulado uma fitness igual a 236 pontos.

• ***Testes e Resultados Experimentais***

Os testes realizados nesta fase do trabalho tiveram como objetivo verificar o comportamento do SIDA2 com as modificações apresentadas acima. Para isso, diferentes conjuntos de variáveis (tabela 9) foram testados de forma aleatória, e usou-se a métrica euclidiana. Os testes foram realizados em 10 experimentos com 10 sementes diferentes, com uma população de 100 indivíduos. O valor do parâmetro ε foi fixados em 0.01 e, foram usados os valores $0.005 \cdot \pi$ e $0.0005 \cdot \pi$ para o parâmetro Δ . Na tabela 24, são destacados os conjuntos de variáveis que apresentaram os melhores resultados, bem

como a geração em o resultado foi encontrado, a semente e o valor do parâmetro Δ usado.

Tabela 24. Melhores vetores protótipos gerados pelo QEA

Variáveis	Condição de operação	Vetores protótipos gerados pelo QEA	Δ	Geração	Fitness
4,7,10, 16	MFWBR	[0.3848 0.1670 0.0378 0.7526]	0.005* π	757	-236
	LOCA	[0.3934 0.02710 0.9836 0.1863]			
	SGRT	[0.9944 0.3209 0.6603 0.3467]			
	NORMAL	[0.9914 0.0781 0.1619 0.0371]			
4,7,10,13 16,18	MFWBR	[0.2286 0.2943 0.0757 0.4193 0.0439 0.6733]	0.0005* π	4022	-236
	LOCA	[0.4596 0.1592 0.9233 0.7934 0.9792 0.1729]			
	SGRT	[0.9602 0.1543 0.9667 0.9062 0.6955 0.3668]			
	NORMAL	[0.9858 0.6855 0.9848 1.0000 0.2036 0.2818]			

Com os resultados da tabela 24, pode-se concluir que o método desenvolvido foi capaz de encontrar o máximo número de classificações corretas (-236) com os dois conjuntos de variáveis considerados. Além disso, pode-se observar que o conjunto com apenas 4 variáveis de estado foi capaz de encontrar o resultado esperado com menor esforço computacional, ou seja, com um menor número de avaliações.

- ***Classificação em tempo real***

Como nas seções anteriores (seções 7.2.1, 7.2.3 e 7.2.4), com o objetivo de verificar a robustez dos vetores protótipos gerados pelo QEA e, simular um Sistema de Identificação de Acidentes em tempo real, foi utilizado o programa Prog_diagnóstico, no qual os melhores vetores protótipos gerados pelo QEA (tabela 24) são usados como vetores representantes das classes de referência, para a classificação instantânea de um evento. Além disso, foram usadas 4 condições de operação postulados para a Usina Nuclear Angra 2 diferentes das condições de operação de referência. Essas novas

condições de operação são as mesmas que participaram do processo de normalização dos dados (BLACKOUT, MSTMISO, MFWISO e STMLIBR) e serão interpretadas pelo programa como eventos “Não Sei”. Cabe ressaltar que, as assinaturas de cada condição operação foram usadas como amostras dos mesmos. Essa modelagem foi permitida uma vez que, a variável tempo (t) não foi usada nos testes considerados.

A classificação do evento como pertencente a uma das classes de referência foi feita, de forma similar as seções anteriores, ou seja, através do cálculo de distância de euclidiana entre a assinatura de cada classe e o seu respectivo vetor protótipo gerado pelo QEA.

Espera-se que ao final de execução do programa o mesmo encontre 59 classificações corretas para cada condição de operação (classe) considerada, inclusive para as condições de operação desconhecidas, uma vez que foram usadas 59 amostras para cada classe. Nas tabelas 25 e 26 são apresentados os resultados obtidos, com os vetores representantes da tabela 24, destacando o número de classificações corretas para cada classe de referência em percentagem, a condição de operação usada como desconhecida.

Tabela 25. Classificação em tempo real para o conjunto de 4 variáveis

Condição de operação desconhecida	Condição de operação	Acertos (%)
BLACKOUT	MFWBR	100 %
	LOCA	100 %
	SGTR	100 %
	NORMAL	100 %
	NÃO SEI	(*) 93%
MSTMISO	MFWBR	100 %
	LOCA	100 %
	SGTR	100 %
	NORMAL	100 %
	NÃO SEI	(*) 97%
MFWISO	MFWBR	100 %
	LOCA	100 %
	SGTR	100 %
	NORMAL	100 %
	NÃO SEI	(*) 39%
STMLIBR	MFWBR	100 %
	LOCA	100 %
	SGTR	100 %
	NORMAL	100 %
	NÃO SEI	100%

(*) - resultado confunde com a condição de operação MFWBR no início da classificação.

Tabela 26. Classificação em tempo real para o conjunto de 6 variáveis

Condição de operação desconhecida	Condição de operação	Acertos
BLACKOUT	MFWBR	100 %
	LOCA	100 %
	SGTR	100 %
	NORMAL	100 %
	NÃO SEI	(*) 95%
MSTMISO	MFWBR	100 %
	LOCA	100 %
	SGTR	100 %
	NORMAL	100 %
	NÃO SEI	100 %
MFWISO	MFWBR	100 %
	LOCA	100 %
	SGTR	100 %
	NORMAL	100 %
	NÃO SEI	(*) 15%
STMLIBR	MFWBR	100 %
	LOCA	100 %
	SGTR	100 %
	NORMAL	100 %
	NÃO SEI	(#) 97%

(*) - resultado confunde com a condição de operação MFWBR no início da classificação.

(#) - resultado confunde com a condição de operação MFWBR no início da classificação.

Pela análise dos resultados mostrados nas tabelas 25 e 26, pode-se observar que ambos os vetores protótipos gerados pelo método proposto foram capazes de reconhecer, em 100% dos casos considerados, as condições de referência e, além disso, identificar as condições de operação desconhecidas em 85% dos casos considerados. Mesmo no caso da condição de operação MFWISO em que se obteve 35% de classificações corretas com o conjunto de 4 variáveis de estado e, 15% de classificações

corretas com o conjunto de 6 variáveis de estado, pode-se dizer que o método proposto teve uma boa performance, pois o MFWISO foi confundido, somente nos primeiros segundo do acidente, com a condição de operação MFWBR, o que não deixa de ser verdade, uma vez que o MFWISO se refere ao isolamento da linha principal de alimentação e o MFWBR a ruptura da linha principal de alimentação.

As tabelas 27 e 28 apresentam os resultados obtidos com os vetores protótipos da tabela 24, quando submetidos a ruídos gaussianos de 1%, 2% e 5% ($\sigma = 1\%, 2\%, 5\%$).

A classificação do evento anômalo como pertencente a uma das classes de referência foi feita através do cálculo de distância euclidiana entre a nova assinatura (assinatura original + ruído) de cada classe e o seu respectivo vetor protótipo gerado pelo QEA. Espera-se que ao final de execução do programa o mesmo encontre 100% de classificações corretas para cada classe considerada. A tabela 27 apresenta os resultados obtidos, destacando as condições de operação usadas, inclusive a condição de operação usada como desconhecida ('Não Sei') e, o número de classificações corretas em percentagem obtidos para cada condição de operação,

Tabela 27. Classificação em tempo real para o conjunto de 4 variáveis

Condição de operação desconhecida	Condição de operação	Acertos %		
		Ruído (1%)	Ruído (2%)	Ruído (5%)
BLACKOUT	MFWBR	100%	100%	100%
	LOCA	100%	100%	98%
	SGTR	100%	100%	97%
	NORMAL	73%	58%	51%
	NÃO SEI	93%	93%	93%
MSTMISO	MFWBR	100%	100%	100%
	LOCA	100%	100%	97%
	SGTR	100%	100%	98%
	NORMAL	73%	58%	51%
	NÃO SEI	97%	97%	97%
MFWISO	MFWBR	100%	100%	100%
	LOCA	100%	100%	98%
	SGTR	100%	100%	97%
	NORMAL	73%	58%	51%
	NÃO SEI	39%	39%	39%
STMLIBR	MFWBR	100%	100%	100%
	LOCA	100%	100%	98%
	SGTR	100%	100%	97%
	NORMAL	73%	58%	51%
	NÃO SEI	100%	100%	100%

Tabela 28. Classificação em tempo real para o conjunto de 6 variáveis

Condição de operação 'NÃO SEI'	Condição de operação	Acertos %		
		Ruído (1%)	Ruído (2%)	Ruído (5%)
BLACKOUT	MFWBR	100%	98%	86%
	LOCA	100%	100%	100%
	SGTR	100%	100%	100%
	NORMAL	69%	61%	53%
	NÃO SEI	95%	95%	95%
MSTMISO	MFWBR	100%	98%	86%
	LOCA	100%	100%	98%
	SGTR	100%	100%	100%
	NORMAL	69%	61%	53%
	NÃO SEI	100%	100%	100%
MFWISO	MFWBR	100%	98%	86%
	LOCA	100%	100%	98%
	SGTR	100%	100%	100%
	NORMAL	69%	61%	53%
	NÃO SEI	15%	15%	15%
STMLIBR	MFWBR	100%	98%	86%
	LOCA	100%	100%	98%
	SGTR	100%	100%	100%
	NORMAL	69%	61%	53%
	NÃO SEI	97%	97%	97%

Pela análise dos resultados mostrados nas tabelas 27 e 28, pode-se observar que ambos os vetores protótipos gerados pelo método proposto apresentaram bons desempenhos na classificação do evento em tempo real, quando submetidos a ruídos de 1% e 2%, onde foram capazes de encontrar o maior número de classificações corretas para as condições de operação de referência em 75% dos casos considerados, apresentando deficiência somente na classificação da condição de operação NORMAL

Cabe ressaltar que, mesmo submetido a ruídos de 5% o método foi capaz de apresentar resultados que indiquem a condições de referência em ocorrência, pois todos

os resultados das classificações tiveram número máximo de classificações corretas acima de 50% do total. Além disso, nos casos de identificação dos acidentes desconhecidos o método foi capaz de encontrar resultados satisfatórios, ou seja, com classificações acima de 90% em 75% dos casos considerados. Observa-se ainda que o vetor representante formado pelo conjunto de apenas 4 variáveis de estado mostrou-se mais robusto em todos os casos apresentados.

Desta forma, com os resultados apresentados nesta seção, pode-se dizer que a metodologia desenvolvida para a determinação das “áreas de influência” das condições de referência mostrou-se uma potencial solução para o problema considerado. Além disso, aponta um caminho promissor na determinação de “áreas de influência” para problemas de classificação de padrão.

Capítulo 8

Conclusões e Propostas de Trabalhos Futuros

Pesquisas no sentido de unir os conceitos teóricos da computação evolucionária e da computação quântica iniciaram-se no final da década de 90, com a finalidade de desenvolver algoritmos baseados tanto nos conceitos de evolução das espécies da computação evolucionária, quanto no conceito de processamento em paralelo da computação quântica objetivando melhorar a eficiência e a velocidade de algoritmos evolucionários já existentes. Embora, os algoritmos criados nesse ambiente de união usem fundamentos da computação quântica, eles são desenvolvidos para serem implementados em computadores clássicos e, por isso são chamados de algoritmos de inspiração quântica. A vantagem desses algoritmos é que além resolver em tempo eficiente problemas com grandes espaços de busca e de difícil modelagem, não necessitam de nenhum conhecimento prévio do espaço de busca do problema.

Nesta tese foi avaliada a capacidade do algoritmo de inspiração-quântica QEA (Quantum Evolutionary Algorithm), proposto por HAN e KIM (2002), como ferramenta de otimização de dois proeminentes problemas da área nuclear: o Problema da Recarga do Combustível Nuclear (PRN) e o Problema de Identificação e Diagnóstico de Acidentes de uma Usina Nuclear (PDA).

O objetivo de aplicação do QEA ao PRN e ao PDA, dentro do contexto desta tese foi o de mostrar a viabilidade da utilização do QEA como ferramenta de otimização de problemas reais da área nuclear de natureza combinatória e contínua, na busca de soluções em espaços de busca multimodais complexos, de alta dimensão e de alto custo computacional. Cabe ressaltar que a aplicação do QEA ao PRN teve como objetivo avaliar o comportamento do método desenvolvido, investigando suas vantagens e dificuldades em termos de eficiência e robustez em relação às técnicas de inteligência artificial existentes na literatura.

Desta forma, os resultados obtidos com o método desenvolvido e apresentados no Capítulo 5 desta tese, tabela 8, mostraram que o QEA encontrou valores superiores para a concentração de boro (C_B) em um menor número de avaliações do que as metaheurísticas de otimização da literatura: Ant-Q (MACHADO e SCHIRRU, 2002), PBIL-MO (MACHADO et. al., 2005), ACCN (DE LIMA et. al., 2008), FPBIL (CALDAS E SCHIRRU, 2008) e PSORK (MENESES et. al., 2009) e, foi capaz de encontrar resultados similares aos das metaheurísticas de inspiração quântica QPBIL (DA SILVA et. al., 2011) e QACO (DA SILVA et. al., 2010) (tabela 8). Ainda na tabela 8, pode-se observar que a média dos valores da C_B encontrado pelo QEA foi superior aos encontrados por todos os outros métodos de referência, embora o QPBIL tenha mostrado resultados similares. Tais resultados comprovaram que o QEA apresentou mais robustez nos resultados do que os outros algoritmos clássicos da literatura e, além disso, comprovam a eficiência do QEA como ferramenta de otimização para este tipo de problema.

Pode-se dizer que as razões para os valores encontrados para a C_B com o método desenvolvido nesta tese, é devido a codificação quântica das soluções candidatas que reduz consideravelmente o número necessário de cromossomos, fazendo com que se tenha uma boa diversidade no processo de busca, pois cada cromossomo é capaz de representar, ao mesmo tempo, várias soluções possíveis. Além disso, o fenômeno de interferência quântica utilizado pelos algoritmos de inspiração quântica reforça a busca de melhores soluções na vizinhança da solução atual.

Por outro lado, a aplicação do QEA ao PDA teve como objetivo dar continuidade ao desenvolvimento do Sistema protótipo de Identificação e Diagnóstico de Acidentes (SIDA) desenvolvido em trabalho anterior (Nicolau, A. S., 2010), buscando o desenvolvimento de um método de classificação de acidentes com a resposta “Não Sei” para eventos desconhecidos, sem a necessidade de um evento iniciador que indicasse a ocorrência de uma condição anormal, SCRAM do reator por exemplo.

Os resultados apresentados no capítulo 7 desta tese, mostraram que o modelo de SIDA desenvolvido foi capaz de identificar os tipos de acidentes de referência e

distinguir os de tipo desconhecido (“Não Sei”). Além disso, cabe ressaltar que o modelo de SIDA, foi capaz de identificar os tipos de acidentes de referência e, distinguir os de tipo desconhecido (“Não Sei”) com o uso de diferentes conjuntos de variáveis de processo (tabela 9). Tal resultado comprovou que existem diferentes conjuntos de variáveis, não necessariamente mínimo, para que o modelo de SIDA desenvolvido encontrasse o resultado esperado.

Nos testes que simularam um SIDA em tempo real (tabelas 25 e 26, capítulo 7), pode-se observar que ambos os vetores protótipos gerados pelo QEA, com conjuntos de 4 e 6 variáveis de estado, responderam de forma eficiente a classificação do evento para todas as condições de referência e, para a maioria das condições de operação “Não Sei”. Exceto em relação a condição de operação MFWISO (isolamento da linha de alimentação principal), no qual o SIDA obteve 39% das classificações corretas, com o vetores protótipos formados por 4 variáveis e, 15% das classificações corretas, com o vetores protótipos formados por 6 variáveis. Porém, tais resultados não invalidam o método proposto, pois o MFWISO foi confundido, apenas nos primeiros segundos de classificação, com a condição de operação MFWBR (ruptura da linha de alimentação principal), o que não deixa de ser verdade, uma vez que o MFWISO se refere ao isolamento da linha principal de alimentação.

Mesmo na presença de ruídos gaussianos de 1%, 2% e 5% (tabelas 27 e 28, capítulo 7) verificou-se a eficácia do método desenvolvido e constatou-se que ambos os vetores protótipos gerados pelo QEA responderam de forma satisfatória a classificação do evento em tempo real. Porém, os vetores protótipos formados por um conjunto de apenas 4 variáveis de estado mostrou-se mais robusto aos ruídos submetidos.

Cabe ressaltar ainda, que o método proposto para a determinação da resposta “Não Sei” mostrou-se uma potencial solução para a determinação dos gráficos de limitação de segurança do SICA de Angra 1, na ocorrência de um dos acidentes de referência (LOCA, SGTR e MFWBR).

Diante dos resultados encontrados e dos fatos mencionados podemos concluir que os resultados apresentados nesta tese tanto para o PRN, quanto para o PDA confirmam a validade dos métodos desenvolvidos com a ferramenta de inspiração quântica QEA, uma vez que ambos resolvem de forma eficaz os problemas

considerados e, além disso mostram que as técnicas de inspiração quântica são potenciais ferramentas de otimização para problemas complexos da área nuclear, pois encontram ótimos resultados em um menor número de avaliações.

• *Propostas de Trabalhos Futuros*

A fim de estender os resultados obtidos neste trabalho e aperfeiçoar os métodos desenvolvidos tanto para o PRN, quanto para o PDA, ficam como sugestões de trabalhos futuros:

- a) aplicar o método desenvolvido para o PDA a um maior número de condições de acidente sem o SCRAM do reactor;
- b) aumentar o número de variáveis usadas no método desenvolvido para o PDA;
- c) pesquisar um conjunto ideal de variáveis de estado, consideradas necessárias e suficientes, para a classificação de um conjunto de condições de operação postulados para a Usina Nuclear Angra1;
- d) Testar o desempenho do Sistema desenvolvido utilizando a métrica de Manhattan, ou seja fazendo o parâmetro p de Minkowski igual 1.
- e) aplicar ambos os métodos desenvolvidos em plataforma paralela CUDA/GPU.

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., 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.

AURENHAMMER E KLEIN, R., 2000. ***Voronoi diagrams***, J.R.Sack, J. Urrutia (Eds), Handbook of Computational Geometry, Elsevier, Amsterdam, PP. 201 – 290.

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. “Detecting Faults in a Nuclear Power Plant by Using a Dynamic Node Architecture Artificial Neural Network”, ***Nuclear Science and Engineering***, vol. 116, pp. 313-325.

BAKSHAYESH, K., M., e GHOFRANI, M., B., 2013. “Transient identification in nuclear power plants: A review”. *Progress in Nuclear Energy*, v.67, pp. 23-32.

BEAN, J. C., 1994. “Genetic Algorithms and Random Keys for Sequencing and Optimization”, *ORSA Journal of Computing* 6, 154-160.

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.

CHANG, H., et al., 2013, “Linear Representation and Sparse Solution for Transient Identification in Nuclear Power Plants”, IEEE Transactions on Nuclear Science, v.60, n.1.

CALDAS, G. H. F., SCHIRRU, R., 2008. “Parameterless Evolutionary Algorithm Applied to the Nuclear Reload Problem”, Annals of Nuclear Energy 35, 583-590.

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.

CHAPOT, J. L. C., 2000. *Otimização Automática de Recargas de Reatores a Água Pressurizada Utilizando Algoritmos Genéticos*. Tese de D.Sc, COPPE/UFRJ, Brasil.

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

DA SILVA, M. H., SCHIRRU, R., DE LIMA, A. M. M., 2010. “QACO-Alpha applied to the nuclear reactor core fuel reload optimization”, Progress in Nuclear Energy 53, 80-85.

DA SILVA, M. H., SCHIRRU, R., 2011. “Optimization of nuclear reactor core fuel reload using the new Quantum PBIL”, Annals of Nuclear Energy 38, 610-614.

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.

DECHAINED, M.D., FELTUS, M.A., 1995. “Nuclear Fuel Management Optimization Using Genetic Algorithms”, Nuclear Technology, v. III, pp. 109-114.

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

DE LIMA, A. M. M, 2005. *Recarga de Reatores Nucleares Utilizando Redes Cognitivas de Colônias Artificiais*. Tese de D. Sc., COPPE/UFRJ, Brasil.

DE LIMA, A. M. M, SCHIRRU, R., DA SILVA, F. C., MEDEIROS, J. A. C. C., 2008. “A nuclear reactor core fuel reload optimization using Ant Colony Connective networks”. Annals of Nuclear Energy, 35, pp. 1606-1612.

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

EVSUKOFF, A., GENTIL, S., 2005. “Recurrent neuro-fuzzy system for fault detection and isolation in nuclear reactors”, Advanced Engineering INFORMATICS, pp. 55-66.

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

FURUKAWA, H., UEDA, T., KITAMURA, M., 1995. “Use of Self-Organizing Neural Networks for Rational Definition of Plant 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 nº 2.632.058.

GROPP, W., LUSK, E., DOSS, N., SKJELLUM, A., 1996. “A high-performance, portable implementation of the MPI message passing interface standard”, Parallel Computing, 22, pp.789–828, ELSEVIER.

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

HAN, K.H., e KIM, J. H., 2004. “Quantum-Inspired Evolutionary Algorithms with a New Termination Criterion, He Gate, and Two-Phase Scheme”, IEEE Transactions on Evolutionary Computation 8, 156–169.

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

HSIAO, T., LIN, C., YUANN, Y.R., 2010. “Identification of initiating events for pressurized water reactor accidents”, Annals of Nuclear Energy, pp. 1502-1512.

HOLLAND, J., *Adaptation in Natural and Artificial Systems*. Ann Arbor, USA: University of Michigan Press, 1975.

JAIN, A., DUBES, R., *Algorithms for clustering data*, Prentice-Hall, 1998.

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.

KROPACKEK, D. J., TURINSKY, P. J., 1991. “In-core Nuclear Fuel Management Optimization for Pressurized Water Reactors Utilizing Simulated Annealing”, Nuclear Technology v.95, n.9, pp.9-31.

LANGENBUCH, S., MAURER, W., WERNES, W., 1977. "Coarse mesh flux expansion method for analysis of space time effects in large light water reactors cores", Nuclear Science and Engineering 63, 437-456.

LIN, C., CHANG, H., 2011. "Identification of pressurized water reactor transient using template matching", Annals of Nuclear Energy, pp. 1662-1666.

LOPES, S. M. O. F., 2008. *Técnicas Geométricas de Condensação para o Classificador K-NN*. Tese de M.Sc., Departamento de Matemática, Universidade de Aveiro, Portugal.

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.

MACHADO, L., SCHIRRU, R., 2002. "The Ant-Q Algorithm Applied to the Nuclear Reload Problem", Annals of Nuclear Energy 29, 1455-1470.

MACHADO, M. D., 2005. *Algoritmo Evolucionário PBIL Multi-Objetivo Aplicado ao Problema da Recarga de Reatores Nucleares*. Tese de D.Sc., COPPE/UFRJ, 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 Enginnering in latin America, Asn, Mexico.

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

MENDES, A. V., 2007. *Estudo de criptografia com chave publica baseada em curvas elípticas*. Dissertação de M.Sc, Universidade estadual de montes claros, Departamento de ciências da computação, curso de sistema da informação, São Paulo, Brasil

MENESES, A. A. M., MACHADO, M. D., SCHIRRU, R., 2009., “Particle Swarm Optimization Applied to the Nuclear Reload Problem of a Pressurized Water Reactor”, *Progress in Nuclear Energy* 51, 319-326.

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., 2010. “Computação Quântica e Inteligência de Enxames Aplicados na Identificação de Acidentes de uma Usina Nuclear PWR”, Dissertação de MS.c, COPPE/UFRJ, Brasil.

NICOLAU^a, A. S., SCHIRRU, R., 2010. “Study of the Quantum Evolutionary Algorithm Parameters Applied to Transient Identification”, *International Journal of Applied Mathematics and Informatics*, 4, 33-40.

NICOLAU^b, A. S., SCHIRRU, R., 2010. “Quantum evolutionary algorithm applied to time independent transient identification of a nuclear power plant”, *Proceedings of the International Conference on Applied Computer Science (ACS)*, Malta, 406-413.

NICOLAU^c, A. S., SCHIRRU, R., 2010. “Study on the Performance of Quantum Evolutionary Algorithm”. In: *XIII Encontro de Modelagem Computacional*, 2010, Friburgo. Caderno de Resumos. Friburgo : UERJ, 2010. v. 1. p. 33-33.

NICOLAU, A. S., SCHIRRU, R., MENESES, A. A. M., 2011. “Quantum evolutionary algorithm applied to transient identification of a nuclear power plant”, *Progress in Nuclear Energy*, 53, 86-91.

NICOLAU^d, A. S., SCHIRRU, R., 2011. “Transient Diagnosis System Using Quantum Inspired Computing and Minkowski Distance”. In: *International Nuclear Atlantic Conference*, 2011, Belo Horizonte. *Inac 2011 - International Nuclear Atlantic Conference _ Nuclear energy - New jobs for a better life*, 2011. v. 1. p. 1-12.

NICOLAU, A. S., SCHIRRU, R., 2010, DE LIMA, A.M.M. 2011. “Accident Identification System with Automatic Detection of Abnormal Condition Using Quantum Computation”. In: International Conference on Mathematics and Computational Methods Applied to Nuclear Science and Engineering (M&C), 2011, Rio de Janeiro. M&C2011. Estados Unidos : Latin American Section.

NICOLAU, A. S., SCHIRRU, R., 2012. “Nuclear Reactor Reload Using Quantum Inspired Algorithm”, Progress in Nuclear Energy 55, 40-48.

NOWOTNIAK, R. e KUCHARSKI, J., 2010. “Building Blocks Propagation in Quantum-Inspired Genetic Algorithm”, Sci Bull. AC. Sci. and Technology, Automatics 14, 795-810.

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

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.

POON, P.W., PARKS, G.T., 1992. “Optimizing PWR Reload Core Design, Parallel Problem Solving from Nature”, v. 2, pp. 371-380.

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**.

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

SCARANI, V., KURTSIEFER, C., 2009. “The black paper of quantum cryptography: real implementation problems”. 0906.4547.

SCIENTIFIC AMERICAN BRASIL, 2012. *Os riscos e as soluções da energia nuclear*. Edição especial, ISSN 1679522-9

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.

SCHIRRU, R., PEREIRA, C.M.N.A, 2004. “ A Real Time Artificially Intelligent Monitoring System for Nuclear Power Plants Operators Support, Real – Time Systems, v. 27, p.p.71 – 83.

SHOR, P.W., 1994. “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, pp. 124-134.

SUN J., et. al., 2004. “Particle Swarm Optimization With Particles Having Quantum Behavior”, *IEEE Transactions on Evolutionary Computation*, pp. 325-331.

SUN J., et. al., 2005. “Adaptive Parameter Control for Quantum-behaved Particle Swarm Optimization on Individual Level”, *IEEE Transactions on Evolutionary Computation*, pp. 3049-54.

VILLAS BÔAS, M.J., 2011. *Diagnóstico de classe utilizando inteligência de enxames aplicado ao problema de identificação de transientes nucleares*, Tese de M.Sc., Universidade Estadual do Ceará. Instituto Federal de Educação, Ciências e Tecnologia do Ceará, Convênio com a Universidade Federal do Rio de Janeiro, RJ, Brasil.

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

WORD NUCLEAR ASSOCIATION, 2013. <http://wordnuclear.org/nfo/Current-and-Future-Generation/PlansFor-New-Reactors-Worldwide/>

Y. G. No, et. al., 2013, “Monitoring severe accidents using AI techniques,” Nucl. Eng. Technol., vol. 44, no.4, pp. 393–404.

YUAN, C., et.al., 2013, “Linear Representation and Sparse Solution for Transient Identification in Nuclear Power Plants”, IEEE Transactions on Nuclear Science, v.60, n.1, pp.319-327