



OTIMIZAÇÃO POR COLÔNIA DE FORMIGAS APLICADA AO PROBLEMA DE
DETECÇÃO DE ACIDENTES EM CENTRAIS NUCLEARES *PWR*

Vicente Carlos Melo da Silva Junior

Dissertação de Mestrado 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 Mestre em
Engenharia Nuclear.

Orientador: Alan Miranda Monteiro de Lima

Rio de Janeiro

Abril de 2025

OTIMIZAÇÃO POR COLÔNIA DE FORMIGAS APLICADA AO PROBLEMA DE
DETECÇÃO DE ACIDENTES EM CENTRAIS NUCLEARES *PWR*

Vicente Carlos Melo da Silva Junior

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

Orientador: Alan Miranda Monteiro de Lima

Aprovada por: Prof: Alan Miranda Monteiro de Lima

Prof: Victor Henrique Cabral Pinheiro

Dr.: Marcelo Carvalho dos Santos

RIO DE JANEIRO, RJ - BRASIL

ABRIL DE 2025

Silva Jr, Vicente Carlos Melo da

Otimização Por Colônia De Formigas Aplicada Ao Problema De Detecção De Acidentes Em Centrais Nucleares PWR/ Vicente Carlos Melo da Silva Junior. – Rio de Janeiro: UFRJ/COPPE, 2025.

XII, 61 p.: il.; 29,7 cm.

Orientador: Alan Miranda Monteiro de Lima

Dissertação (mestrado) – UFRJ/ COPPE/ Programa de Engenharia Nuclear, 2025.

Referências Bibliográficas: p. 59-61

1. Inteligência Artificial 2. Otimização por Colônia de Formigas 3. Detecção de Acidentes/ Transientes 4. Centrais Nucleares. I. Lima, Alan Miranda Monteiro de. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Nuclear. III. Título.

Dedicatória:

Dedico este trabalho à minha mãe (*in memoriam*) e ao meu pai por viabilizarem-me enquanto pessoa, pelos valores ensinados e pelo apoio desprendido até agora, às minhas filhas que, por suas posições em minha vida, são o principal agente motivador e à minha irmã pelo apoio material e moral dispensados desde a tenra idade.

Agradecimentos

Agradeço à minha família, na figura dos meus pais, minha irmã e minhas filhas que, de modo geral, sempre manteve inabalável confiança na minha capacidade de realização, agradeço a orientação recebida pelo Professor Alan, sempre precisa, exata e paciente. Agradeço aos meus velhos amigos, aqueles quem, há mais de duas décadas têm participado da minha jornada, cujo destino ignoro por estar mais interessado em aproveitar a viagem em si.

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

OTIMIZAÇÃO POR COLÔNIA DE FORMIGAS APLICADA AO PROBLEMA DE
DETECÇÃO DE ACIDENTES EM CENTRAIS NUCLEARES *PWR*

Vicente Carlos Melo da Silva Junior

Abril/ 2025

Orientador: Alan Miranda Monteiro de Lima

Programa: Engenharia Nuclear

O presente documento trata da aplicação da Otimização por Colônia de Formigas adaptada para meios contínuos no Problema de Detecção de Acidentes/ Transientes em Centrais Nucleares *PWR*. Tomando como base os dados referentes à progressão das variáveis de interesse da planta que refletem seu comportamento durante um evento base de projeto, a implementação da modelagem baseada na busca pelos centroides destes eventos que maximizam as classificações corretas se mostrou, além de viável, promissora já que a convergência em todos os casos foi atingida com poucas gerações. A questão tratada nesta dissertação tem as características de um problema de separação de classes, cada qual representada por um evento base de projeto, adicionalmente foi adaptada uma metodologia para determinar a zona de influência de cada centroide de modo que o sistema indique que o evento não consta na base de dados, em outras palavras, este é capaz de indicar que “não sabe” o que está em curso. Os resultados e as avaliações em termos de estimativas de custos computacionais mostraram que o método é capaz de encontrar os centroides que maximizam os acertos e a resposta ao evento fora da base de dados indica, sob condições específicas, a robustez do modelo e da implementação computacional aqui proposta.

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

ANT COLONY OPTIMIZATION APPLIED TO THE PROBLEM OF ACCIDENT
DETECTION IN PWR NUCLEAR POWER PLANTS

Vicente Carlos Melo da Silva Junior

April/ 2025

Advisor: Alan Miranda Monteiro de Lima

Department: Nuclear Engineering

This document addresses the application of Ant Colony Optimization, adapted for continuous domains, to the Problem of Accident/Transient Detection in PWR Nuclear Power Plants. Based on data related to the progression of the plant's variables of interest that reflect its behavior during a design basis Accident/Transient, the implementation of modeling based on the search for prototype vectors or centroids of these events that maximize correct classifications proved to be not only feasible but also promising, as convergence was achieved in all cases with few iterations. The issue addressed in this dissertation has the characteristics of a class separation problem, with each class represented by a design basis event. Additionally, the methodology was adapted to determine the zone of influence of each centroid so that the system can indicate that the event is not in the database, in other words, it is capable of indicating that it "does not know" what is happening. The results and evaluations in terms of computational cost estimates showed that the method is capable of finding the centroids that maximize correct identifications, and the response to events outside the database, although with a considerable margin of error under specific conditions, indicates the robustness of the model and the computational implementation proposed here.

Sumário

CAPÍTULO I.....	1
INTRODUÇÃO.....	1
1.1 Organização da Dissertação.....	3
CAPÍTULO 2.....	5
O PROBLEMA DE DETECÇÃO DE ACIDENTES EM CENTRAIS NUCLEARES (PDA).....	5
CAPÍTULO 3.....	7
UM BREVE HISTÓRICO DO DESENVOLVIMENTO DOS SISTEMAS DE APOIO AO OPERADOR.....	7
CAPÍTULO 4.....	11
A OPTIMIZAÇÃO POR COLÔNIA DE FORMIGAS (ACO).....	11
4.1 A Otimização por Colônia de Formigas para domínios discretos.....	11
4.2 A Descrição da Metaheurística do ACO.....	13
4.3 O ACO para domínios contínuos.....	16
4.3.1 Funções Densidade de Probabilidade (FDP) e Funções Distribuição Acumulada (FDA).....	17
4.3.2 Representação do Feromônio em ACO para meios contínuos.....	19
4.4 Funções Contínuas para testes de Otimização.....	22
4.4.1 A Função Himmelblau.....	22
4.4.2 A Função Rosembrock.....	24
4.4.3 A Função Rastrign.....	26
CAPÍTULO 5.....	28
OS ACIDENTES POSTULADOS EM CENTRAIS PWR.....	28
5.1 Blackout.....	28
5.2 LOCA (<i>Loss of Coolant Accident</i>).....	29
5.3 Ruptura dos Tubos do Gerador de Vapor (<i>SGTR</i>).....	30

CAPÍTULO 6.....	31
O MODELO PARA O PROBLEMA DE IDENTIFICAÇÃO DE ACIDENTES E/OU TRANSIENTES.....	31
CAPÍTULO 7.....	36
IMPLEMENTAÇÃO COMPUTACIONAL DO MODELO AO PROBLEMA DE DETECÇÃO DE ACIDENTES.....	36
CAPÍTULO 8.....	39
RESULTADOS E DISCUSSÕES.....	39
8.1 Experimentos de Identificação e Classificação.....	39
8.2 Experimentos de variação dos parâmetros da <i>ACO</i>	45
8.3 Experimentos com séries fora da base de dados.....	48
CAPÍTULO 9.....	57
CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS. .	57
REFERÊNCIAS BIBLIOGRÁFICAS.....	59

Lista de Figuras

Figura 1: Esquemático de Planta PWR (EL-SEF <i>et al</i> - 2019).....	1
Figura 2: Fluxograma do Algoritmo da Colônia de Formigas.....	14
Figura 3: Comparativo entre um <i>Kernel</i> Gaussiano e as funções Gaussianas individuais que o compõe(SOCHA & DORIGO, 2006).....	18
Figura 4: Distribuição de probabilidades Discretas (a) e Contínuas (b).....	19
Figura 5: Esquemático da estrutura do arquivo de soluções T.....	20
Figura 6: Função de <i>Himmelblau</i>	23
Figura 7: Convergência da Função de <i>Himmelblau</i>	24
Figura 8: Função de <i>Rosembrock</i>	25
Figura 9: Convergência da Função de <i>Rosembrock</i>	25
Figura 10: Função de <i>Rastrigin</i>	26
Figura 11: Convergência da Função de <i>Rastrigin</i>	27
Figura 12: Processo de Classificação (NICOLAU-2014).....	32
Figura 13: Diagrama de <i>Voronoi</i> (LOPES-2008).....	33
Figura 14: Círculos caracterizadores das Arestas de Voronoi.....	34
Figura 15: Representação 2-D das zonas de influência dos centroides (adaptado NICOLAU-2014).....	35
Figura 16: Custo x Gerações- LOCA-1.....	40
Figura 17: Custo x Gerações - LOCA- 2.....	41
Figura 18: Custo x Gerações- LOCA 3.....	41
Figura 19: Custo x Gerações - LOCA 4.....	42
Figura 20: Custo x Gerações - Blackout 1.....	43
Figura 21: Custo x Geração- SGTR 4.....	44
Figura 22: Custo x Geração-SGTR- Experimento com Feromônio- 1.....	46
Figura 23: Custo x Gerações- SGTR- Experimentos com feromônios-2.....	46
Figura 24: Custo x Gerações- SGTR- Experimentos com feromônios-4.....	47
Figura 25: Custo x Iterações- Blackout- Experimentos com séries fora da base de dados- ruído 2%.....	50
Figura 26: Custo x Iterações- Blackout- Experimentos com séries fora da base de dados ruído 5%.....	50

Figura 27: Custo x Iterações- <i>LOCA</i> - Experimentos com séries fora da base de dados- ruído 1%.....	51
Figura 28: Custo x Iterações- <i>LOCA</i> - Experimentos com séries fora da base de dados ruído 5%.52	
Figura 29: Custo x Gerações- <i>SGTR</i> - Experimentos com séries fora da base de dados- ruído 1%.....	53
Figura 30: Custo x Gerações- <i>SGTR</i> - Experimentos com séries fora da base de dados- ruído 5%.....	54
Figura 31: Custo x Gerações- Operação Normal- Experimentos com séries fora da base de dados- ruído 1%.....	55
Figura 32: Custo x Gerações- Operação Normal- Experimentos com séries fora da base de dados- ruído 2%.....	56
Figura 33: Custo x Gerações- Operação Normal- Experimentos com séries fora da base de dados- ruído 5%.....	56

Lista de Tabelas

Tabela 1: Variáveis de Estado (NICOLAU-2014).....	32
Tabela 2: Experimento de Identificação de <i>LOCA's</i>	39
Tabela 3: Experimentos de Identificação: <i>Blackouts</i>	43
Tabela 4: Experimento de Identificação de <i>SGTR's</i>	44
Tabela 5: Variação de Feromônios- Identificação de <i>SGTR's</i>	45
Tabela 6: Avaliação da Resposta aos eventos fora da base de dados.....	49

CAPÍTULO I

INTRODUÇÃO

Uma central nuclear do tipo *PWR* (*Pressurized Water Reactor*) tem um funcionamento similar a uma central termoeletrica convencional, diferenciando somente em sua fonte quente em termos conceituais, que neste caso, em vez de queimar combustíveis fósseis para a geração de vapor, utiliza as reações de fissão nuclear para a geração de calor. Embora a diferença conceitual pareça pequena, as questões envolvendo a segurança e a operação têm suas peculiaridades tornando o sistema, embora economicamente interessante, bastante complexo em termos de quesitos técnicos e de implicações ambientais já que o risco associado da atividade nuclear é demasiado alto muito embora a probabilidade de ocorrências adversas seja extremamente baixa, fruto do exaustivo treinamento das equipes técnicas e operacionais e dos elevadíssimos padrões de qualidade de processos de manutenção e operação.




Figura 1: Esquemático de Planta PWR (EL-SEF *et al*- 2019)

O funcionamento de uma central nuclear típica, esquematizado na figura 1, tem seu principal fundamento na ativação do radionuclídeo fissil (usualmente o Urânio) disposto no núcleo agrupado convenientemente em elementos combustíveis que encerram dentro de si os tais radionuclídeos que, em forma de pastilhas, são ativados por nêutrons que os fissiona, levando à liberação de energia e de mais nêutrons que fissionam outros radionuclídeos constituindo assim uma reação em cadeia. A energia liberada nas fissões aquece o fluido refrigerante, usualmente a água, mantida pressurizada no que se convencionou chamar de circuito primário. O circuito primário troca calor com a água de outro circuito chamado secundário que por meio dos geradores de vapor, alimenta as turbinas cujas saídas são direcionadas usualmente a um reaquecedor e separador de umidade para reaproveitamento e regeneração da energia oriunda da alta entalpia residual deste vapor. O vapor da exaustão da turbina é condensado para que novamente seja enviado aos geradores de vapor, esta etapa tem como fonte fria o mar (ou um grande curso de água) constituindo o circuito terciário. As turbinas movem o gerador elétrico cuja produção é enviada ao Sistema Nacional Interligado por meio dos transformadores.

A atividade nuclear envolve o emprego de espécies químicas como o Urânio, elemento com alto potencial danoso à saúde e ao meio ambiente, por esta razão, as exigências de segurança de uma central termonuclear são altíssimas, buscando sempre a prevenção de acidentes que envolvam a liberação deste radionuclídeo, de seus isótopos, de produtos ativados, produtos derivados da própria fissão e da cadeia de decaimento, ou a mitigação dos efeitos de sua liberação para o ambiente.

A sofisticação dos sistemas de segurança, das barreiras físicas e administrativas tornam a atividade nuclear para a geração de potência elétrica segura, ou seja, com risco de ocorrência de efeitos adversos tão baixos que os questionamentos da viabilidade técnica destes empreendimentos são confortavelmente contornáveis em função da alta confiabilidade conferida às instalações tanto em termos de projeto e construção quanto em termos de operação e manutenção.

O presente trabalho tem por objetivo propor um classificador baseado na Optimização por Colônia de Formigas (*ACO*) adaptado para meios contínuos no problema de detecção de acidentes e/ou transientes em centrais nucleares *PWR* através da busca por vetores protótipos, também chamados de centroides que maximizam as classificações corretas de um evento em curso.

O modelo aqui proposto busca, a partir do comportamento das variáveis de interesse que definem o estado da planta, obter a classificação de um evento em curso dentre os eventos base de projeto, ou seja, os eventos postulados. Adicionalmente, tomando como base o método geométrico que relaciona os centroides dos eventos postulados para a obtenção de zonas de influência destes, obter a identificação de um evento que esteja fora da base de dados, isto é, a obtenção da resposta “não sei” para um evento que seja desconhecido. Isto é importante porque, considerando que o classificador aqui tratado seja empregado como um sistema de apoio à decisão da operação de uma usina nuclear, uma classificação baseada unicamente na distância entre o centroide e o estado da planta em determinado instante durante a ocorrência de um evento fora da base de dados, poderá levar a equipe da sala de controle a tomar medidas que potencializem a degradação da segurança da planta.

1.1 Organização da Dissertação

O primeiro capítulo destina-se a descrever em linhas gerais, em caráter introdutório o funcionamento de um reator nuclear de água pressurizada (*PWR*) os pormenores sobre os mecanismos nucleares de fissão, os principais sistemas de segurança, geração e rejeição de calor e de potência são brevemente descritos nesta seção.

O segundo capítulo se ocupa da descrição do Problema de Detecção de Acidentes e/ou Transientes em plantas nucleares, oferecendo um panorama contextualizador e de sua importância para a operação segura de centrais nucleares de potência. Este capítulo é precedido e complementado pelo seguinte, o terceiro capítulo, que oferece um histórico da evolução dos sistemas de apoio a operação e o uso de ferramentas de inteligência artificial para este fim.

O quarto capítulo lança as bases teóricas para a Optimização por Colônia de Formigas (*ACO*), fundamentando matematicamente o método, percorrendo sua origem bioinspirada e oferecendo detalhes sobre o funcionamento deste método e um comparativo para abordagens em meios discretos, que oferecerá um entendimento inicial do assunto e a sua adaptação para os meios contínuos que é a variante empregada no presente trabalho.

O quinto capítulo se destina a descrever os eventos postulados, também conhecidos na literatura técnica como acidentes base de projeto, o comportamento das variáveis de estado de uma planta *PWR* típica durante a ocorrência destes eventos. Cabe pontuar que o presente capítulo se limitou aos três eventos selecionados como base de dados para as simulações, a saber o *Blackout*, ou seja, a perda de alimentação elétrica externa, a Ruptura de Tubos dos Geradores de Vapor (*SGTR*) e ao Acidente com Perda de Refrigerante (*LOCA*).

O sexto capítulo descreve o modelo do Problema de Detecção de Acidentes e/ou Transientes, sua base teórica baseado em vetores protótipos, ou centroides das séries temporais representantes dos eventos postulados e como estes são representados no contexto do problema aqui estudado.

O sétimo capítulo trata da implementação computacional do modelo proposto no capítulo anterior, descreve a busca e ajuste pelos vetores protótipos que maximizam as classificações corretas e como o algoritmo aqui proposto se comporta em relação à identificação de um evento fora da base de dados.

No oitavo capítulo os experimentos para a validação do modelo e da implementação computacional são descritos bem como se oferece uma análise dos resultados salientando os pontos vantajosos do método e também descrevendo suas limitações e necessidades de refino em termos algorítmicos e de modelagem propriamente dita.

Por fim segue-se o nono capítulo no qual as conclusões são expostas bem como as sugestões para prosseguimento da presente pesquisa.

CAPÍTULO 2

O PROBLEMA DE DETECÇÃO DE ACIDENTES EM CENTRAIS NUCLEARES (*PDA*)

O problema de detecção de acidentes em centrais nucleares é uma questão cujos pesquisadores vêm se debruçando há tempos, os operadores, por mais intenso que seja o seu treinamento, estão expostos à uma imensa carga cognitiva e tal fato tem potencial para comprometer sua capacidade de decisão em situações que demandam ações imediatas para reverter a tendência de um evento de levar à degradação as condições de segurança da usina ou ao menos mitigar as consequências desta ocorrência adversa.

A concepção de uma ferramenta computacional capaz de identificar uma condição adversa ou um evento em curso, seja ele um acidente ou transiente, economiza o tempo que o operador dedicaria a identificar tal condição e corrigir o curso destes eventos evitando danos às instalações, aos indivíduos ou ao público em geral. Diversas técnicas computacionais avançadas vêm sendo empregadas com este objetivo. A importância destes sistemas de apoio à operação também reside no fato de que um diagnóstico equivocado da condição ou da evolução dos estados da planta, podem levar à decisões que culminem em ações que podem elevar o nível de degradação dos sistemas e potencializar de forma irreversível suas consequências. Um célebre evento em que isto aconteceu se deu na central nuclear de *Three Mile Island (TMI)* nos Estados Unidos, onde um problema mecânico relativamente simples, a falha do fechamento de uma válvula de alívio, resultou na perda de refrigerante do reator. Tal evento fora mal interpretado pela equipe da sala de controle e as equivocadas ações subsequentes levaram à fusão parcial do núcleo do reator da unidade 2 desta central nuclear.

As tarefas demandadas pela equipe da sala de controle em situações anormais e de emergência são de elevada complexidade tanto pela dimensionalidade do espaço de

busca quanto pela dificuldade de monitoração das numerosas variáveis associadas ao evento em curso. Tais tarefas neste contexto caracterizam um problema prático da engenharia nuclear conhecido como O Problema de Identificação e Diagnóstico de Eventos Anormais/Transientes/Acidentes em uma Usina Nuclear (*PDA*) que, conforme mencionado anteriormente, é objeto de interesse de inúmeras pesquisas na área há décadas (NICOLAU,2010).

CAPÍTULO 3

UM BREVE HISTÓRICO DO DESENVOLVIMENTO DOS SISTEMAS DE APOIO AO OPERADOR

Os sistemas de suporte à operação em usinas nucleares se destinam principalmente a detectar e isolar falhas que por sua vez representam um desvio da condição esperada de determinado equipamento ou sistema integrante da planta. Nesta categoria podem ser incluídos os acidentes base de projeto, também chamados de acidentes ou eventos postulados, transientes operacionais ou eventos desconhecidos. Estas falhas podem ser detectadas em tempo real por meio de indicações dos sistemas de monitoramento e o isolamento destas falhas consiste em determinar sua localização e seu tipo além de relacioná-la ao equipamento, instalação ou subsistema que apresenta comportamento alterado ou não consistente com a condição considerada normal.

As variáveis de processo de uma usina nuclear, quando em operação normal, apresentam padrões muito bem definidos que são apresentados em geral na forma de curvas dependentes do tempo, de modo que, na ocorrência de uma anormalidade esta pode ser identificada pela sua dissimilaridade com o padrão operacional considerado normal.

Conforme citado anteriormente, uma central nuclear é composta de centenas de subsistemas o que pode totalizar milhares de equipamentos e sensores, portanto a seleção das variáveis de interesse se mostra naturalmente bastante desafiadora em função de seu elevado número, ou seja, matematicamente se trata de um problema de elevada dimensionalidade.

O *PDA* tem sido tratado pelos pesquisadores através de sistemas que se utilizam das curvas, ou assinaturas dos eventos postulados, sejam acidentes ou transientes, para que se identifiquem as características específicas de cada um destes de

modo que sirvam de parâmetro para identificar e classificar um evento em curso. A identificação do evento em curso indica as ações que a equipe de operação deve tomar, que em geral, são objetos dos diversos procedimentos operacionais devidamente validados com base nas especificações técnicas e no conhecimento do comportamento dos equipamentos e sistemas que compõem a planta.

Os modelos mais recentes de sistemas de apoio ao operador são baseados na resolução do problema de separação dos dados da evolução temporal das variáveis de estado da planta em classes, buscando identificar o nível de similaridade entre estas para deste modo diagnosticar uma falha.

Definem a robustez e viabilidade destes sistemas a sua rapidez, sua confiabilidade na presença de ruídos e sua capacidade de reconhecer que um evento em curso não está dentre as classes de sua base de dados, em outras palavras, ser capaz de dar uma resposta “não sei” frente a um evento desconhecido.

Desde algum tempo, as técnicas de Inteligência Artificial (*IA*) têm sido empregadas na obtenção dos modelos destes sistemas de apoio com a finalidade de contornar a vastidão e a complexidade do espaço de busca, que por sua natureza, não permite o emprego de técnicas computacionais clássicas dado que estas exigiriam um custo computacional impraticável para estes fins.

Em 1992, surgiu um dos primeiros modelos de sistemas de suporte baseados em *IA*, sendo mais específico, em Redes Neurais Artificiais (*RNA*) intitulado “*Nuclear Power Plant Diagnostics Using an Artificial Neural Network*” (BARTLETT & UHRIG,1992). Já em 1994 o trabalho anterior foi aperfeiçoado por BASU e BARTLLET em seu trabalho “*Deteting Faults in a Nuclear Power Plant by Using a Dynamic Node Architecture Artificial Neural Network*”, onde identificavam 27 transientes de um reator *BWR* (*Boiling Water Reactor*), usando 97 variáveis de processo de planta a partir de uma arquitetura composta de duas *RNAs*. Em 1995 os pesquisadores BARTAL, LIN e UHRIG, apresentaram em seu trabalho “*Nuclear Power Plant Transient Diagnostics Using an Artificial Neural Networks that Allow Don't*

Know Classifications” um classificador, também baseado em redes neurais, capaz de reconhecer que um evento não estava em sua base de treinamento quando exposto a um novo transiente, este classificador foi utilizado para classificar 72 cenários de 13 diferentes tipos de transientes, a partir do comportamento de 76 variáveis dependentes do tempo, este trabalho foi especialmente importante por introduzir uma espécie de “acumulador de evidências” no qual os resultados de classificações anteriores eram empregados como suporte para classificação final por meio de uma votação majoritária entre os valores obtidos a cada instante.

Em 1996 JEONG, FURUTA e KONDO propuseram um método baseado em redes neurais do tipo “*feedforward*” capaz de identificar transientes diversos, avaliar transientes do mesmo tipo, distinguindo-os por seus níveis de severidade. ROVERSO em 1998 desenvolveu dois métodos baseados em agrupamento de padrões, ou no jargão de ciência de dados, “*clustering*”, um deles empregando conjuntos nebulosos e outro em redes neurais. Estes se mostraram capazes de avaliar a distância entre as classes dos conjuntos de treinamento e as amostras. Um terceiro método apresentado por este, consistia em um “*Classificador de Elman*” (uma *RNA* especial) que lidava com séries temporais dispensando o agrupamento de padrões, cabe pontuar que esta última obteve desempenho superior ao das outras duas.

Ainda em 1998 o método denominado “Conjunto Mínimo de centroides (CMC)” fora proposto por PEREIRA, SCHIRRU e MARTINEZ que, por meio de um algoritmo genético, particiona o espaço de busca do problema para encontrar subconjuntos das classes, definidos como subclasses, cujos centroides, representam as classes com o máximo número de classificações corretas.

Desde então foram desenvolvidas várias metodologias e abordagens para o *PDA*, em 2014 NICOLAU apresentou um modelo baseado em um algoritmo de inspiração quântica *QDA* (*Quantum Evolutionary Algorithm*) para o *PDA* que tem como particularidade apresentar uma abordagem nova para que o sistema fosse capaz de dar a resposta “não sei” sem a necessidade de um evento que desencadeasse a condição

anormal de uma planta, tal método determina as zonas de influência dos centroides, ou protótipos dos eventos postulados.

CAPÍTULO 4

A OTIMIZAÇÃO POR COLÔNIA DE FORMIGAS (ACO)

A otimização por colônia de formigas é inspirada no comportamento forrageiro das formigas, esta formulação foi proposta por DORIGO & GAMBARDELLA com o objetivo inicial de resolver problemas combinatoriais de otimização em domínios discretos do tipo *NP-Difícil*, ou seja, problemas que não são solucionáveis em tempo polinomial (DEAN, 2021), logo uma abordagem heurística é mais indicada para a obtenção de soluções aproximadas de qualidade razoável em tempo computacional viável.

Os problemas combinatoriais, como o que o método apresentado neste documento se propõe a resolver aproximadamente, se destina a encontrar permutações ou combinações dentre os entes envolvidos no referido problema. Em um contexto onde muitas variáveis estão envolvidas, o número de combinações ou permutações a serem analisadas torna proibitivo o emprego de técnicas clássicas, portanto é necessário que o problema seja particionado em um conjunto finito de componentes, assim o algoritmo de otimização combinatoria tenta encontrar sua combinação ou permutação ideal.

Muitos problemas práticos de engenharia nuclear (e de outros campos) especificamente o *PDA* e o Problema da Recarga de Reatores requerem uma abordagem combinatorial que trata de variáveis contínuas e o modelo de Colônia de Formigas apresentado aqui se propõe a solucionar este tipo de problema.

4.1 A Otimização por Colônia de Formigas para domínios discretos

O método, como seu nome sugere, é inspirado no comportamento forrageiro das formigas em sua busca por alimentos. Quando em busca de comida, as formigas inicialmente exploram áreas adjacentes ao seu ninho de maneira aleatória. Logo que

uma formiga encontra uma fonte de alimento, ela a avalia e leva um pouco de comida de volta para o ninho. Durante a viagem de volta, a formiga deposita uma trilha de feromônios no chão. O feromônio depositado, o cuja quantidade pode depender do volume ou da qualidade da comida, orienta outras formigas até a fonte. Em 1989 GOSS *et al.* demonstrou a comunicação indireta entre formigas por meio de trilhas de feromônio que as permitem encontrar caminhos mais curtos entre seu ninho e fontes de alimento. Esta capacidade de real colônias de formigas inspirou os algoritmos de otimização por colônias de formigas que, por sua vez, são capazes de encontrar soluções aproximadas para os problemas combinatoriais do tipo NP-Difícil.

Um modelo para o problema combinatorial típico consiste em:

$$P=(S, \Omega, f) \text{ com } f: S \rightarrow \mathbb{R}_0^+ \quad (4.1)$$

onde:

- S é um espaço de busca definido para um conjunto finito de variáveis decisórias discretas;
- Ω é um conjunto de restrições entre as variáveis do espaço de busca;
- f é a função objetivo, normalmente, a ser minimizada.

O espaço de busca S pode ser definido no seguinte contexto: dado um conjunto de variáveis discretas X_i , com $i = 1, 2, 3, \dots, n$ onde são atribuídos a estas variáveis valores $v_i^j \in D_i = \{v_i^1, v_i^2, \dots, v_i^{|D_i|}\}$ tal atribuição é denotada por $X_i \leftarrow v_i^j$. Uma vez que $s \in S$ é uma solução viável do Problema de Otimização Combinatorial (*COP*) em questão, então há um valor da variável v_i^j que satisfaz todas as condições restritivas dadas por Ω .

Um máximo global é a solução $s^* \in S$ se, e somente se, $f(s^*) \leq f(s) \quad \forall \quad s \in S$. O conjunto de todas as soluções ótimas globais é denotado por $S^* \subseteq S$. A resolução de um Problema de Otimização Combinatorial requer encontrar pelo menos um $s^* \in S$.

O modelo de um *COP* é utilizado para obter o modelo de feromônio usado pelo *ACO*. Inicialmente, uma variável de decisão instanciada $X_i = v_i^j$ (ou seja, uma

variável X_i com um valor v_i^j atribuído a partir de seu domínio D_i) é chamada de componente da solução e é denotada por c_{ij} . O conjunto de todos os possíveis componentes da solução é denotado por C . Um parâmetro de trilha de feromônio T_{ij} é então associado a cada componente c_{ij} . O conjunto de todos os parâmetros de trilha de feromônio é denotado por T . O valor de um parâmetro de trilha de feromônio T_{ij} é denotado por s_{ij} (e chamado de valor de feromônio). Este valor de feromônio é então utilizado e atualizado pelo algoritmo *ACO* durante a busca. Ele permite modelar a distribuição de probabilidade de diferentes componentes da solução.

4.2 A Descrição da Metaheurística do *ACO*

O vocábulo “heurística” deriva do verbo grego *heuriskein*, que significa “achar” ou “descobrir”. Atualmente, a heurística é definida como um grupo de técnicas, que melhoram o desempenho de métodos de solução de problemas”. Para GÜNDRA *et al.* (2002), métodos heurísticos são algoritmos que não fornecem necessariamente uma solução ótima, mas permitem chegar, por meio de cálculos, a uma solução aceitável, dentro de um período de tempo razoável. Segundo FIEDLER, GREISTORFER e VOSS (2004), em geral pode-se entender a heurística como um método de solução de problemas que permite achar soluções boas com custos aceitáveis.

O modo como os algoritmos baseados em colônias de formigas funcionam, seguem o fluxo de operações ilustrado na figura 1.

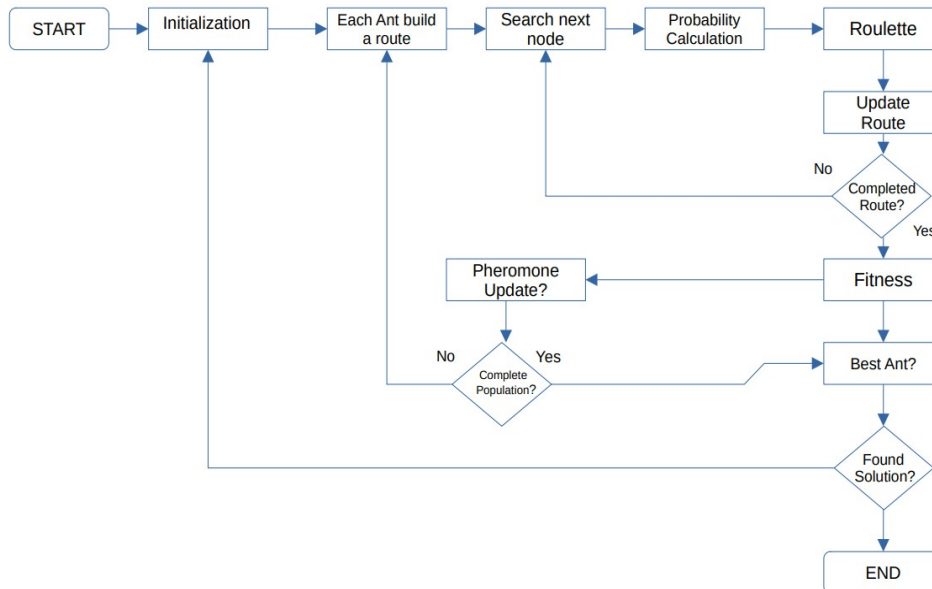


Figura 2: Fluxograma do Algoritmo da Colônia de Formigas

De modo genérico, o exposto na figura 2, representa a *ACO* tanto para meios discretos, como originalmente fora concebido, quanto para meios contínuos, o que caracteriza cada um dos casos é o mecanismo de busca, podendo ser nós de um grafo no contexto dos espaços de busca discretos ou pontos que satisfaçam uma função de adequação em um espaço contínuo, as regras de transição, a distribuição e atualização de feromônios também guardam suas especificidades a depender do contexto do problema que será solucionado.

No contexto da *ACO*, as formigas são classificadas como sistemas computacionais que simulam o comportamento forrageiro descrito na seção 4.1, que na prática cada uma destas executa uma série de tarefas relativamente simples como:

- Mantém uma memória dos lugares já visitados (capacidade de memória);
- Move-se aplicando uma Regra de Transição de Estado;
- Depois de cada movimento atualiza o espaço de busca localmente aplicando uma Regra de Atualização local;
- Depois de gerar uma solução completa, atualiza globalmente o espaço de busca aplicando uma Regra de Atualização Global.

As formigas vão construindo suas soluções vagando de ponto a ponto seguindo regras de decisão bem definidas de modo que suas opções estejam contidas no conjunto de componentes disponíveis, cuja definição pode variar conforme as características do problema a ser resolvido, conforme as formigas vão construindo suas soluções, depositam o feromônio que influenciará a decisão das formigas seguintes.

As formigas artificiais constroem soluções a partir de sequências de componentes retirados de um conjunto finito de n componentes disponíveis da solução $C=\{c_{ij}\}$. A construção de uma solução começa com uma solução parcial vazia $s^p=\emptyset$. A cada geração é adicionado a este conjunto um elemento dentro do conjunto de soluções viáveis, isto define o mecanismo do *ACO* para construção de soluções.

A regra de transição da posição atual da formiga para a seguinte, em geral é dada por regras probabilísticas que são função do feromônio e da visibilidade das opções dos pontos seguintes conforme a equação 4.2.1:

$$p(c_{ij}|s^p) = \frac{\tau_{ij}^\alpha \eta(c_{ij})^\beta}{\sum_{c_{ij} \in N(s^p)} \tau_{ij}^\alpha \eta(c_{ij})^\beta}, \quad \forall c_{ij} \in N(s^p) \quad (4.2.1)$$

onde o termo τ_{ij} representa o feromônio associado ao componente c_{ij} e η é a ponderação da próxima etapa que em geral é proporcional ao inverso da distância (grandeza que se busca minimizar) à posição atual da formiga dentre as posições posteriores que são viáveis contidas no seu respectivo conjunto ($c_{ij} \in N_s(s^p)$). A esta altura cabe informar que o parâmetro α controla a atração das formigas para a melhor posição encontrada até então e β controla a diversificação, isto é, a exploração aleatória no espaço de busca, ou seja, a busca por novas soluções.

A atualização do feromônio tem por objetivo reforçar, o que se traduz em aumentar a probabilidade de escolha em soluções promissoras enquanto as soluções piores recebem menos deste parâmetro até que decresçam e as torne menos prováveis de

serem escolhidas. É comum nas variantes do *ACO* que as soluções consideradas menos atrativas recebam uma penalização que pode ser traduzida como a evaporação do feromônio de modo que a regra para atualização deste é como se segue:

$$\tau_{ij} = \begin{cases} (1 - \rho)\tau_{ij} + \rho \Delta \tau & \text{para } \tau_{ij} \in s_{ch} \\ (1 - \rho)\tau_{ij} & \text{caso contrário} \end{cases} \quad (4.2.2)$$

Neste caso, s_{ch} é a melhor solução até o momento. Ainda sobre a equação 4.2.2, o parâmetro ρ é um número pertencente ao intervalo $[0,1]$ e representa a taxa de evaporação do feromônio que tem a finalidade de prevenir a convergência prematura do algoritmo.

Uma das principais diferenças entre os algoritmos de otimização baseados em colônia de formigas reside nas regras para atualização de feromônios que terão impacto no quanto rápido a convergência será alcançada.

4.3 O *ACO* para domínios contínuos

Conceitualmente há poucas diferenças entre o modelo da *ACO* de meios discretos e meios contínuos, mas estas poucas diferenças são significativas e residem no modo como o feromônio é representado e na regra de transição que, neste caso, é regida por uma função densidade de probabilidade.

Em meios contínuos, em vez das formigas percorrerem um grafo com nós e arestas bem definidos, elas se movem dentro de um espaço contínuo de possíveis soluções, neste trabalho esta representação consta como um vetor de variáveis reais. Aqui, conforme relatado em seções anteriores, feromônio é representado como uma função contínua ou uma distribuição probabilística sobre o espaço de busca. Essa distribuição indica as regiões mais promissoras deste espaço nas quais as formigas têm maior probabilidade de encontrar boas soluções (SOCHA & DORIGO, 2006).

De modo semelhante ao caso dos domínios discretos, o problema de otimização combinatorial, formalmente consiste em:

$Q=(S, \Omega, f)$, onde: S é um conjunto de variáveis contínuas decisórias, Ω é um conjunto de restrições e $f: S \rightarrow \mathbb{R}^0_+$ a função a ser minimizada. As considerações sobre as atribuições das variáveis, as restrições, máximos e mínimos locais e globais são as mesmas para o modelo discreto, sendo a única diferença a natureza contínua das variáveis envolvidas. A escolha da formiga neste contexto é governada por uma função densidade de probabilidade (*FDP*) que, associada a uma função de distribuição cumulativa (*FDA*) define esta escolha.

4.3.1 Funções Densidade de Probabilidade (*FDP*) e Funções Distribuição Acumulada (*FDA*)

A *FDP*, representada por $f(x)$, descreve a densidade da probabilidade de ocorrência de uma variável contínua, o que descreve a probabilidade em si da variável em questão é área sob a curva da *FDP* em um determinado intervalo. Observando as definições discutidas a *FDP* é tal que:

$$\int_{-\infty}^{\infty} f(x) dx = 1, \text{ com } f(x) \geq 0 \quad \forall x \quad (4.3.1)$$

Logo a *FDA*, denotada por $F(x)$ é tal que:

$$f(x) = \frac{d}{dx} F(x) \quad (4.3.2)$$

De modo resumido, uma variável contínua X tem a probabilidade de ocorrer no intervalo $[a, b]$ é dada por : $P(a \leq X \leq b) = \int_a^b f(x) dx$.

No presente trabalho a *FDP* empregada foi a distribuição gaussiana que, dotada de propriedades matemáticas tais quais a simetria em torno da média, as relações entre a média e o desvio padrão capazes de as descreverem completamente, mas sua principal desvantagem é de não ser empregável em distribuições nas quais o domínio possui subconjuntos promissores em termos de qualidade de soluções no espaço de busca que são disjuntos (BOX *et al*, 2005), isto acontece desta forma porque a gaussiana clássica possui apenas um máximo, para contornar este inconveniente

SOCHA & DORIGO (2006) propuseram um *kernel* gaussiano que consiste em uma soma ponderada de várias funções gaussianas unidimensionais denotadas por $g^i_k(x)$. Isto posto, um kernel gaussiano $G^i(x)$ pode ser definido como se segue na equação 4.3.3.

$$G^i(x) = \sum_{l=1}^k \omega_l \frac{1}{\sigma_l} e^{-\frac{(x-\mu_l)^2}{2\sigma_l^2}} = \sum_{l=1}^k \omega_l g^i_l(x) \quad (4.3.3)$$

Observando a equação 4.3.3, assume-se que o número de *PDF's* do *kernel* gaussiano $G^i(x)$ é igual ao número de dimensões do problema ($i=1, 2, \dots, n$) e é parametrizado pelos vetores ω dos pesos associados a cada uma das funções gaussianas individuais $g^i_k(x)$, pelo vetor das médias μ^i e pelo vetor dos desvios-padrão, por sua vez denotado por σ^i . Para fins de conveniência, estabelece-se o parâmetro k , tal que $|\omega| = |\mu^i| = |\sigma^i| = k$.

A justificativa para se usar um kernel gaussiano em vez de uma única PDF é sua maior flexibilidade, as regiões do espaço de busca são exploradas de modo mais efetivo em todo o seu potencial.

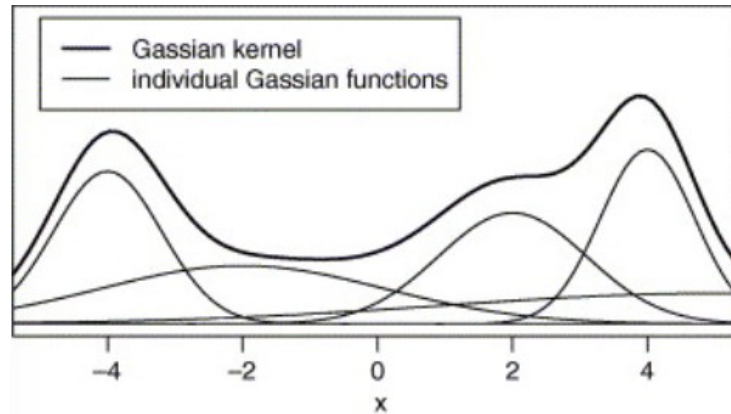


Figura 3: Comparativo entre um *Kernel* Gaussiano e as funções Gaussianas individuais que o compõe (SOCHA & DORIGO, 2006)

A figura 3 ilustra qualitativamente as vantagens de se empregar um *kernel* Gaussiano em vez de uma função gaussiana individual, nota-se que individualmente há várias regiões disjuntas no espaço de busca com bons potenciais de resultado, entretanto o emprego individual destas limitaria as soluções aos seus máximos locais e sua

amostragem não traduziria efetivamente a qualidade das regiões do espaço de busca, o emprego do *kernel* contorna tal limitação pois abarca os máximos locais destas gaussianas individuais tornando a busca menos enviesada.

4.3.2 Representação do Feromônio em ACO para meios contínuos

No contexto dos domínios contínuos as informações do feromônio constam em uma tabela específica que é atualizada a cada iteração quando a escolha do componente a ser incrementado à solução parcial é feita conforme a equação 4.2.1 considerando o fato de não se tratar, neste caso, conforme a figura 4, de probabilidades discretas (a) mas contínuas(b).




Figura 4: Distribuição de probabilidades Discretas (a) e Contínuas (b)

No caso da distribuição contínua (figura 4.b), a tabela de feromônios é atualizada baseada nos componentes de boas soluções encontradas de acordo com a função objetivo, neste caso um certo número de soluções é armazenado, isto é, os valores das variáveis e suas respectivas avaliações segundo esta função objetivo, então as soluções mais antigas, ou seja, as menos adequadas segundo esta mesma função são paulatinamente eliminadas do arquivo conforme as gerações progridem, filosoficamente esta abordagem têm o mesmo sentido da definição de feromônio e sua evaporação para o caso do problema combinatorial para meios discretos. Para o funcionamento do modelo demanda-se que se mantenha o registro da série de soluções em um arquivo de soluções designado T , cuja representação estrutural consta na figura 5, no qual estarão armazenados os valores de todas as variáveis envolvidas (n para o problema n -

dimensional) e sua correspondência com a função objetivo ($f(s_l)$) sendo s_l^i a l -ésima solução para a i -ésima variável.




Figura 5: Esquemático da estrutura do arquivo de soluções T

Assumindo que se trate de um problema de minimização, as soluções são ordenadas no arquivo T conforme sua qualidade, de modo que $f(s_1) \leq f(s_2) \leq f(s_3) \leq \dots \leq f(s_l) \leq \dots \leq f(s_k)$, cada uma destas soluções possui um peso associado ω de tal maneira que $\omega_1 \geq \omega_2 \geq \omega_3 \geq \dots \geq \omega_l \geq \dots \geq \omega_k$ então a FDP para G^i , ou seja o kernel associado a este problema é construído empregando apenas as primeiras i -ésimas coordenadas de todas as k soluções deste arquivo e, em última análise, este parâmetro definirá a complexidade da FDP do kernel formado já que existirão k funções gaussianas para compor a FDP deste e, para cada dimensão $i = 1, 2, \dots, n$ do problema haverá um kernel G^i diferente (ver figura 5), portanto os valores da i -ésima variável de todas as soluções em T tornam-se elementos do vetor μ^i conforme a equação 4.3.3:

$$\mu^i = \{\mu_1^i, \dots, \mu_k^i\} = \{s_1^i, \dots, s_k^i\} \quad (4.3.3)$$

No caso da ACO para meios contínuos, o que foi explicitado no parágrafo anterior culmina no fato de se gerar dinamicamente FDP 's com base no conjunto de soluções armazenadas no arquivo T . O kernel gaussiano formado, conforme definido anteriormente, é parametrizado pelos vetores ω , μ^i e σ^i e estes por sua vez são

calculados conforme os valores armazenados no arquivo T de soluções, e, uma vez gerado, este *kernel* é responsável por guiar as formigas no processo de busca.

O vetor paramétrico dos pesos, ω , é obtido pela classificação das soluções no arquivo T , então, assumindo que cada solução s_l tem classificação l , o peso desta é calculado conforme a equação 4.3.4:

$$\omega_l = \frac{1}{qk\sqrt{2\pi}} e^{\frac{-(l-1)^2}{2q^2k^2}} \quad (4.3.4)$$

Onde q é um parâmetro do algoritmo que, quando pequeno, as soluções são fortemente preferidas e quando grande, tende a uniformizar a probabilidade. Conceitualmente este parâmetro ajusta o equilíbrio entre as atualizações do feromônio da melhor da geração atual e a melhor dentre todas até esta.

Antes de definir a obtenção do vetor dos desvios-padrão σ^j , uma vez definidos os elementos do vetor peso ω , procede-se com a escolha de uma das gaussianas que compõem o *kernel*, a a probabilidade de escolha da l -ésima função é dada pela equação 4.3.5:

$$p_l = \frac{\omega_l}{\sum_{r=1}^k \omega_r} \quad (4.3.5)$$

Em seguida, amostra-se a função gaussiana escolhida através de um gerador de números aleatórios de acordo com uma distribuição normal parametrizada. Nesta etapa o desvio padrão é conhecido para uma única função, logo o vetor de desvios-padrão não precisa ser calculado em sua totalidade, basta apenas obter o σ_l^j para a função gaussiana escolhida. A escolha da l -ésima função gaussiana é feita uma vez por uma formiga em uma iteração, isto é, uma formiga usa as funções gaussianas associadas à uma única solução inteira em uma dada iteração. Uma consequência disso é que a função gaussiana amostrada é diferente em cada etapa da construção e, para cada etapa i , μ_l^i , s_l^i e σ_l^i é calculada em cada etapa a distância média entre solução escolhida s_e^i e as demais e multiplicando pelo fator ζ que faz as vezes da taxa de evaporação de feromônio e é o mesmo para todas as dimensões do problema, logo σ_l^i é dado pela equação 4.3.6:

$$\sigma_l^i = \zeta \sum_{e=1}^k \frac{|s_e^i - s_l^i|}{k-1} \quad (4.3.6)$$

Cabe pontuar que, quanto maior for o parâmetro ζ menor será a velocidade com a qual o algoritmo converge, no caso da *ACO* para meios discretos, a taxa de evaporação do feromônio influencia a memória de longo prazo (soluções piores são esquecidas mais rapidamente), ζ define o modo como a memória de longo prazo é utilizada, em outras palavras, deixa a busca menos tendenciosa às regiões do espaço de busca já exploradas o que favorece à exploração em detrimento da exploração.

4.4 Funções Contínuas para testes de Otimização

A otimização pode ser definida como qualquer processo que busca o máximo benefício segundo algum critério, isto é, trata-se de uma busca por uma condição ou valor ótimo (LEAL, 2007). A modelagem matemática no contexto dos problemas de otimização sempre envolverá pelo menos uma função objetivo a qual se busca minimizar ou maximizar a depender do contexto. A complexidade dos problemas de otimização residem principalmente na dimensionalidade, de modo que, quanto mais elevada, mais complexo o problema tende a se tornar e quando tal problema é multiobjetivo.

Será apresentada nesta seção a aplicação da *ACO* nas funções *Himmelblau*, *Rastrign* e *Rosembrock*, já consagradas na literatura como referência para testes de métodos de otimização.

4.4.1 A Função Himmelblau

Trata-se de uma função polinomial multimodal largamente empregada em testes de desempenho de algoritmos de otimização. Esta função contém um máximo global e quatro mínimos locais idênticos que podem ser encontradas analiticamente:

$$f(x, y) = (x^2 + y - 11)^2 + (x + y^2 - 7)^2 \quad (4.4.1)$$

Esta função tem seus mínimos encontrados em seus zeros: $f(3.0, 2.0)$, $f(-2.805118, 3.131312)$, $f(-3.779310, -3.283186)$ e $f(3.584428, -1.848126)$. Seu gráfico tridimensional pode ser observado na figura 6.

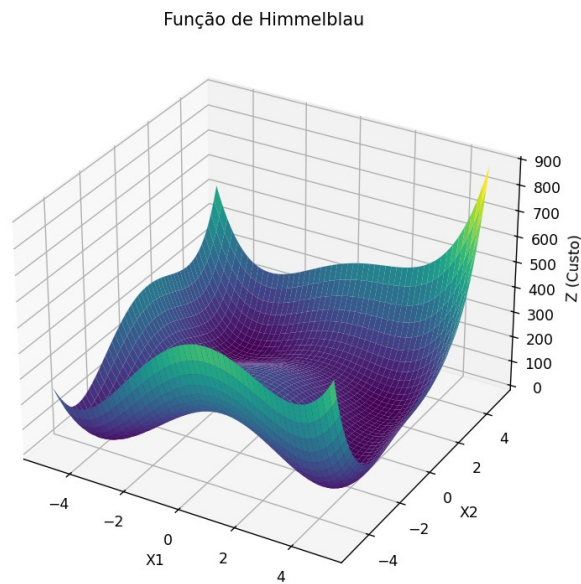


Figura 6: Função de *Himmelblau*

A convergência do *ACO* para meios contínuos empregados neste trabalho pode ser observada na figura 7, onde é possível notar que o algoritmo leva ao resultado ótimo depois de pouco mais de 20 gerações o que comprova a eficácia do método e seu relativo baixo custo computacional.

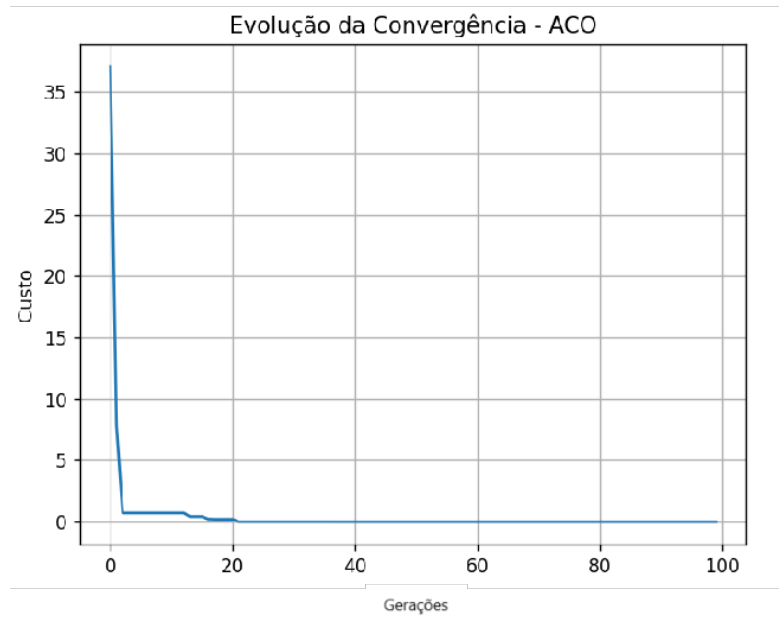


Figura 7: Convergência da Função de *Himmelblau*

4.4.2 A Função *Rosembrock*

A função de *Rosembrock*, assim como a de *Himmelblau* é não convexa e por este motivo, reúne características que a tornam um excelente instrumento para a calibração de modelos e algoritmos de otimização. Esta função tem a forma descrita na equação 4.4.2 como se segue:

$$f(x, y) = (a - x)^2 + b(y - x^2)^2 \quad (4.4.2)$$

Nesta função, o mínimo global está em $f(a, a^2) = 0$ e somente no caso trivial, ou seja, $a = 0$, a função se torna simétrica e o mínimo está na origem. Seu gráfico na forma tridimensional é como se segue na figura 8.

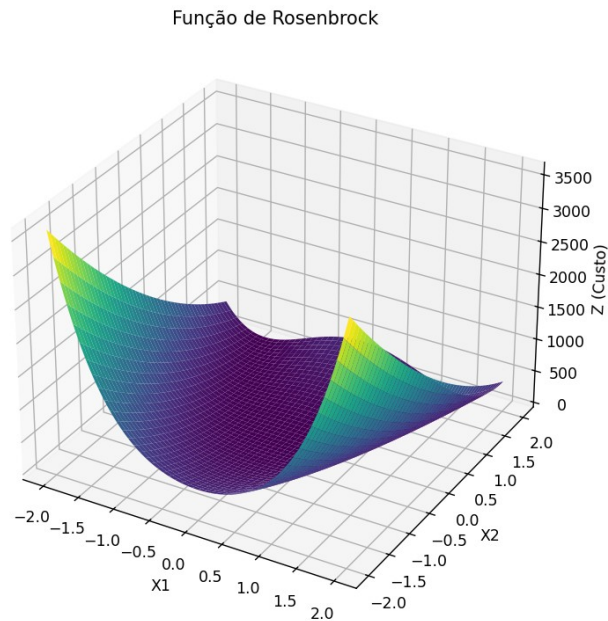


Figura 8: Função de *Rosenbrock*

O emprego do *ACO* para encontrar os mínimos na função de *Rosenbrock* tem sua evolução explicitada na figura 9, assim como na função *Himmelblau*, neste caso foram empregados os mesmos parâmetros da colônia de formigas e a convergência ao valor ótimo ocorreu pouco depois da vigésima geração.

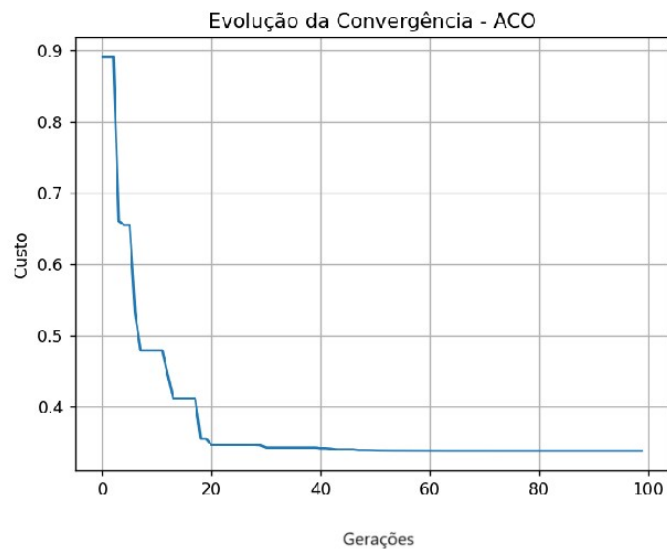


Figura 9: Convergência da Função de *Rosenbrock*

4.4.3 A Função Rastrigin

Esta é a mais complexa das funções para testes em otimizações aqui apresentada, é não-convexa com múltiplos mínimos locais o que a torna uma excelente ferramenta de teste para atestar a robustez do método. Sua forma matemática é como se segue na equação 4.4.3:

$$f(x) = 10n + \sum_{i=1}^n \left(x_i^2 + 10 \cos(2\pi x_i) \right) \quad (4.4.3)$$

onde n é o número de variáveis (dimensões), x_i é a i -ésima variável e o termo $10n$ é uma constante que controla a escala da função, e o termo $10\cos(2\pi x_i)$ adiciona ondulações à função. Seu gráfico na forma tridimensional é como se segue na figura 10.




Figura 10: Função de Rastrigin

A evolução das gerações até a convergência do ACO aplicado à função de Rastrigin consta na figura 11 e onde é possível notar que, a despeito da complexidade da função, o algoritmo converge antes da quadragésima geração, isto denota um custo computacional relativamente baixo.




Figura 11: Convergência da Função de *Rastrigin*

Cabe reforçar que os parâmetros heurísticos e de feromônios empregados nas funções para testes abordadas nesta seção foram os mesmos utilizados nas simulações para a resolução do *PDA* que será abordado nas seções subsequentes.

CAPÍTULO 5

OS ACIDENTES POSTULADOS EM CENTRAIS

PWR

A cadeia industrial nuclear, junto com o setor de aviação, é famosa por seus rígidos padrões de segurança, em todo o seu ciclo, isto é, desde o projeto conceitual até o descomissionamento, as questões envolvendo a segurança operacional, pessoal e ambiental são estudadas à miúdo de modo que os riscos envolvidos em todas as etapas são intensamente minimizados. Para tanto, poderosas ferramentas estatísticas bem como as análises determinísticas são amplamente empregadas afim de se prever o comportamento da planta em condições adversas bem como as consequências destas para o indivíduo público e para o meio ambiente.

As plantas como a de Angra-1, dotadas de um reator *PWR* com dois *loops* dispõem de um conjunto de *Acidentes Postulados*, também chamados de *Acidentes Base de Projeto (DBA)* dos quais, por meio de análises determinísticas, se avaliam os comportamentos da usina, dos seus sistemas e dos equipamentos frente a tais situações de modo a evitar a liberação de material radioativo ao público e ao ambiente. A partir destas análises são estabelecidos os limites seguros para a operação deste tipo de central nuclear (PETRANGELI, 2006; KHATTAK *et al.*, 2018).

Embora o conjunto de acidentes postulados seja numeroso, para fins de contextualização o presente trabalho se limitará a descrição dos três acidentes base de projeto empregados como base para teste do modelo proposto, a saber, o *Blackout*, o *LOCA* e o *SGTR*.

5.1 *Blackout*

O *Blackout* pode ser definido como a perda de fonte externa e interna de energia elétrica, é particularmente importante no contexto de plantas nucleares porque a

grande maioria dos equipamentos empregados são alimentados por eletricidade. Em geral, as instalações possuem redundâncias em termos de alimentação, ou seja, são alimentadas por redes distintas e geradores de emergência para suprimento no caso da queda da rede principal, em outras palavras, este incidente pode ser definido pela indisponibilidade dos equipamentos essenciais da planta, tanto para sua operação quanto para a proteção do núcleo, em função da perda de fonte elétrica externa e interna e a homologação da planta depende da capacidade desta de resistir a tal ocorrência (MAZZONI, 2018).

5.2 LOCA (*Loss of Coolant Accident*)

O *LOCA* consiste em um acidente que envolva a perda de inventário de refrigerante do reator, a escala deste depende diretamente do tamanho da ruptura no circuito primário, ou seja, aquele cujo fluido (a água neste caso) está em contato direto com o núcleo do reator (SEHGAL, 2012).

O processo físico pelo qual um *LOCA* pode condenar o núcleo é a diminuição na taxa de remoção de calor do elemento combustível em função da redução da vazão do refrigerante. Em casos extremos, o elemento combustível superaquece de modo que a sua fusão é uma consequência muito provável. A depender do momento no qual o *LOCA* ocorre, o calor de decaimento dos elementos combustíveis pode ser suficiente para danificá-lo no caso da queda de pressão no circuito primário, o que caracteriza o acidente em questão.

O acidente envolvendo a perda de refrigerante desencadeia uma série de fenômenos físicos tais quais as reações entre o fluido refrigerante e a liga de zircônio do revestimento do combustível que libera H_2 fragilizando-o. O revestimento do elemento combustível pode ser fragilizado pelo acúmulo dos gases de fissão tais quais o I , Kr e Xe , tal acúmulo pode dilatar o elemento alterando adversamente a geometria dos canais de resfriamento potencializando ainda mais a condição de resfriamento do núcleo e no caso do resfriamento não ser reestabelecido, o UO_2 e o revestimento de ZrO_2 se fundem inutilizando de forma permanente o reator (RAGHEB, 2016).

5.3 Ruptura dos Tubos do Gerador de Vapor (SGTR)

Este acidente é caracterizado pelo vazamento de fluido do primário para o secundário, ocorre pelo rompimento de um ou mais tubos do gerador de vapor que fazem a interface de troca de calor entre os circuitos primário e secundário, tal evento resulta em contaminação radiológica para o secundário e potencial liberação de produtos de fissão para o meio ambiente. Para fazer frente a tal ocorrência adversa se faz necessário prover resfriamento adequado ao núcleo e manter equilibradas as pressões entre primário e secundário, uma vez que a primeira é maior, naturalmente o fluido refrigerante, potencialmente contaminado com radioisótopos, fluirá para o segundo (MACDONALD, SHAH, *et al.*, 1996).

CAPÍTULO 6

O MODELO PARA O PROBLEMA DE IDENTIFICAÇÃO DE ACIDENTES E/OU TRANSIENTES

A ideia inicial é classificar um evento anômalo, em relação a assinatura de um conjunto de três condições de acidentes de base de projeto, postulados para uma central nuclear típica *PWR*, a saber o *LOCA* (*Loss of Coolant Accident*), o *SGTR* (*Steam Generator's Tubes Rupture*) e o *BLACKOUT* (*External Power Blackout*), que melhor representa o evento em curso. O modelo aqui descrito 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 indicará a condição de acidente que evento anômalo pertence.

A Otimização por Colônia de Formigas foi utilizada como meio de otimização incumbido de encontrar os melhores centroides, ou seja, os vetores protótipos ótimos para cada classe, de modo que suas posições maximizem o número de classificações corretas. Espera-se que cada um destes centroides seja o melhor representante da 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 conforme pode ser visto na figura 12.




Figura 12: Processo de Classificação (NICOLAU-2014)

Com base em documentos como o *FSAR (Final Safety Analysis Report, 2023)* e em trabalhos como o de NICOLAU (2014) e ALVARENGA (1997) os eventos postulados selecionados para a simulação foram representados por séries temporais de 17 variáveis operacionais consideradas suficientes para a caracterização destes eventos postulados conforme a tabela 1:

Tabela 1: Variáveis de Estado (NICOLAU-2014)

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 importância da resposta “não sei” em um sistema de suporte ao operador reside no fato de evitar que se tomem decisões e ações baseadas em um diagnóstico equivocado, o que poderia se traduzir em uma degradação ainda maior das condições de segurança da planta. NICOLAU (2014) propôs o conceito de zona de influência de um centroide o que permite que o sistema absorva, em certo grau, os eventuais ruídos nas informações, bem como, no caso da ocorrência de um evento fora da base de treinamento, este seja identificado como desconhecido e posteriormente possa ser integrado a base de dados do sistema expandindo a sua capacidade de diagnosticar o estado da planta.

A determinação da “área de influência” de cada centroide empregou como base a teoria de aresta de *Voronoi* (HAYKIN, 1994), uma vez que as posições encontradas pelo *ACO* se comportam como estes vetores, também chamados de pontos geradores, que por definição são aqueles que a distância de um ponto qualquer da região ao redor deste 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 um Diagrama de *Voronoi* como sendo a subdivisão do plano em n regiões, onde cada uma destas é formada pelo lugar geométrico dos pontos mais próximos de cada ponto do conjunto dado conforme a figura 13 (LOPES, 2008).




Figura 13: Diagrama de *Voronoi* (LOPES-2008)

Uma aresta de *Voronoi* é o segmento de linha que separa duas regiões de *Voronoi* adjacentes. Cada região de *Voronoi*, ou célula, é associada a um ponto gerador,

e a aresta de *Voronoi* representa a fronteira onde os pontos do espaço são equidistantes dos dois geradores correspondentes às regiões vizinhas. Essas arestas fazem parte do diagrama de *Voronoi*, que particiona o espaço em regiões baseadas na proximidade a um conjunto de pontos geradores.




Figura 14: Círculos caracterizadores das *Arestas de Voronoi*

Geometricamente, as arestas de *Voronoi* são formadas ao longo dos locais geométricos onde qualquer ponto é igualmente distante de dois pontos geradores específicos. Se três ou mais regiões se encontram, o ponto de interseção das arestas é chamado de vértice de *Voronoi*. Isto implica que duas regiões têm uma aresta em comum, se e somente se, existe um círculo que contém somente os dois geradores destas regiões conforme pode ser observado na figura 14.

As definições acima foram aplicadas à base de dados para a obtenção das zonas de influência de cada um dos centroides dos eventos postulados empregados nesta simulação. Duas zonas de influência possuem um único ponto em comum, isto é consequência das definições apresentadas, se fosse diferente, tais zonas perderiam parte do seu poder de ponderar a classificação do evento em curso e este ficaria dependente somente da distância entre este e o centroide mais próximo.




Figura 15: Representação 2-D das zonas de influência dos centroides (adaptado NICOLAU-2014)

A figura 15 consiste de uma possível representação em duas dimensões das zonas de influência de cada um dos centroides para três eventos postulados e da evolução das variáveis do comportamento normal da planta.

No presente trabalho as zonas de influência serão empregadas como tolerância para o distanciamento dos centroides, esta abordagem trará mais robustez às classificações pois pode ser considerada uma medida de similaridade entre as séries que por sua vez representam o estado da planta em determinado instante.

CAPÍTULO 7

IMPLEMENTAÇÃO COMPUTACIONAL DO MODELO AO PROBLEMA DE DETECÇÃO DE ACIDENTES

O intervalo de tempo total para fins de amostragem de cada um dos eventos postulados foi de 61 segundos, partindo da condição normal de operação em potência, o primeiro segundo corresponde a esta condição, já o instante seguinte corresponde ao desarme do reator. O intervalo de tempo de 61 segundos foi empregado por ser considerado suficiente para a distinção entre os eventos postulados analisados em função da evolução individual das diversas variáveis de estado envolvidas.

Em função das diferentes ordens de grandeza das variáveis envolvidas, os dados empregados passaram por um processo de normalização *MÁX-MIN*. Esta forma de equalização fora escolhida por acomodar distância relativa entre os mais pontos mais próximos embora seja relativamente sensível às distorções provocadas por eventuais *outliers* (PRASAD; BEG, 2009).

O algoritmo carrega as séries conhecidas que consistem nos eventos postulados e a série que será classificada dentre as conhecidas, em seguida, por meio da *ACO* inicia a busca pelos centroides dessas séries de treinamento, isto é, as séries conhecidas, que representam os eventos postulados. A função custo foi concebida para buscar dois objetivos: minimizar a distância do centroide de cada série a cada ponto de sua série correspondente e maximizar o número de acertos reais na classificação da série. Esta descrição ilustra bem a complexidade do problema combinatorial multiobjetivo que por sua vez justifica o emprego de um método heurístico em vez de um clássico, uma vez que o tempo computacional envolvido inviabilizaria a sua resolução.

Em termos gerais, dentro do algoritmo, as formigas são alocadas aleatoriamente dentro do espaço de busca, então começam sua pesquisa por novas posições seguindo a seguinte regra:

$$x_{ij+1} = x_{ij} + \alpha \rho (1 - \zeta) (x_b - x_{ij}) + \beta \eta_0 e^{-\lambda i} r \quad (7.1)$$

Onde:

x_{ij+1} é a nova posição da formiga;

x_{ij} é a posição atual da formiga;

α representa a influência do feromônio;

ρ representa a evaporação do feromônio;

ζ representa a quantidade inicial de feromônio;

x_b é a melhor posição encontrada até a então;

β representa a informação heurística do problema;

η_0 representa a importância inicial da informação heurística;

λ é a constante de decaimento da influência heurística;

r é uma perturbação aleatória adaptativa que diminui conforme as gerações forçando uma exploração mais ampla no início da busca.

Para simular a condição normal da planta, assumindo que são esperadas pequenas flutuações em cada um dos parâmetros, foram implantados pequenos ruídos aleatórios de $\pm 1,0\%$ para simular esta condição que fora inserida na base de referência para as condições postuladas. A métrica empregada para avaliar o comportamento da função custo foi o erro relativo das classificações (ver equação 7.2), busca-se minimizar esta função pela busca dos centroides mais representativos para cada evento postulado, esta medida serve também para avaliar o quanto o evento em curso é similar ao evento postulado correspondente constante na base de treinamento do algoritmo.

$$E_{relativo} = Class_{totais} - Class_{corretas} \quad (7.2)$$

onde:

$Class_{totais}$ = instantes analisados x num de eventos base

$Class_{corretas}$ = acertos dentro da classe esperada

Em resumo a implementação do modelo proposto inicialmente recebe os dados dos eventos postulados para constituir sua base, em seguida inicializa os centroides, após isto, recebe os dados do evento em curso e os compara, linha a linha, o que neste contexto significa instante a instante, com os vetores obtidos pela *ACO*, elegendo o mais similar, ou seja, o mais próximo para aquele instante, classificando-o segundo esta classe, ou evento postulado da base de dados, ao final do processo, considerando a evolução da planta pelo período de 60s, finalizadas as classificações, os centroides finais são novamente comparados a cada instante do evento em curso de modo a avaliar se o vetor protótipo gerado de fato traduz a condição da planta. Para validar o modelo foram testados diferentes parâmetros para várias sementes aleatórias conforme explicitado no próximo capítulo.

CAPÍTULO 8

RESULTADOS E DISCUSSÕES

Foram executados 30 experimentos e resultados ótimos, ou seja, com 100% de classificações corretas, em média foram alcançados dentro de 30 à 60 gerações, isto constitui um indicativo forte da eficiência do método se comparado aos outros algoritmos bioinspirados empregados na resolução do *PDA*. A tabela 2 mostra a influência da variação dos diversos parâmetros da *ACO* na evolução desta implementação bem como seu impacto no custo computacional na execução do algoritmo.

8.1 Experimentos de Identificação e Classificação

É necessário pontuar que os testes para cada um dos acidentes postulados aqui analisados sofreram perturbações aleatórias de $\pm 2\%$ com o objetivo de aumentar a diversidade do banco de dados e portanto testar a robustez do método.

Tabela 2: Experimento de Identificação de *LOCA*'s

Experimentos para identificação de <i>LOCA</i> 's										
Teste	Formigas	ρ	α	β	η_0	λ	Semente	Acertos Iniciais(%)	Reclassificação (%)	Gerações
1	50	0.5	1,0	2,0	0.1	0.1	1234	43	100	31
2	100	0.5	1,0	2,0	0.1	0.1	5678	45	100	27
3	50	0.1	1.2	0.9	0.1	0.1	9101	48	100	47
4	50	0.2	2,0	0.8	0.1	0.1	1211	43	100	38
5*	100	0.5	1.5	2.5	0.1	0.1	3141	32	32	-

*O sistema classificou com "Desconhecido"

Para diversos *LOCA*'s com perturbações aleatórias de $\pm 2\%$ o equilíbrio entre exploração e exploração traduzidos respectivamente pelos parâmetros α e β influenciam diretamente na capacidade do algoritmo de encontrar as melhores soluções com o menor custo computacional. Conforme explanado na seção anterior, o custo, avaliado no

período da busca pelos centroides que melhor representam cada um dos eventos postulados são funções da quantidade de acertos descrito pela equação 7.2, o comportamento do algoritmo até encontrar o melhor centroide nesta fase pode ser observado nas figuras 16, 17, 18, 19 e 20.




Figura 16: Custo x Gerações- LOCA-1

A comparação da figura 16 com a figura 17 deixa clara o retardo da convergência da *ACO* em função do número de agentes, no caso, as formigas, no algoritmo, isso ocorre porque mais agentes exploram mais o espaço de busca, isso se traduz em uma convergência um pouco mais precoce quando comparada com o teste anterior, mas isto sacrificou a qualidade da solução já que na primeira fase da execução o algoritmo obteve um número menor de acertos. Os testes cujos resultados estão ilustrados nas figuras 16 e 17 mantêm comparativamente as relações entre os parâmetros de exploração e exploração as mesmas, os impactos observados foram exclusivamente devidos a diferença no número de agentes (formigas).




Figura 17: Custo x Gerações - LOCA- 2

Os dois testes subsequentes consistiram de variações significativas na relação entre α e β onde no segundo caso a influência exploratória sobrepujou a influência heurística conforme observado nas figuras 18 e 19 que, respectivamente representam o terceiro e quarto experimentos.




Figura 18: Custo x Gerações- LOCA 3

O teste referente a figura 18 foi feito com um relativo equilíbrio entre as influências exploratórias e heurísticas, a convergência foi observada após um número maior de gerações ao mesmo tempo a qualidade da solução foi inferior quando comparada ao experimento seguinte.

A figura 19 ilustra o comportamento do 4º teste para o *LOCA* onde a discrepância entre as influências exploratórias e heurísticas foi a maior entre os experimentos. O termo exploratório com mais peso, no caso deste espaço de busca e das características dos dados de entrada apresentou uma convergência mais precoce e qualidade superior da solução encontrada.




Figura 19: Custo x Gerações - *LOCA* 4

Os testes para reconhecimento dos eventos *SGTR* e *Blackout* foram realizados com variações dos parâmetros da *ACO* idênticas às empregadas para a análise dos diversos *LOCAs* expostos ao longo desta seção conforme as tabelas 3 e 4.

Tabela 3: Experimentos de Identificação: *Blackouts*

Experimentos para identificação de <i>Blackouts</i>										
Teste	Formigas	ρ	α	β	η_0	λ	Semente	Acertos Iniciais(%)	Reclassificação (%)	Gerações
1	50	0.5	2,0	2,5	0.1	0.1	1234	93	100	43
2	100	0.5	1,0	2,0	0.1	0.1	5678	89	100	47
3	50	0.1	1.2	0.9	0.1	0.1	9101	91	100	47
4	50	0.2	2,0	0.8	0.1	0.1	1211	90	100	39
5	50	0.5	1.5	2.5	0.1	0.1	3141	92	100	42

Observa-se no caso da identificação dos *Blackouts* simulados é que o número de acertos iniciais é significativamente mais elevado que os dos demais eventos postulados, isto se explica pelo fato do comportamento da planta neste caso é dissimilar o bastante dos demais acidentes aqui analisados, a evolução das variáveis termohidráulicas da planta ocorre de modo muito distinto dos demais fazendo com que sua identificação possa ser efetuada com um custo computacional menor e ainda assim apresentar soluções de alta qualidade quando comparadas com a análise dos demais eventos postulados conforme se pode notar na figura 20.




Figura 20: Custo x Gerações - *Blackout 1*

Os resultados para os experimentos de identificação do *SGTR* constam na tabela 4, na qual seu comportamento similar aos dos eventos relacionados ao *LOCA* fica evidente pois ambos implicam, em função de suas próprias naturezas, em intensas flutuações em parâmetros termohidráulicos específicos cuja comparação com qualquer outro evento seja relativamente simples dada a baixa similaridade guardada entre os demais.

Tabela 4: Experimento de Identificação de *SGTR*'s

Teste	Formigas	ρ	α	β	η_0	λ	Semente	Acertos Iniciais(%)	Reclassificação (%)	Gerações
1	50	0.5	1,0	2,0	0.1	0.1	1234	55	100	37
2	100	0.5	1,0	2,0	0.1	0.1	5678	55	100	52
3	50	0.1	1.2	0.9	0.1	0.1	9101	53	100	38
4	50	0.2	2,0	0.8	0.1	0.1	1211	40	100	57
5	50	0.5	1.5	2.5	0.1	0.1	3141	65	100	50

O algoritmo forneceu indicações errôneas nas primeiras gerações justo pela proximidade sintomática deste com o *LOCA* propriamente dita, em termos práticos, o sistema confunde os primeiros sintomas. O comportamento do 4º teste sugere que uma influência exploratória ligeiramente superior a influência heurística obterá os melhores resultados relativos, isto se dá em função da distribuição dos pontos que constituem a base de dados no espaço de busca.




Figura 21: Custo x Geração- *SGTR 4*

A observação da figura 21, objeto de um teste com o evento *SGTR*, sugere uma solução de boa qualidade já que apresentou um custo relativamente baixo e também devido a relativa rapidez com que converge quando comparado às identificações simuladas do evento postulado.

8.2 Experimentos de variação dos parâmetros da *ACO*

A influência dos parâmetros relacionados ao feromônio foi testada conforme o roteiro exposto na tabela 5. Os termos e parâmetros relacionados à regra de transição dos agentes dentro do algoritmo estão diretamente associados ao aprendizado e ao enviesamento controlado da busca dentro do espaço das soluções, que no caso do problema aqui analisado, um hiperespaço com 17 dimensões.

As parcelas relacionadas à evaporação, a deposição e ao decaimento do feromônio, quando equilibradas tendem a armazenar as melhores soluções e descartar as piores segundo a métrica da função custo.

Tabela 5: Variação de Feromônios- Identificação de *SGTR*'s

Teste	Formigas	ρ	α	β	η_0	λ	Semente	Acertos Iniciais(%)	Reclassificação (%)	Gerações
1	50	0.5	1.5	2.5	0.1	0.1	1234	55	100	37
2	100	0.5	1.5	2.5	0.5	0.1	5678	50	100	43
3	50	0.5	1.5	2.5	0.1	0.01	9101	53	100	38
4	50	0.5	1.5	2.5	0.1	0.5	1211	39	100	57
5	50	0.5	1.5	2.5	0.5	0.01	3141	36	100	50

Na figura 22, que mostra o comportamento do algoritmo quanto à convergência no caso da identificação de um *SGTR* com os parâmetros relacionados ao feromônio que estão listados na tabela 4.




Figura 22: Custo x Geração-SGTR- Experimento com Feromônio- 1

No segundo experimento, o aumento valor de η_0 piora a qualidade das soluções iniciais visto que na primeira etapa da simulação o índice de acertos para o *SGTR* caiu de 55 para 50% e o número de gerações até o ponto ótimo aumentou, este fato é explicado pelo enviesamento mal equilibrado que fez os agentes se direcionarem para um ótimo local inferior em termos de qualidade ao primeiro experimento, tal comportamento está ilustrado na figura 23.




Figura 23: Custo x Gerações- SGTR- Experimentos com feromônios-2

O comportamento da função custo, que indiretamente traduz a evolução do algoritmo em termos do número de classificações corretas para o evento, apresenta comportamento errático e menos suave do que o apresentado na figura 23, o aumento dos parâmetros de feromônio provoca estagnações limitadas aumentando o custo computacional já que mais gerações foram necessárias para a convergência para um valor ótimo que provavelmente é local.

O caso extremo foi observado no experimento 4 (ver tabela 4) onde o termo η_0 foi reduzido drasticamente enquanto para constante de decaimento λ foi escolhido um valor relativamente alto se comparado aos demais, seu comportamento está ilustrado na figura 24.




Figura 24: Custo x Gerações- SGTR- Experimentos com feromônios-4

A elevada queda inicial da função custo indica que a parcela exploratória do algoritmo se sobrepôs a parcela de exploração, no entanto o rápido decaimento do feromônio provocou uma convergência tardia e forneceu uma solução inicial de qualidade inferior visto que a parcela de acertos iniciais (39%) foi o pior índice dentre os experimentos e o custo computacional foi o mais elevado.

8.3 Experimentos com séries fora da base de dados

Com o objetivo de avaliar a capacidade do modelo de reconhecer que um determinado evento não consta em sua base de dados foram realizados diversos testes variando tanto os eventos desconhecidos quanto os parâmetros de ruído, para esta etapa os parâmetros da *ACO* foram mantidos constantes. Os dados sobre os experimentos para eventos desconhecidos constam na tabela 6.

As condições enumeradas foram avaliadas sem a reclassificação em relação ao melhor centroide encontrado, ou seja, foram dados somente referentes à busca da *ACO* por estes ao contrário do que foi testado nas etapas anteriores onde se reclassificavam os instantes com base no último e, presumidamente o melhor, centroide. Nos casos anteriores a análise buscava confirmar que a *ACO* era capaz de encontrar de fato o centroide que traduzia, ou representava melhor a série dado que, desde o primeiro instante do evento, este era classificado corretamente na maioria dos casos. Analisando os dados da tabela 6, vê-se que, quando a condição normal não se encontrava na base de dados, o algoritmo a classificou como evento desconhecido na totalidade dos instantes.

Tabela 6: Avaliação da Resposta aos eventos fora da base de dados

Condição de Operação	Condição desconhecida	Ruídos (%)							
		1		2		3		5	
		Class.(%)	Semente	Class.(%)	Semente	Class.(%)	Semente	Class.(%)	Semente
LOCA	Blackout	0	43512	0	58309	0	69357	0	55139
SGTR		0		0		0		0	
Op. Normal		12		95		0		97	
Desconhecido		88		5		100		3	
Condição de Operação	Condição desconhecida	Ruídos (%)							
		1		2		3		5	
		Class.(%)	Semente	Class.(%)	Semente	Class.(%)	Semente	Class.(%)	Semente
LOCA	SGTR	36	341982	35	75894	9	90354	43	10253
Blackout		0		0		0		0	
Op. Normal		0		0		0		0	
Desconhecido		64		65		91		67	
Condição de Operação	Condição desconhecida	Ruídos (%)							
		1		2		3		5	
		Class.(%)	Semente	Class.(%)	Semente	Class.(%)	Semente	Class.(%)	Semente
SGTR	LOCA	35	89732	43	57835	48	38156	36	28347
Blackout		0		0		0		0	
Op. Normal		0		0		0		0	
Desconhecido		65		57		52		64	
Condição de Operação	Condição desconhecida	Ruídos (%)							
		1		2		3		5	
		Class.(%)	Semente	Class.(%)	Semente	Class.(%)	Semente	Class.(%)	Semente
LOCA	Operação Normal	0	32812	0	48361	0	75436	0	5997
SGTR		0		0		0		0	
Blackout		0		0		0		0	
Desconhecido		100		100		100		100	

Em eventos com progressões e consequências similares como o *LOCA* e o *SGTR* empregados como condição desconhecida, o algoritmo não foi capaz de encontrar a classificação correta em todos os instantes devido ao comportamento similar de algumas das variáveis destes acidentes, entretanto após a reclassificação estes eventos foram classificados corretamente em 100% dos instantes, o que atesta mais uma vez que o modelo é capaz de encontrar os centroides dos dados dos eventos postulados que maximizem o número de classificações corretas.

Algumas ponderações sobre o comportamento da *ACO* serão elencadas a seguir com base em suas curvas características.

Evolução do Erro Minimizado - Antes da Reclassificação




Figura 25: Custo x Iterações- *Blackout*- Experimentos com séries fora da base de dados- ruído 2%

Na figura 25 observa-se o comportamento do algoritmo na presença de um ruído de 2% no evento desconhecido, nota-se que depois de meras 15 gerações há uma clara tendência de convergência.

Evolução do Erro Minimizado - Antes da Reclassificação




Figura 26: Custo x Iterações- *Blackout*- Experimentos com séries fora da base de dados ruído 5%

Na figura 26 o ruído inserido foi de 5%, a tendência de convergência também se deu por volta das 15 gerações, entretanto a menor taxa a minimização da função custo, quando comparada com a taxa de 2%, indica que o espaço de busca foi mais explorado quando, isto se explica no fato de que um nível menor de ruído denota um grau de adequação maior da série desconhecida ao centroide correspondente.

Os comportamentos mais erráticos foram relacionados aos eventos *LOCA* e *SGTR*, isto se explica pelas semelhanças guardadas entre estes no tocante às variáveis de estado e seu comportamento durante estas ocorrências, deve-se pontuar que após os momentos iniciais, o desenrolar destes eventos as consequências para a planta são bem distintas.

Os dados da tabela 6 para estes eventos específicos sugerem que a busca pelos centroides ideais geram uma carga computacional maior já que, há uma elevada taxa de classificações errôneas quando comparadas aos demais.

Quando se retira o *LOCA* da base de dados, o algoritmo tende a confundi-lo com um *SGTR*, a recíproca é verdadeira mas em grau ligeiramente menor.

A figura 27 mostra o comportamento do algoritmo para a ocorrência de um *LOCA* com 1% de ruído, nota-se uma convergência mais tardia se comparada ao teste com o *Blackout*, isto ocorre porque a busca pela centroide se torna mais desafiadora quando os eventos constantes na base de dados há um certo grau de similaridade.




Figura 27: Custo x Iterações- *LOCA*- Experimentos com séries fora da base de dados- ruído 1%

O teste ilustrado na figura 28 sugere que um ruído maior, faz com que o algoritmo entenda, com um custo computacional menor, que o evento em questão não é conhecido da base de dados, sua convergência menos tardia, embora com uma taxa menor se comparado ao caso anterior, sugere que o espaço de busca foi explorado numa extensão maior.

Evolução do Erro Minimizado - Antes da Reclassificação

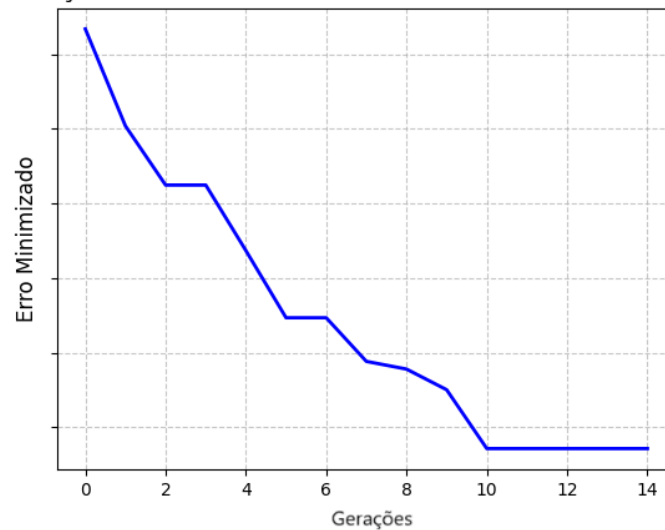


Figura 28: Custo x Iterações- *LOCA*- Experimentos com séries fora da base de dados ruído 5%

Com o *SGTR* fora da base de dados, o algoritmo, em dados instantes da evolução do evento, o confunde com um *LOCA* conforme explicitado anteriormente, o comportamento do algoritmo está explicitado na figura 29.

Evolução do Erro Minimizado - Antes da Reclassificação




Figura 29: Custo x Gerações- *SGTR*- Experimentos com séries fora da base de dados- ruído 1%

O platô entre a segunda e a terceira geração sugerem uma estagnação local, isso só é vencido porque o mecanismo de busca da *ACO* conta com um uma perturbação inerente que simula a parcela das formigas que realizam a busca completamente aleatória, que, nos casos analisados neste trabalho, foi mantida em 10%, isto garante que o enviesamento das buscas seja limitado e a própria procura por soluções explore de modo mais abrangente o espaço das soluções.

Evolução do Erro Minimizado - Antes da Reclassificação

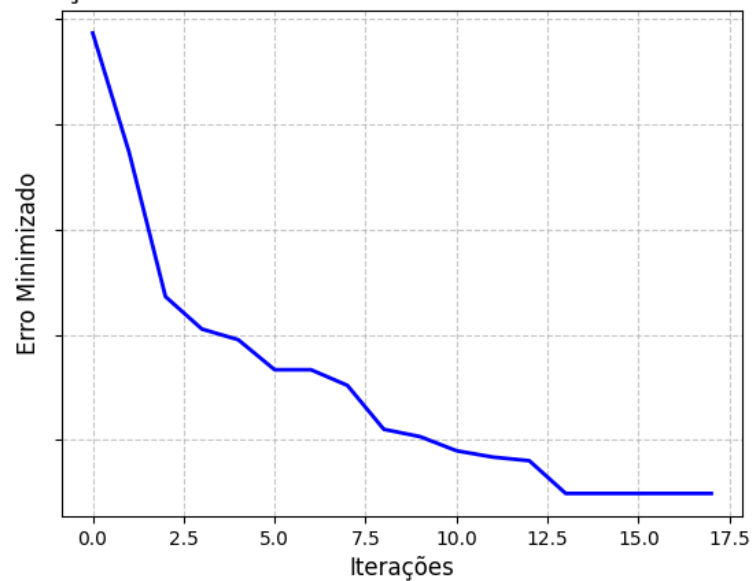


Figura 30: Custo x Gerações- *SGTR*- Experimentos com séries fora da base de dados- ruído 5%

Conforme o ruído aleatório inserido no evento desconhecido aumenta, este, como esperado, tende a se distanciar mais dos eventos postulados constantes na base de dados empregada portanto é esperado que a busca se torne mais custosa em termos computacionais, isto é refletido na convergência ligeiramente mais tardia e na evolução da taxa de acertos por geração conforme pode ser observado comparando as figuras 29 e 30.

Quando as condições de operação normal são retiradas da base para fins de reconhecimento de um evento desconhecido em curso, os resultados, conforme a tabela 6, mostram que o modelo e sua implementação foram capazes de interpretar esta condição desde os primeiros instantes, isto é explicado pela grande dissimilaridade deste evento, aproximadamente constante a despeito dos ruídos inseridos para simular as condições de incerteza de instrumentação e outras eventuais flutuações, a precisão e exatidão dos resultados deste experimento vêm acompanhados de um ligeiro ganho em termos de custo computacional como se pode observar na figura 28.

Evolução do Erro Minimizado - Antes da Reclassificação




Figura 31: Custo x Gerações- Operação Normal- Experimentos com séries fora da base de dados- ruído 1%

Quando o experimento é realizado com ruídos maiores, observa-se uma taxa de queda na minimização do erro menor quando comparada com a figura 31. Observa-se na figura 32 uma ligeira tendência de estagnação entre a 4ª e a 8ª gerações, seguida de uma acentuada queda na função erro, isto ocorre pela própria natureza dissimilar da evolução da planta em operação normal em relação aos eventos postulados, as poucas variações na evolução do estado desta tende a manter as classificações distantes das zonas de influência dos centroides encontrados.

Evolução do Erro Minimizado - Antes da Reclassificação




Figura 32: Custo x Gerações- Operação Normal- Experimentos com séries fora da base de dados- ruído 2%

A figura 33 mostra a evolução da minimização da função erro quando o evento fora da base de dados simula a operação normal da planta com um ruído aleatório de 5%. Neste caso o comportamento de queda mais acentuado e a convergência mais precoce quando comparada em casos de ruídos menores indica uma dissimilaridade maior entre o evento em curso e a base de dados, em outras palavras, o algoritmo tende a reconhecer que não entende o evento em curso com mais facilidade.




Figura 33: Custo x Gerações- Operação Normal- Experimentos com séries fora da base de dados- ruído 5%

CAPÍTULO 9

CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

A busca pelos centroides ou protótipos de uma massa de dados que, neste contexto compõem a evolução do estado da planta se mostrou viável computacionalmente, principalmente devido ao baixo custo computacional, isto é, foram necessárias poucas gerações para se chegar ao resultado esperado, que neste caso é a totalidade dos acertos nas classificações. As flutuações aleatórias representando os eventuais ruídos e incertezas na instrumentação da planta não causaram impactos suficientes para prejudicar o desempenho do algoritmo. Entretanto o *ACO* é muito sensível a um número significativo de parâmetros cujas combinações adequadas possuem caráter fortemente empírico por isso seu uso demanda certa experiência dos usuários e pesquisadores.

Sugere-se como trabalhos futuros:

- A expansão da base de dados, empregando outros acidentes postulados, transientes, tal qual o *ATWS* (*Anticipated Transient Without SCRAM*);
- O aprimoramento da resposta “Não-Sei”, através do emprego do método proposto por NICOLAU (2014) para a obtenção das zonas de influência dos protótipos a partir de medidas estatísticas das séries de base, estes considerando também outras métricas de distância que absorvam melhor os *outliers* se comparados a métrica euclidiana, neste contexto sugere-se também a avaliação de outros meios de normalização dos dados, tais quais os métodos *sigmoidais*, o *Scaling* (particularmente útil para representar situações de referência estáveis) e o *Quantis* (*Quartile Transformation*) dada a natureza fortemente não linear do comportamento das variáveis nas situações de eventos postulados.
- Sugere-se testar o modelo para outras métricas além da euclidiana, tais quais a *Mahalanobis*, especialmente útil por ser invariante à escala, poderia absorver

casos de falha isolada de instrumentação, *Manhattan* e a de *Minkowisk* para diversos valores do parâmetro p ;

- Sugere-se investigar também novos conjuntos de variáveis de processo, preferencialmente menores, que sejam também suficientes para caracterizar o estado da planta para fins de diagnósticos operacionais com custos computacionais menores tal qual o modelo aqui exposto se propõe.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALVARENGA M.A.B., 1997. **Diagnóstico do Desligamento de um Reator Nuclear Através de Técnicas Avançadas de Inteligência Artificial**. Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- BARTAL, Y., LIN, J. UHRIG, R.E., 1995. **“Nuclear Power Plant Transient Diagnostics Using an 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 Unsing an Artificial Nueral Networks”**, Nuclear Technology, vol. 97, Mar, pp. 272-281.
- BASU, A., BARTLETT, E.B. 1994. **“Detecting Faults in a Nuclear Plant by Using a Dynamic Node Architecture Artificial Neural Network”**, Nulear Science and Engineering, vol. 116, pp. 313-325.
- BOX, G. E. P., HUNTER, J. S., & HUNTER, W. G. (2005). *Statistics for Experimenters*.
- DORIGO, M.; GAMBARDELLA, L. M. **“Ant Colony System: A Cooperative Learning Approach to the Traveling Salesman Problem”**. IEEE Transactions on Evolutionary Computation, VOL. 1, Nº. 1, Abril 1997
- DEAN, Walter. **“Computational Complex Theory”**. In: ZALTA, Edward N. (Ed.). *The Stanford Encyclopedia of Philosophy*. Fall 2021. ed. Stanford: Metaphysical Research Laboratory, Stanford University, 2021. Disponível em: <https://plato.stanford.edu/archives/fall2021/entries/complexidade-computacional/>. Acesso em: 25 fev. 2025.
- EL-SEFY, Mohamed; EZZELDIN, Mohamed; EL-DAKHAKHNI, Wael; WIEBE, Lydell; NAGASAK, Shinya. **System dynamics simulation of the thermal dynamic processes in nuclear power plants** Nuclear Engineering and Technology, vol 51, Págs 1540-1553, Set 2019.
- FIEDLER, C.; GREISTORFER, P.; VOSS, S. **Meta-heuristiken als moderne Lösungskonzepte für komplexe Optimierungsprobleme** Disponível em: <<http://kfuniquez.ac.at>>. Acesso em: 10 de outubro. 2024.

- FSAR, 2023. ***Final Safety Analysis Report***, revisão 41, ELETRONUCLEAR, Rio de Janeiro.
- GOSS, S.; ARON, S.; DENEUBOURG, J. L.; PASTEELS, J. M. ***Self-organized shortcuts in the Argentine Ant. Naturwissenschaften***, v. 76, p. 579-581, 1989.
- GÜNDRA, H. et al. ***Heuristische Ansätze zur Lösung von Standortfragen un deren Implementierung*** 2002. Disponível em: <<http://www.itwm.fraunhofer.de>>. Acesso em: 10 de outubro. 2024.
- HAYKIN, S., 1994. ***Neural Networks – A Comprehensive Foudation***. Macmillan College publishing Company, New York.
- 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.
- KHATTAK, M. A. *et al.* **Deterministic Safety Analysis for High Level Waste (Spent Fuel): Management of NPP**, A Review. Progress in Energy and Environment, p. 62-74, Janeiro 2018.
- LEAL, P. C.. ***Um estudo sobre otimização de funções reais de várias variáveis: Teoria e Aplicações***. 2007. Dissertação (Mestrado em Ciências Matemáticas) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2007.
- 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.
- MAZZONI, O. S. **Electrical Systems for Nuclear Power Plants**. [S.l.]: IEEE Press, 2018.
- MACDONALD, P. E. *et al.* **Steam Generator Tube Failures**. [S.l.]: NUREG/CR-6365, 1996.

- NICOLAU, A. S., 2010. “*Computação Quântica e Inteligência de Enxames Aplicados na Identificação de Acidentes de uma Usina Nuclear PWR*”, Dissertação de MSc, COPPE/UFRJ, Brasil.
- NICOLAU, A. S., 2014. “*Algoritmo Evolucionário de Inspiração Quântica Aplicado na Otimização de Problemas na Engenharia Nuclear*”, Tese de DSc, COPPE/UFRJ, Brasil.
- 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*”, 1th ed. Computation Mechanics Publications, WIT Press, Inglaterra.
- PETRANGELI, G. **Nuclear Safety**. [S.l.]: Elsevier, 2006.
- PRASAD, P. W. Chandana; BEG, Azam. *Investigating data preprocessing methods for circuit complexity models*. Expert Systems with Applications, v. 36, pg. 519-526, 2009.
- RAGHEB, M. **Notas de aula do professor M. Ragheb**. [S.l.]: [s.n.], 2016.
- ROVERSO, D., 1998. “*A Neural Model for Event Identification in Dynamic Processes*”. In: Report HWR-516, OECD HALDEN REACTOR PROJECT, Institutt for Energietechnik, Norway
- SEHGAL, B. R. **Nuclear Safety in Light Water Reactors: Severe Accident Phenomenology**. [S.l.]: Elsevier, 2012
- SOCHA, K.; DORIGO, M. *Ant colony optimization for continuous domains*. IRIDIA, Université Libre de Bruxelles, CP 194/6, Ave. Franklin D. Roosevelt 50, 1050 Brussels, Belgium. Disponível em: <https://www.iritia.ulb.ac.be>. Acesso em: 12 de outubro 2024.