

**INSTITUTO DE ENGENHARIA NUCLEAR**

**FREDERICO ALEXANDRE CARDOSO GUIMARÃES**

**CLASSIFICAÇÃO DE ACIDENTES EM USINA NUCLEAR ATRAVÉS DE  
TÉCNICAS DE APRENDIZADO DE MÁQUINA: UM ESTUDO COMPARATIVO.**

**Rio de Janeiro**

**2022**

FREDERICO ALEXANDRE CARDOSO GUIMARÃES

**CLASSIFICAÇÃO DE ACIDENTES EM USINA NUCLEAR ATRAVÉS DE  
TÉCNICAS DE APRENDIZADO DE MÁQUINA: UM ESTUDO COMPARATIVO.**

Dissertação apresentada ao Programa de Pós-graduação em Ciência e Tecnologia Nucleares do Instituto de Engenharia Nuclear da Comissão Nacional de Energia Nuclear como parte dos requisitos necessários para a obtenção do Grau de Mestre em Ciências e Tecnologia Nuclear – em Métodos Computacionais Aplicados.

Orientadores: Prof. Dr. Cláudio Márcio do Nascimento Abreu Pereira

Prof. Dr. Carlos Alexandre Fructuoso Jorge (*in memoriam*)

Rio de Janeiro

2022

GUIM Guimarães, Frederico Alexandre Cardoso.

Classificação de Acidente em Usina Nuclear Através de Técnicas de Aprendizado de Máquina: Um estudo Comparativo / Frederico Alexandre Cardoso Guimarães – Rio de Janeiro: CNEN/IEN, 2022.

xvii, 102 f. : il. ; 31 cm

Orientadores: Cláudio Márcio do Nascimento Abreu Pereira e Carlos Alexandre Frutuoso Jorge (*in memoriam*)

Dissertação (Mestrado em Métodos Computacionais Aplicados) – Instituto de Engenharia Nuclear, PPGIEN, 2022.

1. Transientes em Usinas Nucleares. 2. Árvores de Decisão. 3. Algoritmos de Florestas Aleatórias. 4. Bagging. 5. Gradient Boosting. 6. Máquinas de Suporte Vetorial. 7. Redes Neurais.

CDD

CDU

CLASSIFICAÇÃO DE ACIDENTES EM USINA NUCLEAR ATRAVÉS DE TÉCNICAS DE APRENDIZADO DE MÁQUINA: UM ESTUDO COMPARATIVO.

Frederico Alexandre Cardoso Guimarães

DISSERTAÇÃO APRESENTADA AO PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA E TECNOLOGIA NUCLEARES DO INSTITUTO DE ENGENHARIA NUCLEAR DA COMISSÃO NACIONAL DE ENERGIA NUCLEAR COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS E TECNOLOGIA NUCLEAR – EM MÉTODOS COMPUTACIONAIS APLICADOS

Aprovada por:



---

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



---

Prof. Claudio Henrique dos Santos Grecco, D. Sc.



---

Prof. Paulo Cezar Rocha Silveira, D. Sc.

RIO DE JANEIRO, RJ – BRASIL

NOVEMBRO DE 2022.

## DEDICATÓRIA

Aos meus Pais (*in memoriam*), Elço e Neuza.

“Amor e Saudade eternos”.

## AGRADECIMENTO

A DEUS pelo dom da vida, e por propiciar este momento tão sonhado e desejado por mim.

Aos meus orientadores, os Professores Drs. Cláudio Márcio do Nascimento Abreu Pereira e Carlos Alexandre Frutuoso Jorge (*in memoriam*), por tudo o que foi realizado desde as aulas até hoje, para a concretização deste trabalho.

Aos professores do Mestrado em Ciência e Tecnologia Nucleares, por compartilhar seus conhecimentos nas aulas e fora delas.

Aos meus pares neste curso, cujo convívio foi extremamente gratificante e prazeroso, tornando cada momento um momento ímpar.

Aos meus amigos que sempre, independentemente de onde estiveram, permaneceram a meu lado mesmo que em espírito, me incentivando e apoiando na caminhada para a realização deste meu sonho.

Ao Bibliotecário do IEN Almir Barbio, por sua ajuda ímpar nas buscas para as pesquisas e estudos dentro do curso, e pelas boas conversas.

Às Secretárias do IEN, Cláudia e Carla, pela sua acolhida e carinho desde a inscrição e matrícula até hoje.

Aos funcionários do LABIHS, pela doação e compartilhamento de seu tempo e conhecimento, peças fundamentais para a realização desta dissertação.

A Furnas Centrais Elétricas, por me permitir e dar o suporte necessário para que eu pudesse cursar o mestrado e alcançar este momento.

Aos meus familiares, que neste plano ou no plano superior junto a DEUS, se fazem presentes em minha vida, seja por palavras, pensamentos ou orações, por tudo o que representam, na minha vida.

Ao meu grande amor, esposa e companheira Viviane Cristina, mulher maravilhosa, que junto de seus filhos Bruno Henrique, Gustavo Henrique e Amanda, seu neto Ryan Henrique, seus pais Ângelo (*in memoriam*) e Izabel, irmãos Ângela e Evandro, com seus filhos Letícia, Mariana, Isabela e Guilherme, me acolheu em seu coração e faz parte de minha vida, sendo grande incentivadora, motivadora, e por ter estado ao meu lado, mesmo em minha ausência, na elaboração desta dissertação.

**... “A vida não teria sentido nenhum sem a presença de vocês” ...**

**E como disse uma vez Carl Sagan: “Diante da vastidão do tempo e da imensidão do universo, é um imenso prazer para mim dividir um planeta e uma época com vocês”**

## EPÍGRAFE

“An equation for me has no meaning unless it expresses a thought of God”

“Uma equação para mim não tem sentido a menos que ela expresse um pensamento de DEUS”

Srinivasa Ramanujam  
(Matemático Indiano)

## RESUMO

A operação de usinas nucleares requer procedimentos de segurança para garantir condições de normalidade em sua operação. Para conseguir isso, as variáveis da usina devem ser monitoradas on-line, como para permitir a detecção e identificação de qualquer incidente por meio de análise de sinais, objetivando permitir a intervenção adequada do operador. Neste trabalho, métodos de reconhecimento de padrões são usados para essas tarefas. O objetivo principal é uma comparação de métodos de inteligência artificial para classificar os transitórios e os acidentes de forma que análises de segurança possam ser realizadas com melhor e maior nível de acurácia possível. Entre os métodos de inteligência artificial utilizadas, como objeto de estudo e comparação, estão os métodos de Algoritmos de Florestas Aleatórias (RFA), Máquinas de Suporte Vetorial (SVM), Redes Neurais (RN). A literatura mostra que estes métodos de inteligência artificial são muito promissores para esse tipo de tarefa. Isso permite em estudos e simulações, classificar possíveis acidentes de forma rápida e eficiente. Os sinais experimentais medidos são provenientes de dados coletados de um simulador de usina nuclear no Instituto de Engenharia Nuclear IEN/CNEN. As simulações abrangem a operação normal, bem como alguns casos de acidente. Os resultados são promissores e podem orientar possíveis implementações e futuras modificações em sistemas de apoio à decisão, visando melhorar a segurança na operação da usina nuclear.

**Palavras-Chave:** Algoritmo de Florestas Aleatórias, Máquinas de Suporte Vetorial, Redes Neurais, Métodos de Reconhecimento de Padrões

## ABSTRACT

The operation of nuclear power plants requires safety procedures to ensure normal operating conditions. To achieve this, the plant variables must be monitored online, as to allow the detection and identification of any incident through signal analysis, aiming to allow adequate operator intervention. In this work, pattern recognition methods are used for these tasks. The main objective is a comparison of artificial intelligence methods to classify transients and accidents so that safety analyzes can be performed with the best and highest level of accuracy possible. Among the artificial intelligence methods used, as object of study and comparison, are the methods of Random Forest Algorithm (RFA), Support Vector Machines (SVM), Neural Networks (RN). The literature shows that these artificial intelligence methods are very promising for this type of task. This allows, in studies and simulations, to classify possible accidents quickly and efficiently. The measured experimental signals come from data collected from a nuclear power plant simulator at the Instituto de Engenharia Nuclear IEN/CNEN. The simulations cover normal operation as well as some accident cases. The results are promising and can guide possible implementations and future changes in decision support systems, aiming to improve safety in the operation of the nuclear power plant.

**Keywords:** Random Forest Algorithms, Support Vector Machines, Neural Networks, Pattern Recognition Methods

## LISTA DE ILUSTRAÇÕES

Figura 1:	Diagrama esquemático de um reator tipo PWR.....	37
Figura 2:	Diagrama esquemático de um gerador de vapor (GV).....	41
Figura 3:	Diagrama esquemático da operação um gerador de vapor (GV).....	42
Figura 4:	Diagrama esquemático de um pressurizador (PRZ).....	43
Figura 5:	Diagrama esquemático do sistema de injeção de segurança (SIS).....	47
Figura 6:	Diagrama em bloco simplificado do sistema de proteção do reator (SPR)...	51
Figura 7:	Exemplo de formação de floresta aleatória composta de várias árvores de decisão.....	54
Figura 8:	Exemplo de formação de uma árvore de decisão.....	55
Figura 9:	Exemplo de floresta aleatória com árvore escolhida de maior representatividade.....	56
Figura 10:	Exemplo gráfico da diminuição do erro em função do aumento de árvores.	58
Figura 11:	Exemplo de um neurônio biológico.....	60
Figura 12:	Esquema de unidade McCulloch – Pitts.....	62
Figura 13:	Estrutura de uma rede neural artificial.....	63
Figura 14:	Estrutura de uma rede MLP.....	65
Figura 15:	Fases do algoritmo backpropagation.....	66
Figura 16:	Exemplo Gráfico de uma SVM.....	68
Figura 17:	Fluxograma de ações operativas.....	69
Figura 18:	Vista parcial do simulador no LABIHS.....	75

## LISTA DE TABELAS

Tabela 1:	Acidente com Perda de Refrigerante (LOCA)	77
Tabela 2:	Pressurizador	77
Tabela 3:	Bomba de Refrigeração do Reator (RCP)	78
Tabela 4:	Gerador de Vapor (S/G)	78
Tabela 5:	Sistema de Controle Químico e de Volume	79
Tabela 6:	Sistema de Remoção do Calor Residual	79
Tabela 7:	Sistema de Ejeção de Vapor	79
Tabela 8:	Sistema Principal de Vapor	80
Tabela 9:	Sistema da Turbina	80
Tabela 10:	Condensador e Sistema do Condensado	80
Tabela 11:	Sistema de Água de Alimentação	81
Tabela 12:	Sistema Auxiliar de Água de Alimentação	81
Tabela 13:	Sistemas Diversos	81
Tabela 14:	Descrição dos Códigos	82
Tabela 15:	Listagem das Variáveis Utilizadas do Simulador	83
Tabela 16:	Tabela Exemplo com os dados de Saída do Simulador com as Variáveis utilizadas	84
Tabela 17:	Lista dos logs utilizados	85
Tabela 18:	Parâmetros da rede neural MLP1	87
Tabela 19:	Resultados obtidos com a rede neural MLP1	88
Tabela 20:	Parâmetros da rede neural MLP2	88
Tabela 21:	Resultados obtidos com a rede neural MLP2	88
Tabela 22:	Parâmetros da rede neural MLP3	88

Tabela 23: Resultados obtidos com a rede neural MLP3	89
Tabela 24: Parâmetros da rede neural MLP4	89
Tabela 25: Resultados obtidos com a rede neural MLP4	89
Tabela 26: Parâmetros da rede neural MLP5	89
Tabela 27: Resultados obtidos com a rede neural MLP5	88
Tabela 28: Parâmetros da rede neural MLP6	90
Tabela 29: Resultados obtidos com a rede neural MLP6	90
Tabela 30: Parâmetros da rede neural MLP7	91
Tabela 31: Resultados obtidos com a rede neural MLP7	91
Tabela 32: Parâmetros da rede neural MLP8	91
Tabela 33: Resultados obtidos com a rede neural MLP8	91
Tabela 34: Parâmetros da rede neural MLP9	92
Tabela 35: Resultados obtidos com a rede neural MLP9	92
Tabela 36: Parâmetros da rede neural MLP10	92
Tabela 37: Resultados obtidos com a rede neural MLP10	92
Tabela 38: Parâmetros da rede neural MLP11	93
Tabela 39: Resultados obtidos com a rede neural MLP11v	93
Tabela 40: Parâmetros da rede neural MLP12	93
Tabela 41: Resultados obtidos com a rede neural MLP12	93
Tabela 42: Melhor resultado obtido com a rede neural	94
Tabela 43: Parâmetros e Resultados obtidos com as simulações do Algoritmo RFA	94
Tabela 44: Melhor resultado obtido com as simulações do Algoritmo RFA	95
Tabela 45: Parâmetros e Resultados obtidos com as simulações de SVM	95
Tabela 46: Melhor resultado obtido com as simulações do SVC	96

Tabela 47: Resultados finais das simulações

96

## LISTA DE ABREVIATURAS E SIGLAS

BNN	– Backpropagation Neural Network
DT	– Decision Tree
FFNFC	– Feed Forward Neuro Fuzzy Classifier
GB	– Gradient Boosting
GV	– Gerador de Vapor
IAEA	– International Atomic Energy Agency
IEN	– Instituto de Engenharia Nuclear
LABIHS	– Laboratório de Interface Humano-Sistema
MLP	– Multilayer Perceptron
PRZ	– Pressurizador
PWR	– Pressurized Water Reactor
RNFC	– Recurrent Neuro Fuzzy Classifier
RFA	– Random Forest Algorithm
SAAP	– Sistema de Água de Alimentação Principal
SCQV	– Sistema de Controle Químico e Volumétrico
SIS	– Sistema de Injeção de Segurança
SPR	– Sistema de proteção do Reator
SRR	– Sistema de Refrigeração do Reator
SVC	– Support Vector Machine Classifier
SVM	– Support Vector Machines

## LISTA DE SÍMBOLOS

$f(x)$	- Função de $x$
$\beta_m$	- Coeficiente de expansão
$b(x;\gamma)$	- Funções simples do argumento $x$ , que são caracterizadas pelo parâmetro $\gamma$
$\Sigma$	- Somatório
$X_p$	- Sinal de entrada na rede neural
$W_p$	- Peso de cada sinal na rede neural
$y$	- Sinal de saída da rede neural
$H_p$	- Camada escondida da rede neural
$\mu$	- Taxa de aprendizagem
$k$	- Representa um neurônio da camada imediatamente posterior à camada do neurônio $j$
$\delta(n)$	- Gradiente local
$y_i$	- Saída do neurônio $i$
$F(.)$	- Função de ativação
$a_j(n)$	- Ativação do neurônio $j$
$W_{ki}$	- Sinapse entre o neurônio $k$ e o neurônio $i$
$\gamma$	- Hiperparâmetro do SVC
$u$	- Média das amostras de treinamento
$s$	- Desvio padrão das amostras de treinamento
$Z$	- Pontuação padrão de uma amostra

## SUMÁRIO

<b>1. INTRODUÇÃO.....</b>	<b>18</b>
1.1. APRESENTAÇÃO DO PROBLEMA.....	18
1.2. OBJETIVO .....	22
1.3. METODOLOGIA.....	23
<b>2. TRABALHOS RELACIONADOS.....</b>	<b>24</b>
<b>3. FUNDAMENTAÇÃO TEÓRICA .....</b>	<b>36</b>
3.1. DESCRIÇÃO DOS SISTEMAS E COMPONENTES RELEVANTES EM CASOS DE ACIDENTES .....	36
3.1.1. Reator .....	36
3.1.2. Barras de Controle .....	38
3.1.3. O Sistema de Refrigeração do Reator.....	39
3.1.3.1. Geradores de vapor .....	40
3.1.3.2. Pressurizador .....	42
3.1.3.3. Bomba de alimentação .....	44
3.1.3.4. Circuito de canalização do refrigerante .....	46
3.1.4. Sistema de Injeção de Segurança .....	46
3.1.5. Sistema de Proteção do Reator .....	50
3.1.6. Sistema de Água de Alimentação Principal .....	52
3.2. MÉTODOS DE APRENDIZADO DE MÁQUINA PARA CLASSIFICAÇÃO..	53
3.2.1. Algoritmos de Florestas Aleatórias (RFA) .....	53
3.2.1.1. Árvores de Decisão (DT) .....	54
3.2.1.2. Bagging .....	57
3.2.1.3. Gradient Boosting .....	57
3.2.2. Rede Neural Multicamadas (MLP).....	59
3.2.3. Máquinas de Suporte de Vetores (SVM).....	67
<b>4. APLICAÇÃO NO PROBLEMA PROPOSTO .....</b>	<b>69</b>
4.1. OS TRANSIENTES/ACIDENTES EM USINAS NUCLEARES .....	69
4.1.1. A Segurança Operativa de uma Usina Nuclear .....	69
4.2. SIMULAÇÕES NO LABORATÓRIO DE INTERFACE HOMEM SISTEMA..	74
4.2.1. Procedimento para realização das Simulações.....	82
<b>5. EXPERIMENTOS COMPUTACIONAIS E RESULTADOS OBTIDOS .....</b>	<b>87</b>

5.1. APLICAÇÃO DE REDES NEURAIIS MLP.....	87
5.1.1. Rede Neural MLP1.....	87
5.1.2. Rede Neural MLP2.....	88
5.1.3. Rede Neural MLP3.....	88
5.1.4. Rede Neural MLP4.....	89
5.1.5. Rede Neural MLP5.....	89
5.1.6. Rede Neural MLP6.....	90
5.1.7. Rede Neural MLP7.....	90
5.1.8. Rede Neural MLP8.....	91
5.1.9. Rede Neural MLP9.....	91
5.1.10. Rede Neural MLP10.....	92
5.1.11. Rede Neural MLP11.....	92
5.1.12. Rede Neural MLP12.....	93
5.2. APLICAÇÃO DE FLORESTAS ALEATÓRIAS RFA.....	94
5.3. APLICAÇÃO DE MÁQUINA DE SUPORTE DE VETORES SVM.....	95
<b>6. CONCLUSÃO .....</b>	<b>98</b>
<b>7. PROPOSTAS DE TRABALHOS FUTUROS .....</b>	<b>99</b>
<b>8. REFERÊNCIAS.....</b>	<b>100</b>

## 1. INTRODUÇÃO

### 1.1. APRESENTAÇÃO DO PROBLEMA

A função primordial de usina nuclear, é a de geração de energia para fornecimento de energia elétrica a um sistema elétrico interligado, ou até mesmo a um sistema isolado.

Suas caracterizações, de forma primária, são relativas à tecnologia de reatores empregadas em sua operação, que podem vir a possuir diferentes características construtivas, de funcionamento, e consequente operação. (EL-WAKIL, 1971)

A segurança de uma usina nuclear passa necessariamente por avaliações meticolosas e que envolvem sempre, a consideração das potencialidades e das consequências de um número elevado de acidentes, que são normalmente ranqueados desde um menor contratempo até um evento realmente catastrófico.

Esse ranqueamento, em princípio segue algumas definições onde são colocados em algumas categorias (COLLUM, 2107) conforme segue:

- Categoria 1: São os acidentes que possuem potencial de causar sérios e enormes danos não somente à usina em si, mas como também ao seu entorno, devido a sérios problemas envolvendo radiação, podendo em alguns casos, vir a se tornar um acidente em escala global;

- Categoria 2: São os acidentes que se limitam ao local da usina e ao seu entorno, causando danos devido a exposição à radiação, dentro da usina e em seu entorno;

- Categoria 3: São acidentes que tem potencial de causar danos por radiação, quase que somente no local da usina;

- Categoria 4: São acidentes que não possuem características de riscos radiológicos, mas que podem vir a conduzir a se tornarem danosos ao meio-ambiente;

As preocupações de segurança com usinas nucleares, particularmente, o medo da liberação de materiais radioativos, levaram a análises muito cuidadosas de todos os desvios concebidos da operação normal do reator e de todos os acidentes concebidos que podem ter consequências graves. (BRENNEN, 2005)

Claro que a experiência nas análises de segurança com relação à geração de energia de fonte nuclear em todo mundo tem contribuído de forma significativa no acúmulo de experiência com relação à possibilidade de ocorrência destes acidentes.

Uma das lições dessa experiência, é que a combinação de pequenos eventos, às vezes podem levar a grandes problemas. Isso torna a previsão de acidentes ainda mais complexa, uma vez que requer investigação de muitas mais permutações de acidentes.

As especificidades das sequências de acidentes que devem receber a atenção devida, dependem fortemente do tipo de reator, dos detalhes do projeto, e operação dos sistemas de transporte de calor, das barreiras dos produtos de fissão, e dos sistemas de segurança. (BRENNEN, 2005)

Eventos concebíveis em uma usina de geração nuclear são classificados como transientes operacionais normais, que não requerem ação especial, falhas que podem exigir desligamento do reator, mas que permitem um retorno bastante rápido à operação normal, falhas que resultam em desligamento não planejado, que resultarão em desligamento prolongado e falhas limitantes que podem resultar na liberação de material radioativo.

De maneira preliminar, pode-se classificar os acidentes com reatores nucleares em algumas categorias mais amplas conforma segue (LEWIS, 1977):

- Acidentes com reatividade;
- Acidentes com falhas de refrigeração;
- Acidentes com manipulação de combustíveis;
- Acidentes provocados pelo local de instalação;

Uma avaliação metódica dos sistemas de uma usina nuclear, necessariamente envolve a consideração das potencialidades e as possíveis consequências de um grande número de acidentes que podem vir a ocorrer, os quais são ranqueados desde o menor contratempo até um evento verdadeiramente catastrófico. Isto mostra a real necessidade do diagnóstico precoce de qualquer incidente anormal ou acidente, de forma o mais confiável possível.

Nestas categorias acima mencionadas, à exceção dos acidentes com manipulação de combustível, os danos originam no derretimento do núcleo (LEWIS,1977), e até mesmo em uma vaporização do combustível resultando de uma inabilidade ou incapacidade de se remover o calor do refrigerante de forma rápida e eficiente.

Os acidentes com reatividade, que são acidentes que podem ocorrer devido a falhas operativas, são muitas vezes classificados como sendo transientes de sobrepotência ou excursões nucleares dependendo se está envolvendo um aumento de potência do reator, de uma forma lenta acima do seu valor, ou, uma excursão de potência extremamente rápida (LEWIS,1977).

Em alguns casos extremos, que são algumas vezes postulados, uma parte considerada substancial do combustível pode ser perdida, conhecida como produtos de fissão, ameaçando o sistema primário. O derretimento do combustível pode resultar no derretimento de materiais do núcleo, e com isso, precedendo a um derretimento junto com materiais de isolamento do sistema primário.

Alternativamente, parte da energia térmica que é rapidamente depositada no combustível, pode ser efetivamente convertida em trabalho mecânico destrutivo.

Ambas, a expansão do combustível vaporizado e as explosões de vapor resultantes da mistura rápida do combustível derretido, com refrigerante vaporizado a alta pressão tem sido postulados como possíveis mecanismos de conversão de acidentes, onde neste caso a explosão pode ameaçar a integridade do vaso do reator (LEWIS,1977).

Acidentes com falhas de refrigeração podem ser originados de um número variado de fontes. No sistema primário, um transporte de calor adequado requer que o fluxo do refrigerante, temperatura e o inventário sejam mantidos. Acidentes com perda de fluxo resultam tanto da obstrução de “loops” do refrigerante quanto de falhas de bombeamento. As obstruções no fluxo são em sua maioria a causa da diminuição do fluxo local no núcleo, ao passo que falhas no bombeamento são na maioria a causa que afeta a maior parte ou totalmente o núcleo. O travamento do rotor de uma bomba pode resultar em uma queda pontual da taxa de variação ou razão do fluxo. Entretanto, com um projeto de “loop” paralelo isto não é tão sério como a perda de potência das bombas de refrigeração em todos os “loops”. (LEWIS,1977)

A temperatura e a pressão de todo o sistema primário, pode subir a níveis altos inaceitáveis, se o calor produzido pelo reator não possa ser removido do sistema primário. Acidentes que obstruem o caminho do transporte do calor através do gerador de vapor, ou linhas de vapor em um sistema de ciclo direto, podem se originar de falhas de refrigeração no sistema secundário (LEWIS,1977):

- Perda de fluxo (de uma falha de uma bomba de alimentação);
- Perda de inventário do fluido de trabalho (de uma ruptura de uma linha de vapor ou água de alimentação);
- Perda de decaimento de calor (se a retirada de calor do condensador se torna inoperante);

Podemos dizer que, a perda de refrigerante do sistema primário pode ser considerada crítica no caso de uma grande ruptura no “loop” de refrigeração.

Eventos iniciadores de acidentes com falhas de refrigeração são caracterizadas por problemas que tendem a ser mais severos quando o reator está somente com parte de sua potência. Isto não se deve, entretanto, ser tomado para significar que uma usina nuclear é a priori segura quando ela está a potência baixa, ou até mesmo quando o reator está subcrítico.

As usinas nucleares, e seus sistemas associados de proteção e segurança, são projetados para operar, até mesmo quando algum evento de alta magnitude ocorra, por mais improvável que o seja. O que justifica a ênfase em sua segurança, desde que a integridade do núcleo do reator permaneça intacta, mesmo que acidentes severos possam resultar em uma mínima liberação de material radioativo para o ambiente.

Os acidentes estudados na análise de segurança do reator, em sua grande maioria, são assumidos que são iniciados por falha e/ou mal funcionamento de equipamentos, algum erro no projeto da usina, erro humano, e uma gama de causas possíveis inter-relacionadas. (LEWIS,1977)

Soma-se a isto, que eventos no exterior da planta, sejam eles naturais, ou causados pelo homem, podem ter o potencial para induzir sérios acidentes. Desta forma, eles devem ser levados em consideração na elaboração das bases e procedimentos operacionais.

Cita-se como acidentes desta natureza, a possível ocorrência de furação, ou qualquer outro tipo de tempestade, terremotos ou abalos sísmicos de menor magnitude, maremotos e alagamentos.

Como pode ser discutido, existe um número de perigos em potencial associados com excursões nucleares quando o reator está a uma potência muito baixa. Além de que acidentes de carregamento de combustíveis, apresentam também alguns problemas únicos e são subclassificados como uma terceira categoria de acidentes, mas que não são ao alvo desta dissertação.

## 1.2. OBJETIVO

Este trabalho tem como objetivo principal, realizar um estudo comparativo entre algumas das principais técnicas de Inteligência Artificial (IA) na classificação dos transientes em usinas nucleares, de forma a proporcionar uma maior segurança operativa das usinas nucleares e permitir melhorar os estudos de segurança delas.

Como objetivos específicos, pode-se destacar:

- Realizar simulações de diversos transientes e acidentes utilizando-se o simulador de usinas nucleares do Laboratório de Interface Humano-Sistema (LABIHS) do Instituto de Engenharia Nuclear (IEN), para obtenção dos dados operacionais que formarão uma base de dados para o presente estudo;
- Aplicação da técnica de redes neurais artificiais (do inglês, Artificial Neural Networks, ANN) tipo Perceptron Multi-camadas (do inglês, Multilayer Perceptron, MLP);
- Aplicação da técnica de florestas aleatórias (do inglês, Random Forest, RFA);
- Aplicação da técnica de máquina de suporte vetorial (do inglês, Support Vector Machines – SVM);
- Comparação entre os métodos aplicados;

### 1.3. METODOLOGIA

Inicialmente foi feita revisão bibliográfica de artigos técnicos, teses, livros e capítulos de livros a respeito de transientes e acidentes em usinas nucleares, Redes Neurais Artificiais, Algoritmos de Florestas Aleatórias, Gradient Boosting e Máquinas de Suporte Vetorial.

Depreendeu-se desta revisão, a ideia central de cada uma das técnicas computacionais mencionadas, bem como a respeito de um dos objetos de estudo, que são os transientes em usinas nucleares.

Foram realizadas simulações no LABHS/IEN para criação de uma base de dados de acidentes, para posterior aplicação das técnicas de IA propostas, e realização de comparação dos resultados obtidos para que se possa mostrar suas qualidades e utilidades nos estudos de transientes.

Todas as simulações de acidentes que foram executadas no ambiente do simulador, e seguiram a indicação contida em seu manual de operação, conforme acordado em reunião entre meus orientadores, eu e a equipe responsável pela operação do simulador.

Após sua realização, como os resultados obtidos das simulações possuem o formato .TXT, os mesmos, foram organizados em planilhas EXCEL para facilitar sua utilização a partir das técnicas de inteligência artificial, objetos desta dissertação.

A primeira técnica a ser implementada e aplicada foi a de Redes Neurais do tipo MLP (HAYKIN,2001). A segunda, o algoritmo de Florestas Aleatórias (FREDERICK, GERARD, GÉRON,2005), juntamente com o método de Gradient Boosting (GÉRON,2015) e a terceira técnica foi a Máquina de Suporte Vetorial (GÉRON,2018).

Para cada técnica utilizada, foram aplicados diferentes valores de hiper parâmetros, a fim de otimizar o desempenho de cada uma delas.

De posse dos resultados, procedeu-se, então, análises comparativas entre as técnicas utilizadas

## 2. TRABALHOS RELACIONADOS

A identificação e classificação dos transientes têm sido objeto de estudo devido ao potencial de causar acidentes na usina nuclear com consequências danosas tanto para a usina em si, quanto para o meio ambiente, incluindo os seres humanos, especialmente quando há a liberação de material radioativo.

Diversas abordagens para identificação de transientes e acidentes em usinas nucleares, utilizando técnicas de IA têm sido propostas. Aqui, entretanto, por serem alvo desta dissertação, serão destacadas as Redes Neurais Artificiais (RNA), os Algoritmos de Florestas Aleatórias (RFA), e Máquinas de Suporte Vetorial (SVM).

(BARTLETT, E., URIGH, R.,1991), nos mostra que em uma usina nuclear, o problema de reconhecimento do seu status operativo, tem sido investigado aplicando-se redes neurais artificiais. O objetivo da utilização desta técnica, é a realização do treinamento da rede neural para que ela possa classificar as condições de acidentes que ocorrem em uma usina nuclear, e assim, permitir que possam vir a ser desenvolvidos, dentro do objetivo do uso das redes neurais, o diagnóstico dos sistemas operativos de uma usina nuclear.

O treinamento das redes neurais é realizado de forma que ela reconheça padrões de operação normal, e condições potencialmente inseguras em cenários de acidentes gerados dentro de um ambiente de um simulador de operação de usinas nucleares, no qual alguns cenários, podem incluir os chamados acidentes postulados.

Toda usina nuclear requer um monitoramento cuidadoso. Toda e qualquer ação corretiva deve ser aplicada sempre em que existe a possibilidade de se antever uma condição insegura, e até mesmo quando da real ocorrência dela.

Os diagnósticos destas condições, sempre devem ser rápidos e possuir uma alta acurácia. O objetivo de um sistema de diagnóstico da operação de uma usina, é o de prover aos operadores e engenheiros, diagnósticos em tempo suficiente, para que se possa assim, permitir que se tenha o real status das condições operativas, e que as ações de correção, com relação a qualquer uma das condições anormais de operação, seja realizada de uma forma segura e precisa.

Vários passos em direção às pesquisas de técnicas de generalização, que é uma característica das redes neurais, têm levado a implementações técnicas que mostram que estes resultados, sejam cada vez mais utilizados em novos estudos, pesquisas e desenvolvimento de sistemas supervisórios, e sua aplicação em usinas nucleares como uma ferramenta consistente de auxílio na sua operação, tornando-a cada vez mais segura e confiável.

(BARTLETT e URIGH, 1991) mostram a utilização de uma rede neural para a realização do reconhecimento, de sete cenários de acidentes além do cenário de operação normal à plena potência de uma usina nuclear, usando um simulador para treinamento, com base nos dados da usina de Wattsbar.

No conjunto de dados escolhido, cada cenário estudado, continha 27 variáveis, e o intervalo para a aquisição dos dados foi de meio segundo, com um intervalo total de coleta de 250 segundos.

O primeiro passo, foi o treinamento da rede, com o objetivo que ela pudesse distinguir as condições normais de desligamento, que ocorrem após cada cenário de acidente. Então, a rede é utilizada novamente para cada um dos cenários.

Novos dados de treinamento foram sendo acrescentados, e novamente procedeu-se ao treinamento da rede, onde ela apresentou um erro, e novamente foi retreinada para melhorar sua performance, e dentro de cada um desses cenários, não foram assumidas nenhuma ação humana por parte dos operadores.

Dentro do que foi proposto, a rede neural mostrou um potencial de uso bastante útil em relação à confiabilidade de seu uso, como uma ferramenta de diagnóstico para os estudos de transientes em usinas nucleares.

(MOL,2002), propõe um método que identifica e classifica os eventos através de uma RNA do tipo “jump” multicamada, a qual possui uma boa capacidade de generalização, com algoritmo “backpropagation” que é aplicado a dados com ruídos, possuindo um sistema de validação de diagnóstico capaz de obter uma saída ‘NÃO SEI’, para eventos fora do escopo de treinamento, com isso evitando classificações incorretas ou não confiáveis, este método de acordo com o que foi feito, ainda possui um módulo de validação.

O sistema em questão se mostra independente da variável de tempo, que se justifica devido à questão de detecção do transiente ser um problema complexo e ainda não totalmente resolvido na literatura.

Como características deste sistema, têm-se as condições fundamentais de ele ser robusto em relação ao ruído, poder trabalhar com sistemas dinâmicos e ainda fornecer a saída “NÃO SEI” para os eventos desconhecidos, possuindo este sistema de identificação, a característica de cada etapa subsequente ser complementar à anterior.

Como característica do sistema de identificação de eventos em ambientes ruidosos apresentado, de forma que ele aumente sua capacidade de generalização e robustez, uma grande quantidade de padrões deve ser apresentada à rede na fase de treinamento, se adicionando padrões com ruídos superpostos, forçando para que a rede reconheça estes novos exemplos como sendo pertencentes às classes originais sem ruído. Apresenta ainda como característica da RNA utilizada, que sua utilização se deu ao fato de que seus padrões de saída dentro dela possuam flutuações de um mesmo padrão de entrada, devido à mesma não ser como explicada, fundamentalmente classificadora em torno de um valor discreto esperado. Se determinou dentro de sua fase de treinamento o chamado “raio da zona de alcance” para cada um dos eventos que foi definido como sendo o maior desvio entre o valor esperado e o valor apresentado na saída da rede para o respectivo evento, a partir disso quando se determina o raio de alcance de cada evento define-se o critério de identificação e validação da rede.

(COSTA,2009), apresenta uma proposta para a identificação dos transientes que é feita através da utilização de uma ferramenta de modelagem Neuro-Fuzzy, para uma identificação dos transientes. Sendo que isso é feito através da utilização de uma RNA para um diagnóstico inicial, de onde a partir desta identificação preliminar, o sistema de lógica Fuzzy analise os resultados.

O modelo de RNA utilizado foi o de uma RNA do tipo “jump” com o algoritmo de “backpropagation” para o seu treinamento. Esta escolha foi motivada devido aos bons resultados obtidos quando foram aplicados ao problema de identificação de transientes em usinas nucleares.

A seleção dos eventos foi feita através de uma estrutura modular, onde cada módulo de identificação independente foi composto por até 4 módulos neurais básicos baseados na RNA tipo “jump”, sendo que cada um destes módulos era responsável pela identificação de um evento específico, apresentando as variáveis de processo como entradas e apenas duas saídas, uma delas representando o evento pelo qual o módulo é responsável, que foi denominada de classe A, e a outra saída denominada de classe B que representava os demais eventos. Quando da seleção, foi atribuído o valor 1(um) para a saída ao qual o módulo representava, e 0 (zero) para as demais classes.

Para se aumentar a capacidade de generalização e sua robustez ao ruído, simulando as incertezas do mundo real de operação de usinas nucleares, fez-se necessário que uma grande quantidade de padrões fosse apresentada à RNA em sua fase de treinamento, o que foi feito com a adição de exemplos de padrões com ruídos superpostos de forma que a rede fosse forçada a reconhecer estes exemplos novos como sendo pertencentes às classes originais sem ruídos, mas por não ser fundamentalmente classificadora, este tipo de arquitetura de RNA, permite que os valores apresentados em suas saídas em resposta aos padrões de entrada que representam um mesmo evento flutuem em torno do valor esperado.

Dentro deste escopo, também se utilizou como em (MOL,2002), o mesmo conceito de raio da zona de alcance, como sendo representado como a diferença entre o valor esperado e o valor de saída para cada evento.

Na determinação do grau de confiança nas respostas da RNA, foi utilizado um sistema de lógica nebulosa ou Fuzzy. Assim para cada módulo neural básico, foi proposto um módulo nebuloso, o qual comparava a saída apresentada pelo seu respectivo módulo neural básico com as saídas dos outros módulos neurais básicos que compõem o módulo de identificação independente.

Desta forma, obteve-se a classificação dos eventos em eventos fortes, médios, fracos ou não eventos. Para o grau de confiança teve-se a classificação em graus de confiança do tipo confiante, muito confiante, médio confiante, pouco confiante e não confiante.

(EVSUKOFF, A., GENTIL, S., 2005), nos é mostrado, que, em uma usina nuclear, os sistemas de diagnóstico e análises feitos por computador, tem como objetivo principal, serem ferramentas de suporte aos operadores, principalmente durante as condições chamadas de condições fora do normal, mais conhecidas como transientes ou faltas.

Estes sistemas possuem como seu objetivo principal, a detecção de faltas e o seu posterior isolamento,

Uma falta, seja ela qual for, representa um desvio no comportamento operacional de um sistema no ambiente de uma usina nuclear, em relação às suas condições normais de operação.

A abordagem classificatória, por reconhecimento de padrões, é baseada no reconhecimento, como o próprio nome mostra, em seu comportamento, e nos dados que são apresentados e processados.

Sendo assim, cada alteração em cada um dos sistemas de uma usina nuclear, que apresente um padrão diferente, é considerada como sendo uma falha e/ou transiente, e que são indicativos de serem considerados mais relevantes e indicados como mais representativos.

Relações entre sistemas e falhas em um determinado sistema, são obtidas através de aprendizagem supervisionada, quando as falhas são conhecidas à priori, como por exemplo, através do conhecimento de especialistas. Neste caso a decisão do sistema do sistema é ajustada para corresponder à resposta correta de um conjunto de treinamento de exemplos conhecidos.

Neste caso, o sistema de diagnóstico é um classificador que deve reconhecer, em tempo real, a situação atual representada dos resultados, e associá-los a cada uma das falhas conhecidas. O classificador também deve possuir capacidade de aprendizado, para que possa lidar com possíveis falhas e/ou transientes desconhecidos, ou seja, falhas que por algum motivo não tenham sido colocadas em seu conjunto de treinamento.

(EVSUKOFF e GENTIL, 2005) mostra, que dentre os possíveis classificadores, as redes neurais são amplamente reconhecidas, tanto por sua capacidade de aprendizado, quanto por sua capacidade de classificação não linear.

As redes neurais multicamadas, têm sido extensivamente aplicadas na identificação, bem como na também no controle de sistemas dinâmicos não lineares, e em processos de diagnóstico, estes baseados em alguns modelos previamente estudados.

Em sua maioria, as redes neurais, por vezes, são chamadas e/ou conhecidas como sendo modelos de previsão que estão “um passo à frente”, nos quais a saída do processo atual é utilizada como entrada, sendo assim feito para se computar a saída do modelo no próximo passo de tempo amostral.

Predições de vários passos à frente, podem ser desenvolvidos, ou até mesmo encontrados através de topologias recorrentes, onde apenas algumas, ou todas as unidades da rede são retroalimentadas.

Além do seu uso para modelos de processos com fontes de dados não lineares, elas também podem ser utilizadas diretamente como classificadoras de falhas que porventura venham a estar presentes no sistema, as quais foram direcionadas para estudo.

O processo mostrado, foi a utilização de um sistema neuro-fuzzy generalizado em conjunto com uma rede neural, sistema esse no qual as entradas eram variáveis do processo com valores diferentes dos pontos normais de operação.

Duas topologias de redes neurais foram propostas, e o método de diagnóstico foi realizado através dos dados de um reator nuclear tipo PWR. Uma das topologias apresentadas foi a Feed Forward Neuro Fuzzy Classifier (FFNFC), cujos pesos e suas conexões puderam ter sido computados diretamente como soluções de um problema de mínimos quadrados.

A outra topologia apresentada, foi a Recurrent Neuro Fuzzy Classifier (RNFC), que se mostrou mais eficiente, e a qual obteve melhores resultados, capazes de reconhecer padrões, até mesmo eles sendo bastantes similares aos valores iniciais usados para análise.

(SANTOS,2019) mostra que a questão da utilização da rede neural é tratada através de uma breve introdução, quando cita a respeito de que o problema de identificação de acidentes nucleares (NAIP em Inglês) pode ser visto, como sendo um problema de reconhecimento de padrões, onde os efeitos compostos por um conjunto de variáveis da usina nuclear são identificados para representar o acidente.

Ele comenta que vários métodos estatísticos e de inteligência artificial têm sido aplicados na literatura específica de modo a solucionar o problema do NAIP, citando trabalhos escritos por (MOL,2002) entre outros. Entre estes estudos, as redes neurais têm sido exploradas, individualmente ou em conjunto com outras técnicas, como sendo uma

ferramenta de identificação automática destes padrões de medidas as quais surgem durante um transiente ou até mesmo um acidente, e que são diferentes das que são observadas na operação normal.

A evolução da performance das redes neurais para identificação de acidentes nucleares acompanha diretamente a evolução das próprias redes neurais em si, e que evoluíram desde técnicas que não eram capazes de fazer uma identificação suficientemente rápida de transientes, até as que podem lidar com vários cenários de acidentes.

Entretanto a dificuldade na identificação de transientes rápidos, treinamento exaustivo de longas dependências temporais e modelagem de dados dependentes do tempo, são considerados métodos tradicionais e recorrentemente fracos nos problemas de redes neurais para identificação de acidentes nucleares.

A complexidade que envolve um treinamento de redes neurais com camadas profundas (com mais camadas escondidas), mais redes conectadas, tem sido bastante documentada e dificultado a aplicação de versões modernas de redes, em uma infinidade de problemas incluindo o de identificação dos acidentes nucleares.

Entretanto recentes avanços no campo das arquiteturas de redes, métodos e procedimentos de treinamento tem feito com que se possa potencializar a acurácia com um tempo menor de treinamento e maior capacidade de generalização.

Após a parte teórica a respeito das arquiteturas de redes neurais artificiais profundas, de rede neural retificadora profunda, inicia-se a metodologia do trabalho em si, mostrando que como na literatura não existe uma formalidade ou método definido quanto à questão do número de camadas ou de neurônios nas mesmas, o trabalho consistiu de primeiramente, vários testes usando diferentes redes neurais retificadoras profundas, a que se mostrou com os melhores resultados foi a rede neural retificadora profunda com 5 camadas com função de ativação, com retificadoras lineares nas camadas escondidas e na camada de saída. Sendo que as camadas de entrada e saída possuíam 16 e 1 neurônios respectivamente, e as 3 camadas escondidas de 1000 neurônios cada. (SANTOS,2019).

No treinamento foi utilizada uma estrutura de treinamento em paralelo utilizando hardware de computação paralela baseado em GPU, bem como uso de linguagem PYTHON e C++, junto com utilização de arquitetura CUDA (Compute Unified Device Architecture),

bibliotecas de redes neurais profundas e placas NVÍDIA com suas bibliotecas para o treinamento das redes neurais profundas com aceleração.

Ele descreve seu conjunto de dados como sendo composto de 16 variáveis de estado e 13 cenários operacionais, e com dados (assinaturas) de 61 segundos, dos 13 cenários operacionais, 12 são acidentes postulados para um reator tipo PWR.

De forma a se implementar a robustez do método proposto, ao mesmo tempo em que se provia a rede com uma quantidade apropriada de exemplos para treinamento, o conjunto de dados original foi aumentado, simulando as oscilações da instrumentação por meio de sobreposição aos dados originais de cada variável com ruído branco com distribuição normal e 1% de desvio padrão. Após isso, para cada cenário, os padrões de treinamento e validação foram igualmente divididos para cada um dos 13 cenários operacionais, perfazendo assim para cada um deles, 336 padrões para treinamento, 112 para teste e 168 para validação.

Após ter sido feita a implementação da rede neural, foram feitas análises de performance com 5 segundos e 3 segundos, e chegou-se à conclusão que a precisão com o tempo maior se mostrou melhor. E como resultado final teve-se que a precisão do método alcançou uma média de 98% de acurácia.

(HADAD,2019), apresenta um novo método de reconhecimento/identificação de faltas em uma usina nuclear, usando a transformada wavelet baseada em uma rede neural artificial, onde foram simulados 10 acidentes básicos de projeto (postulados) em um reator tipo VVER-1000 usando 15 parâmetros de entrada com a utilização de uma rede neural do tipo perceptron multicamada com um algoritmo de backpropagation.

Onde, após isso, foi apresentado a aplicação da transformada wavelet por sua propriedade de mudança temporal, ou seja, suas janelas de tempo e de análise multiresolução, características para se reduzir as oscilações ou perturbações no conjunto de treinamento de entrada.

Neste estudo dentro dos 17 acidentes básicos de projeto que foram apresentados no relatório final de análise de segurança do reator VVER-1000, foram escolhidos 10 acidentes cujos dados experimentais se encontravam no relatório referido anteriormente. Existem inúmeros parâmetros que devem ser monitorados, e devido à simetria da planta onde se encontrava este reator, muitos destes parâmetros eram redundantes e não proviam uma

informação útil. Aqui neste estudo foram então escolhidos 15 parâmetros como entrada da rede neural, e os acidentes básicos de projeto foram os 10 acidentes mais comuns.

O comportamento dinâmico de cada parâmetro é a entrada para a rede usando uma janela temporal móvel, onde se tem um vetor de entrada de dimensão 15x5 apresentado à rede neural artificial onde foi colocado o critério de resposta “não conhece”.

A performance da rede de treinamento foi medida pelos erros nos conjuntos de dados de validação e teste. Foi feita uma análise por regressão linear entre a resposta de rede e os componentes alvos, o que produziu uma curva com interceptação em Y e um coeficiente de correlação o qual pode ser usado para avaliar a performance da rede.

Um estudo detalhado de vários algoritmos de redes neurais artificiais, para que fosse selecionado o algoritmo mais eficiente já foi publicado e mencionado na referência bibliográfica deste trabalho de (HADAD,2019).

Aqui no caso foi escolhido o algoritmo backpropagation. Utilizou-se também o método de otimização de Levenberg-Marquardt como o método de otimização escolhido.

Com transientes não lineares, o reconhecimento de padrões e a classificação de acidentes é muito mais difícil e com isso classificações errôneas podem surgir. Durante um transiente em uma usina nuclear, um número de variáveis de estado tem o comportamento fortemente não linear e o comportamento dinâmico do sistema experimenta fortes perturbações.

Como resultado, para a detecção de falhas em uma usina nuclear com reator tipo VVER-1000, conforme mostrado em (HADDAD,2019) teve-se a conclusão de que a proposta de um sistema de detecção e classificação baseado na transformada wavelet e redes neurais possibilitou grandemente um aumento na performance da rede. E como resultado a acurácia deste tipo de sistema foi muito maior do que somente com a rede neural artificial sozinha.

(ZHANG, B. et ali.,2020), nos mostra que a pesquisa se deu em reatores modulares, que assim como reatores de potência maior, possuem variáveis de controle que devem ser monitoradas, de forma que se possa exercer controle sobre elas, e com isso, obter uma operação segura.

A predição das tendências de evolução dos parâmetros de segurança dos reatores e o seu monitoramento, onde estes parâmetros excedem as condições limites de operação, são fundamentais para antes que o operador possa atuar, auxiliie o operador a analisar o processo deste transiente, especialmente no caso de alguma degradação do equipamento.

Foi proposta, a utilização do algoritmo de florestas aleatórias (RFA), no qual foi considerado o impacto da degradação do equipamento em seus parâmetros de segurança.

Os dados de transientes utilizados para o treinamento, incluíram diferentes condições de acompanhamento da carga a ser atendida, considerando vários graus de degradação do mecanismo da bomba de refrigeração principal, e a degradação efetiva da área de transferência de calor no gerador de vapor, no caso aqui em (ZHANG, B. et ali.,2020), um gerador de vapor de passagem única.

Para a avaliação do modelo proposto, novos dados de transientes não treinados foram usados como dados de teste.

De posse destas condições, foram realizadas simulações do algoritmo RF em comparação com uma rede neural backpropagation, e os resultados obtidos mostraram que a tendência evolutiva dos parâmetros de segurança possuiu uma acurácia maior na predição através da utilização do algoritmo RFA em comparação com a rede neural backpropagation.

(AWADALLA, M., et ali,2014), por sua vez, propôs a utilização de SVM baseado na teoria do aprendizado estatístico.

Como uma usina nuclear pode estar sujeita a falhas que podem afetar as suas variáveis de estado, aqui foi proposto um estudo simulado de 30 tipos de falhas diferentes. Como o desempenho de qualquer método estatístico, depende exclusivamente dos conjuntos de dados nos quais é treinado, é aconselhável, que os conjuntos de dados sejam criados de forma que todas as dinâmicas possíveis das variáveis de estado sejam capturadas.

As características selecionadas devem ser as mais descorrelacionadas possível, para evitar o problema da multicolinearidade, que é quando o modelo inclui vários fatores correlacionados, não apenas à sua variável de resposta, mas também uns aos outros.

Para a investigação do algoritmo proposto, foi utilizado um modelo matemático de um reator PWR, baseado em processos neutrônicos e termohidráulicos, com o núcleo do reator, pressurizador, bomba de alimentação e o gerador de vapor.

A abordagem proposta para solução, foi a de se usar SVM multiclasse, em dois métodos desta abordagem, onde foram utilizados os algoritmos “um para um” e “um para todos”.

Não serão explicados aqui estes algoritmos, devido ao escopo principal desta pesquisa de dissertação, não estar direcionado a uma variação do método SVM, nem tampouco qualquer comentário, a respeito da utilização dos algoritmos genéticos em conjunto com a proposta de SVM realizada pelos autores.

(AWADALLA, M., et ali,2014), na conclusão de sua pesquisa, mostra que a utilização dos dois métodos em conjunto de SVM citados anteriormente, apresentaram uma acurácia da ordem de 95,3%, a qual os autores consideraram satisfatória para sua pesquisa.

(AYODEJI, A., et ali.,2018), em seu trabalho, cita que a aleatoriedade e a natureza incipiente de certas faltas no sistema do reator, garantem um mecanismo robusto e dinâmico de detecção de faltas.

A existência de modelos e métodos para o diagnóstico de faltas, usando diferentes métodos matemáticos e de inferências estatísticas, muitas vezes, tornam incipientes as capacidades de detecção de novas faltas.

Com isso, este trabalho propôs, um método de diagnóstico e detecção de faltas usando a flexibilidade do método de SVM em conjunto com “data driven”, conhecida como programação orientada a dados, que é um tipo de programação, onde as instruções do programa descrevem os dados a serem correspondidos, e o processamento necessário, em vez de definir uma sequência de etapas a serem executadas, para um diagnóstico de faltas a nível de componente do sistema.

O método foi composto por uma integração de módulos de SVM para treinamento e simulação, capazes de realizar um diagnóstico das faltas a nível de componente em um sistema inteligente e coerente, com cada um dos módulos do SVM realizando o monitoramento dos componentes do sistema de resfriamento do reator.

Em usinas nucleares, a natureza incipiente de algumas faltas, fazem com que seus diagnósticos sejam problemáticos. Estes resultados advêm do fato de que os efeitos destes tipos de faltas têm a ver com a faixa de exatidão e/ou operação de alguns sistemas de controle e instrumentação.

Degradação do hardware, rupturas e vazamentos em componentes, tais como válvulas e encanamentos, que não são grandes o suficiente para mudar o ponto de operação, possam permanecer indetectáveis por um longo período e são indicativos de faltas incipientes. Adicionando-se a isto, o fato de que as faltas possuem natureza randômica, logo, os mecanismos para sua detecção necessitam de ser robustos e dinâmicos.

(AYODEJI, A., et ali.,2018), apresenta uma proposta, que foi a utilização de um método de treinamento para os módulos SVM multi-classes, no qual, cada um deles, monitora cada uma das unidades componentes do sistema de resfriamento do reator, sendo o tipo de reator escolhido, um reator do tipo PWR.

Para a otimização dos módulos SVM e seleção do melhor algoritmo de treinamento, foi considerada a comparação entre as performances de diferentes implementações multi-classe destes algoritmos, usando diferentes funções em seu núcleo, também conhecido como kernell, que foram as funções linear e a gaussiana.

Dentro do que foi proposto pelos autores em sua pesquisa, os resultados apresentados demonstraram que o método foi efetivo, onde cada um dos módulos SVM previu as faltas para diferentes localizações na usina, e a natureza distributiva dos módulos SVM, em consequência disso, a localização de cada falta foi endereçada pelo SVM distribuído, não sendo neste trabalho aprofundado em seus resultados, qual dos núcleos utilizados possuiu melhor desempenho.

### **3. FUNDAMENTAÇÃO TEÓRICA**

#### **3.1. DESCRIÇÃO DOS SISTEMAS E COMPONENTES RELEVANTES EM CASO DE ACIDENTES**

Com o objetivo principal de que a usina nuclear seja operada com uma flexibilidade operativa e segurança intrínseca, são necessários vários componentes e circuitos de controle, bem como também uma instrumentação bem adequada para que se possa obter medições as mais apuradas possíveis dos parâmetros de controle.

Neste capítulo, será apresentada uma descrição sucinta dos componentes e dos sistemas inerentes à uma usina nuclear e a este trabalho em si.

##### **3.1.1. Reator**

O Reator nuclear, é o componente principal de uma usina nuclear, e em termos de circuito, se localiza no circuito primário da usina, tendo como função, a geração de calor que irá variar, conforme as variações de potência exigida à usina ao longo de sua operação.

Sua constituição é de um núcleo combustível, estruturas internas para a sustentação do núcleo e orientação do refrigerante durante seu percurso em seu interior, um vaso de pressão que contém os componentes anteriormente mencionados, e os mecanismos responsáveis pela atuação das barras de controle, que são adaptados ao vaso do reator, a Figura 1 mostra a seguir uma visão global do reator. (ALVES, 1993; LAMARSH, 2001)

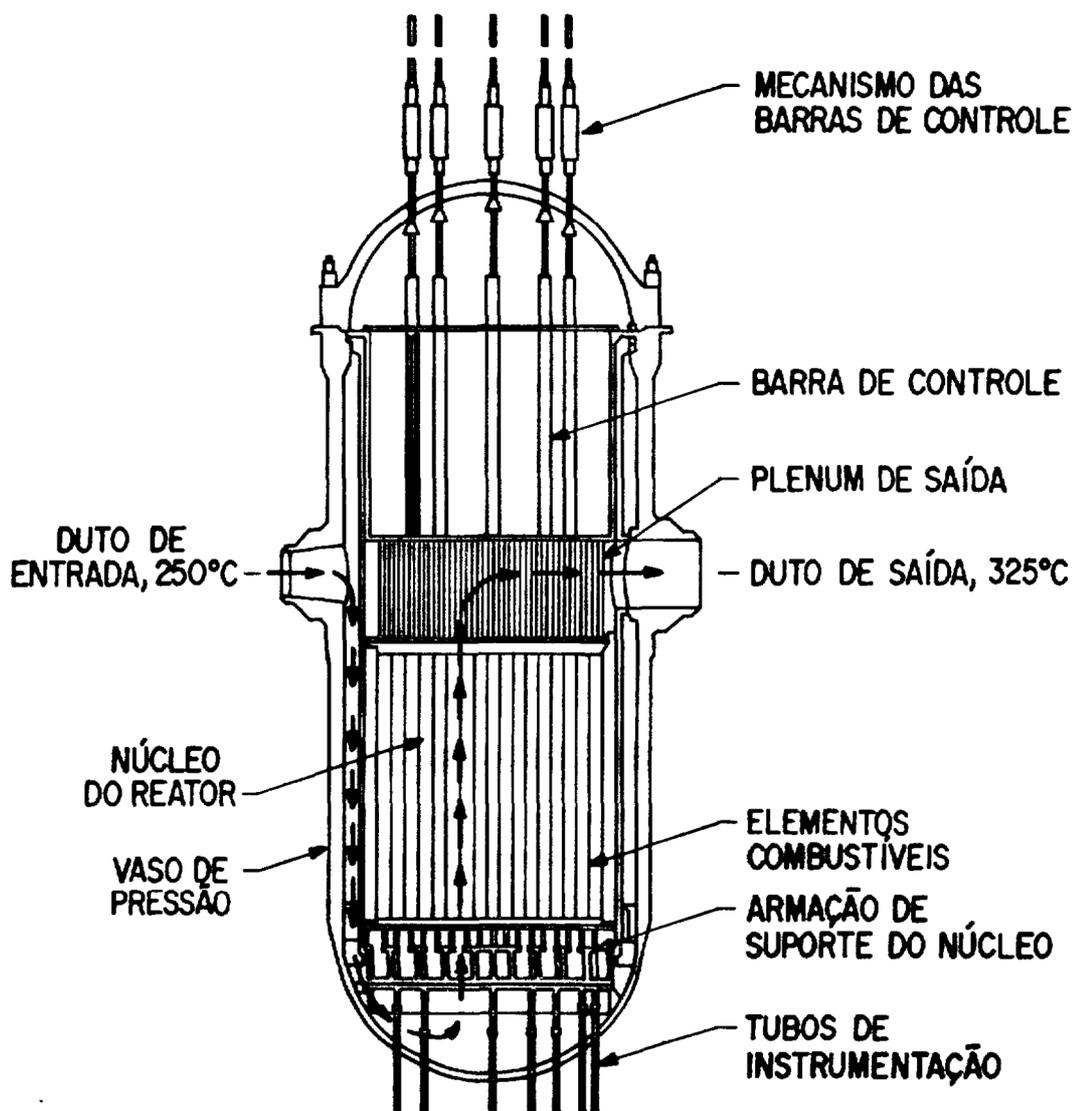


Figura 1: Diagrama esquemático de um reator tipo PWR (ALVES, 1993)

### 3.1.2. Barras de Controle

Nos reatores tipo PWR, o controle é exercido através das chamadas barras de controle ou também chamadas, barras absorvedoras, cuja composição podem vir a ser de carbeto de boro ou de uma liga de índio-cádmio-prata.

Ressalta-se que o controle é exercido também pela dissolução de ácido bórico na água que é o elemento moderador.

O controle em um reator nuclear é dividido em duas classes, uma chamada de controle fino, realizado pelas barras de controle, e a outra chamada de controle grosso o qual é realizado pelo ácido bórico.

As barras de controle são divididas em dois tipos, que são a de comprimento total, nas quais o elemento absorvedor se estende ao longo de todo o seu comprimento, e as barras de comprimento parcial, nas quais o material absorvedor se ocupa apenas do quarto inferior do comprimento total, sendo estas afixadas em uma estrutura de aço inoxidável, conhecida pelo nome de “aranha”.

As barras de controle de comprimento parcial, são usadas com a finalidade de se alterar a forma como a potência é distribuída na direção axial, e assim exercer também o controle da distribuição do xenônio, decorrente das variações dos níveis de potência.

Quando nos remetemos ao uso das barras de controle de comprimento total, temos seu uso no provimento da capacidade de desligamento, do controle dos desvios operativos relativos à reatividade, que são ocasionados pelas variações de temperatura.

No caso de um desligamento emergencial da usina em função de alguma ocorrência sistêmica, nesse desligamento, também conhecido como “trip”, existe um sistema de segurança que faz com que as barras caiam, por efeito de gravidade, instantaneamente no interior do núcleo do reator, cessando com isso, toda e qualquer reação que esteja ocorrendo dentro do núcleo do reator. (ALVES,1993; LAMARSH, 2001)

### 3.1.3. Sistema de Refrigeração do Reator (SRR)

A função do sistema de refrigeração do reator, dentro de uma planta nuclear, é a de realizar a extração do calor do núcleo do reator, por meio dos geradores de vapor, e com isso, que haja a produção de vapor, que irá, no circuito secundário da usina, proceder ao acionamento mecânico das turbinas, e com isso, gerar energia elétrica.

Operacionalmente, a água de refrigeração do circuito primário, é injetada no vaso do reator pelo seu bocal de entrada, percorrendo o interior do núcleo do reator, realizando a troca de calor ou retirada do calor gerado pelas reações de fissão, de onde sai através da chamada “perna quente”, que é a parte da tubulação que sai do reator, indo até a entrada do gerador de vapor, onde se processa a troca de calor, através de seu conjunto de tubos internos, com a água advinda do circuito secundário, importante observar que, entre a água do circuito primário, e a água do circuito secundário, não existe nenhum contato direto.

Após a realização desta troca de calor com a água do circuito secundário, essa água que vem do reator, sai do gerador de vapor através da chamada “perna de ligação”, indo assim até a bomba do refrigerante, seguindo pela “perna fria” até sua entrada no vaso do reator, fechando com essa operação todo o circuito.

A água de refrigeração, é pressurizada de forma que não venha a evaporar totalmente devido às altas temperaturas de trabalho. Sua regularização da pressão é realizada pelo pressurizador, que se conecta ao circuito primário na “perna quente”, isso é realizado desta forma, devido a que esse arranjo é o que apresenta as melhores respostas às variações de pressão, o pressurizador por sua vez, é ligado ao seu tanque de alívio por meio de válvulas de alívio e de segurança, existindo ainda uma ligação do pressurizador com a “perna fria” através da sua linha do “spray”.

Componentes de sistemas auxiliares do reator, carregam o sistema de refrigerante, fazem a adição da água de reposição, purificam a água de refrigeração, e fazem a adição de produtos químicos que são usados na proteção contra corrosão, e, para controle do reator, refrigeram componentes do sistema, exercendo a importante e primordial função, de remoção do calor residual, quando do desligamento do reator, provendo também a injeção de água de emergência. (ALVES, 1993; LAMARSH, 2001)

### 3.1.3.1. Geradores de Vapor (GV)

Uma planta nuclear, normalmente possui mais de um circuito de sistemas de refrigeração, sendo assim, cada circuito possui gerador de vapor, sua montagem é da forma vertical, sendo que em sua cabeça hemisférica inferior existem dois bocais, sendo um de entrada e outro de saída do refrigerante, na sua cabeça hemisférica superior, cujo formato é mais achatado do que na inferior, encontra-se a saída do vapor produzido.

No corpo do gerador de vapor, em sua parte inferior, está localizada a entrada de água de alimentação. Os geradores de vapor consistem basicamente em duas seções assim descritas: O evaporador composto por tubos em formato “U”, e os separadores, onde se processa a separação da mistura água-vapor. A Figura 2 nos mostra o diagrama esquemático de um gerador de vapor. (ALVES,1993; LAMARSH, 2001)

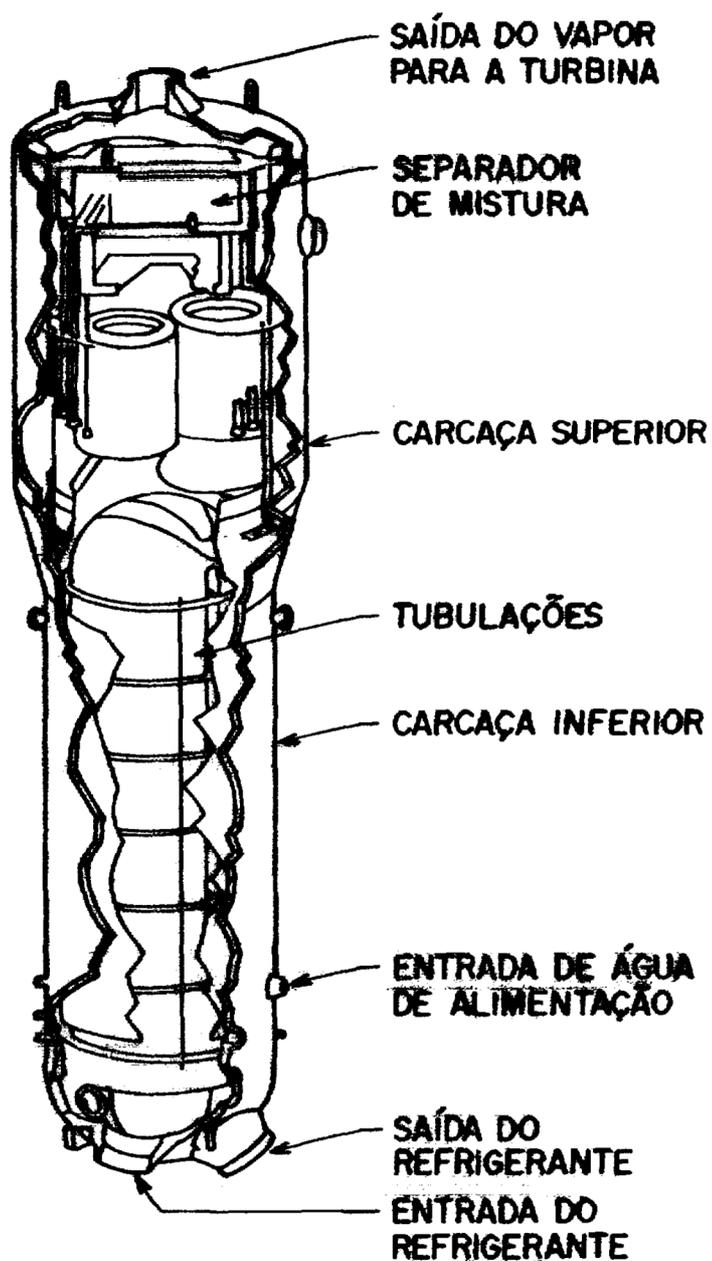


Figura 2: Diagrama esquemático de um gerador de vapor (GV) (ALVES,1993)

O nível da água dentro do gerador de vapor é função do nível de potência da usina, a 0% (zero) de potência, o nível de água dentro do gerador de vapor é da ordem de 33%, sendo que esse nível se eleva linearmente até 44%, quando a usina está na faixa de operação de 20% da potência nominal, mantendo-se nesta faixa até o atingimento de 100% da potência nominal da usina. A razão para o nível de água permanecer nos 44%, pode ser explicado a partir da Figura 3.

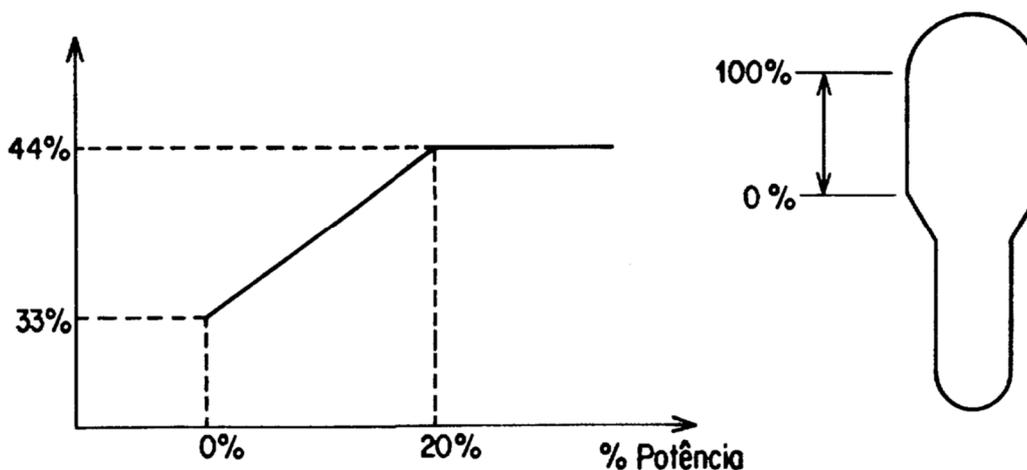


Figura 3: Diagrama esquemático da operação um gerador de vapor (GV) (ALVES,1993)

Há um desligamento do reator quando o nível de água atinge 13%, desta forma, se o reator estiver funcionando a 100% da potência nominal, a um nível de água de 33%, quando houver uma rejeição de carga a 50%, atinge-se o nível de desligamento a 13%. (ALVES,1993)

Quando nos remetemos aos problemas de desligamentos associados a um gerador de vapor, temos dois principais, que são os desligamentos associados a um nível muito baixo, que se refere ao decaimento do nível ao patamar de 13% e o de baixo nível, quando o nível cair a 25% e em conjunção a uma discordância de fluxo, na entrada e na saída do trocador de calor. (ALVES,1993; LAMARSH,2001)

### 3.1.3.2. Pressurizador (PRZ)

O pressurizador, dentro de uma planta nuclear tem como função, a manutenção da pressão do sistema de refrigeração do reator durante sua operação normal e limitar as variações da mesma durante os transientes.

Fundamentalmente, o pressurizador consiste de um vaso, com uma parte superior em forma hemisférica e uma parte inferior na forma plana.

Existem no pressurizador em sua parte inferior, os chamados aquecedores de imersão que são compostos de resistências elétricas cambiáveis, e também um bocal de comunicação do pressurizador com o resto do sistema, e na sua parte superior um bocal de “spray” que é conectado à “perna fria” do circuito de refrigeração.

A Figura 4 mostra uma figura esquemática do pressurizador.

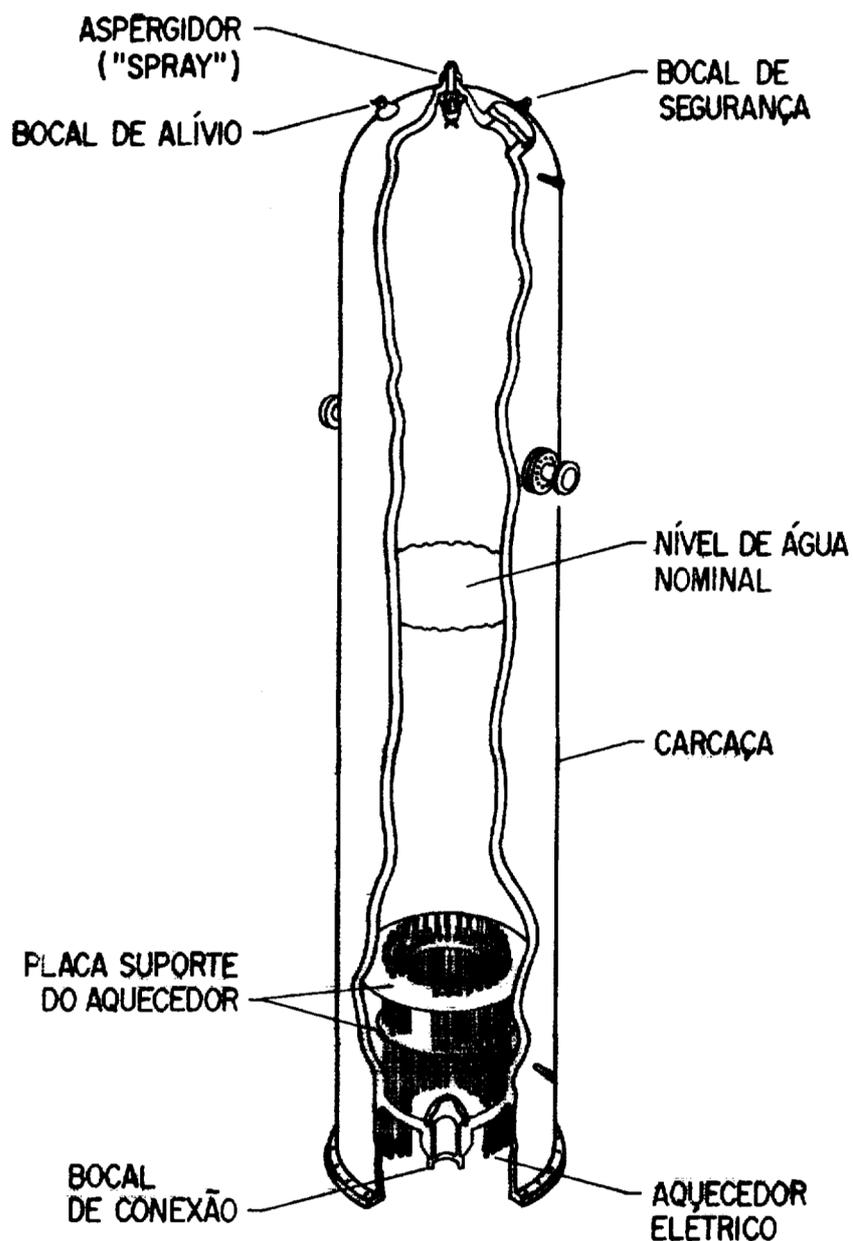


Figura 4: Diagrama esquemático de um pressurizador (PRZ) (ALVES,1993)

Durante as suas condições normais de operação, o pressurizador possui cerca de 60% de seu volume ocupado por água e os restantes 40% ocupados por vapor. A função dos aquecedores de imersão é a de manter a água na temperatura de saturação, e com isso, a pressão do sistema constante.

Se ocorrer um aumento da demanda de carga no sistema, significa que existe uma maior demanda de vapor na turbina, implicando assim uma maior troca de calor com o refrigerante primário e conseqüentemente diminuição da temperatura média e de seu volume. Assim, o refrigerante tende a escoar do pressurizador para o circuito reduzindo o nível e a pressão. Essa redução de pressão é auto limitante, pois ela provoca a formação de vapor, a qual limita a redução de pressão, sendo essa redução, a responsável pelo fechamento dos contatos do aquecedor, e com isso tendo como consequência uma elevação de temperatura, a qual tende a aumentar a pressão do sistema trazendo-o ao estado de equilíbrio novamente.

Contrariamente, havendo uma diminuição na demanda de carga, o refrigerante aumenta a sua temperatura média e também o seu volume, isso nos leva a um aumento da pressão do sistema, desta forma, isso leva a uma operação das válvulas na região do “spray”, que utiliza a água da “perna fria” aspergindo-a na região de vapor, provocando a condensação do mesmo e com isso uma diminuição da pressão.

O reator possui, associado ao pressurizador os seguintes desligamentos que são os desligamentos por alta pressão, alto nível, e desligamento por baixa pressão. (ALVES,1993; LAMARSH, 2001)

#### 3.1.3.3. Bomba de alimentação

Os reatores usam bombas que possuem características construtivas singulares, essas bombas são de eixo selado e do tipo vertical, centrífuga, de um estágio, e sendo elas soldadas à tubulação fazendo assim parte integrante do sistema.

O refrigerante é então bombeado pelas palhetas do rotor que são ligadas à parte terminal inferior do eixo, sendo a sucção do refrigerante através do bocal de entrada que fica localizado na parte inferior da carcaça pelas palhetas, e descarregado através do difusor no

bocal de saída, que se localiza em uma posição de 90° em relação à entrada. A função do difusor é a de transformar a energia de velocidade em energia de pressão.

Existe uma barreira térmica localizada e fixada entre o flange principal e a carcaça da bomba, cuja funcionalidade principal é a de separar a água do refrigerante primário que está à temperatura normal de operação daquela que está à uma temperatura mais baixa.

Essa água à temperatura mais baixa é usada para refrigerar e lubrificar o mancal radial e para suprir os selos. O elemento principal da barreira térmica é um trocador de calor em forma de uma serpentina, com seus tubos construídos utilizando-se aço inox, dentro dos quais a água que circula é uma água de refrigeração à baixa pressão que é fornecida pelo sistema de refrigeração de componentes. Note-se que durante seu funcionamento normal, a bomba tem a água de injeção dos selos, de alta pressão, proveniente do sistema de controle químico e volumétrico (SCQV), circulando em espirais minimizando desta forma os requisitos de troca de calor da água de refrigeração. O trocador descrito mais acima possui principalmente duas funções conforme seguem.

A primeira é a da manutenção do funcionamento do mancal radial bem como dos selos em uma temperatura ideal, isso se dando através da refrigeração descrita anteriormente.

A segunda é de provisionar em caso de emergência água resfriada para os selos do circuito na ocorrência de alguma falha na injeção de água de alta pressão do SCQV.

Existe um detalhe importante, que é a existência de um mecanismo que impede a reversão da rotação da bomba em caso de uma parada de funcionamento, o que é chamado de rotor parado, no volante em seu diâmetro externo, são montadas garras que correm sobre um disco dentado. Quando existe uma tendência de inversão de rotação, essas garras encaixam-se nos entalhes dos dentes travando assim o volante, e, por conseguinte, a bomba, impedindo assim qualquer movimento de inversão da rotação da mesma. (ALVES,1993; LAMARSH, 2001)

#### 3.1.3.4. Circuito de canalização do refrigerante

O circuito básico do refrigerante, é constituído pelo vaso do reator, pela “perna quente”, pelo gerador de vapor, pela “perna de ligação” do gerador de vapor à bomba, pela bomba de refrigerante e pela “perna fria”, sendo que as tubulações principais são dimensionadas com tamanhos diferentes. Esse dimensionamento leva em consideração alguns fatores distintos conforme segue.

Uma limitação na velocidade máxima do fluxo com o objetivo claro de se evitar qualquer uma possibilidade de haver qualquer tipo de erosão. A diferença da densidade da água antes, e também depois de sua passagem pelo trocador de calor.

O volume do líquido que está contido no sistema de refrigeração, devendo ser este o mínimo possível, tendo que se levar em conta uma possível liberação de água em caso de um evento de ruptura da tubulação. O tamanho imposto à tubulação de admissão na bomba em sua “perna de ligação”, para que se obtenha na entrada da mesma as condições de um fluxo ótimo, e as espessuras das tubulações que são dimensionadas em função da pressão interna do sistema, seu diâmetro interno e o material que venha a ser utilizado.

#### **3.1.4. Sistema de Injeção de Segurança (SIS)**

O referido sistema é projetado para executar duas funções distintas caso haja algum acidente que implique na perda da refrigeração tanto no circuito primário quanto no circuito secundário, ou até mesmo quando da ruptura dos tubos do gerador de vapor, inclusive na tubulação de vapor do secundário.

A primeira função é a de fornecer refrigeração que seja suficiente para o núcleo do reator, de modo que possa limitar as falhas dos elementos combustíveis e manter a configuração geométrica do núcleo.

A segunda função é a de se adicionar ao núcleo uma reatividade negativa, que possa assegurar o desligamento do reator dentro de uma margem de segurança adequada. Ambas as funções são exercidas de forma simultânea através da injeção no núcleo do reator de água borada juntamente com a atuação das barras de controle.

Os acidentes podem vir a causar uma rápida despressurização do circuito primário, como por exemplo, através de uma ruptura completa da tubulação do circuito, ou mesmo uma despressurização lenta, como por exemplo através de uma ruptura de pequeno porte na tubulação do primário, sendo assim pode-se ter a ocorrência ou não de vazamento do refrigerante do primário.

Conforme cada tipo de acidente, o sistema de injeção de segurança irá funcionar de uma maneira em particular ou diferente através de seus principais componentes.

Esses componentes são os acumuladores, na quantidade de um para cada circuito primário, duas bombas de injeção de segurança, de alta pressão e pequena vazão, e as duas bombas de remoção de calor residual, baixa pressão e grande vazão.

A Figura 5 nos mostra um diagrama esquemático do sistema de injeção de segurança (SIS).

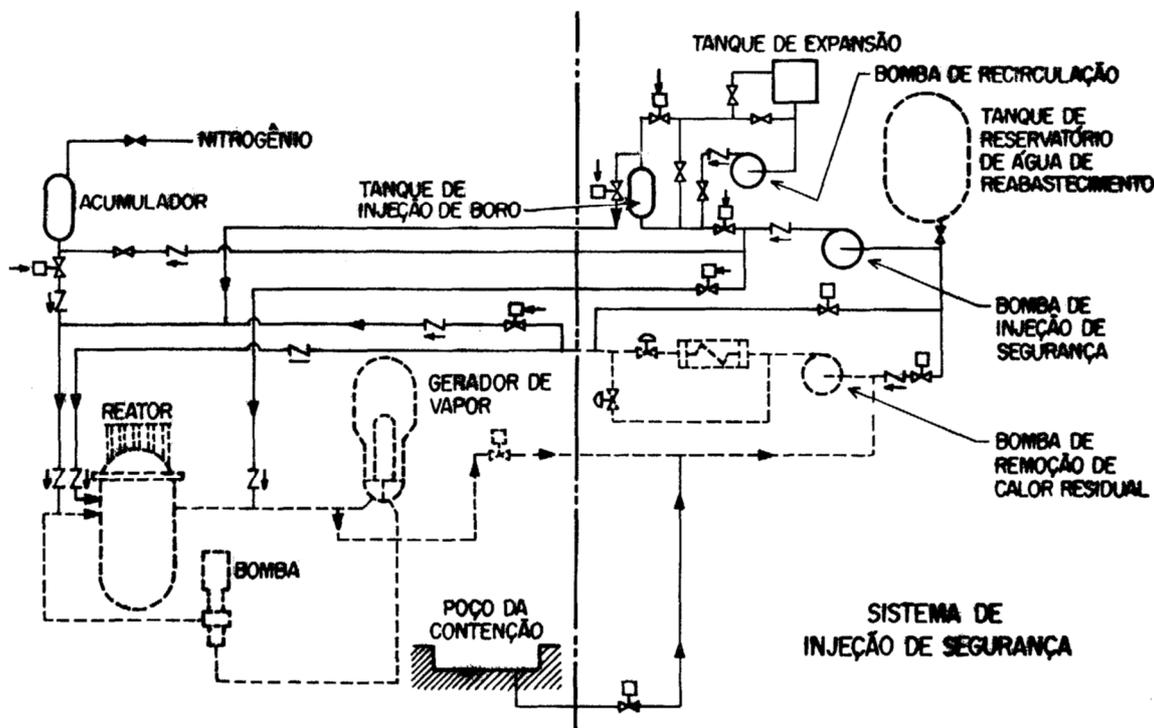


Figura 5: Diagrama esquemático do sistema de injeção de segurança (SIS) (ALVES,1993)

Pode-se descrever o funcionamento deste sistema de uma forma simples e direta conforme segue.

A injeção da água borada é realizada através de circuitos de alta e baixa pressão. Pelo circuito de baixa pressão, temos os seguintes componentes que fazem parte dele, que são os acumuladores e as bombas de calor residual, sendo que em cada um dos acumuladores está contida uma solução de ácido bórico com uma concentração definida e ainda sob pressão de nitrogênio e ligado à “perna fria” do circuito primário próximo ao local de entrada do vaso de pressão do reator.

Automaticamente, os acumuladores quando a pressão do circuito cai a determinados valores já previamente calculados, ele descarrega de forma automática a água borada, assegurando desta forma, uma rápida refrigeração do núcleo, quando do aparecimento de grandes rupturas na tubulação do primário.

Com o objetivo de se manter a refrigeração que foi proporcionada pelos acumuladores, ativam-se as bombas de remoção de calor residual, que injetam água borada que vem do reservatório de água de reabastecimento.

Sendo esta água, injetada no “plenum” superior do núcleo através de bocais que adentram o vaso de pressão, e também o cilindro do núcleo.

Em relação ao circuito de alta pressão, temos como parte do mesmo, as bombas de injeção de segurança, onde a sucção de cada uma das bombas está ligada ao tanque reservatório de água de reabastecimento e suas descargas estão ligadas ao tanque de injeção de boro, este contendo a água borada em uma concentração definida, provendo desta forma, uma forma rápida de que a água borada possa chegar ao núcleo. O tanque de injeção de boro, possui uma saída que acaba se dividindo em duas, cada uma delas se dirigindo a uma “perna fria” do primário. Entre as descargas das bombas de injeção de segurança e o tanque de injeção de boro, provém uma derivação que se divide em duas, sendo que cada uma delas é direcionada a uma “perna quente” do circuito primário.

Na ocorrência de uma ruptura na linha de vapor, a válvula de isolamento da linha da alta pressão que se dirige às “pernas quentes” atua, e promovendo assim um direcionamento da vazão provida pelas bombas de injeção de segurança para as “pernas frias”, assegurando com isso, uma inserção rápida de reatividade negativa no núcleo.

Ocorrido o acidente, a fase de injeção termina antes que seja esvaziado o reservatório de água de reabastecimento. Indicadores de nível presentes neste tanque, fornecem alarme,

para que o operador. De forma simultânea, acontece o mesmo com os indicadores de nível do poço de contenção, pondo o operador a par do que está ocorrendo, de forma que o operador possa finalizar a fase de injeção e iniciar logo em seguida a fase de recirculação.

Após a operação de injeção, o refrigerante primário que foi derramado por causa da ruptura da tubulação e a água do “spray” da contenção, é coletado do poço de contenção, retornando ao SRR, através do sistema de recirculação.

O modo de funcionamento do sistema de recirculação vai depender diretamente do nível de depressurização que se deu no sistema primário, caso a ruptura tenha sido de uma dimensão considerada grande, a depressurização é devida à fuga em larga escala de massa e de energia do circuito primário para contenção, assim desse modo, a recirculação é realizada através das bombas de remoção do calor residual, das quais a sucção é transferida para o poço de contenção, fazendo com que a água retorne ao núcleo do reator, passando através dos trocadores de calor residual.

Para o caso de acidentes nos quais temos uma lenta depressurização, onde a pressão do sistema primário é maior que a pressão das descargas das bombas de remoção de calor residual no momento em que deva ser iniciada a circulação, a descarga das bombas de remoção do calor residual, é realizada na sucção das bombas de injeção de segurança, de forma que a recirculação seja feita através das linhas de alta pressão.

Para uma partida do SIS, temos sinalizado baixos nível e pressão coincidentes no pressurizador, uma baixa pressão nas linhas de vapor e uma alta pressão na contenção, ou ainda acionamento manual.

Os sinais que provém do pressurizador ou das linhas de vapor podem ser bloqueados enquanto a pressão permanecer abaixo do valor estipulado em projeto, com a finalidade estrita de evitar a entrada em operação, do SIS, durante a partida (aquecimento) ou parada (resfriamento) do reator.

Caso o acidente seja consistido de uma pequena perda de refrigerante, caracterizando-se por uma lenta queda na pressão, a linha de injeção de alta pressão é utilizada, de forma que a injeção é iniciada assim que a pressão do circuito primário cai abaixo de um determinado valor de projeto. As bombas de remoção de calor residual então

são acionadas, mas devido à baixa pressão de descarga, apenas há recirculação através da bomba e do trocador de calor residual.

Quando o acidente consiste em uma grande perda de refrigerante, caracterizado por uma queda de pressão de forma muito rápida, ambas as linhas de injeção, tanto a de alta pressão quanto a de baixa pressão são utilizadas, sendo iniciadas assim que a pressão de ativação destas linhas é atingida. Entretanto nestes casos, a injeção por meio da linha de alta pressão é desprezível perante a injeção provida pela linha de baixa pressão.

Se o acidente é uma ruptura dos tubos do gerador de vapor, o sistema de injeção restabelece o nível e a pressão do pressurizador, iniciando-se o desligamento do reator, assim que a pressão no sistema primário atine um determinado nível já calculado, o gerador de vapor danificado é isolado e a fuga de refrigerante para o meio ambiente é interrompida.

Quando o acidente é a ruptura de uma tubulação de vapor, devido ao rápido resfriamento do refrigerante primário, a diminuição do nível e pressão do pressurizador aciona o SIS através da linha de alta pressão. Essa injeção fornece reatividade negativa para impedir o retorno do reator à criticalidade e restabelecer o nível e pressão no pressurizador. A partir deste ponto, o SIS não se torna mais necessário, e o resfriamento segue de forma normal e usual. (ALVES,1993; LAMARSH, 2001)

### **3.1.5. Sistema de Proteção do Reator (SPR)**

O SPR faz parte dos chamados sistemas de instrumentação e controle e tem por objetivo principal, evitar danos ao núcleo e a outras partes da usina nuclear que são importantes para a segurança da mesma. A instrumentação da usina nuclear nos informa a existência de uma condição anormal ao sistema de proteção que, então, faz com que os alarmes atuem sinalizando ao operador que existe algo fora dos parâmetros normais de operação para que ele tome as devidas providências corretivas, impede a retirada das barras de controle, inicia a redução de carga do gerador e/ou desliga o reator dependendo da gravidade da situação que estiver ocorrendo.

O sistema de bloqueio de retirada das barras de controle é utilizado para prevenir o agravamento de uma condição anormal de funcionamento que poderia causar o

desligamento do reator. As condições que bloqueiam a retirada das barras de controle são as seguintes:

- Queda das barras de controle;
- Alta taxa de aumento de potência;
- Alto fluxo de nêutrons;

A redução automática da carga da turbina pode ser iniciada por um sinal de queda de barras de controle ou aproximação de uma condição de sobrepotência ou sobretemperatura, a Figura 6 nos mostra um diagrama de blocos simplificado do sistema de proteção.

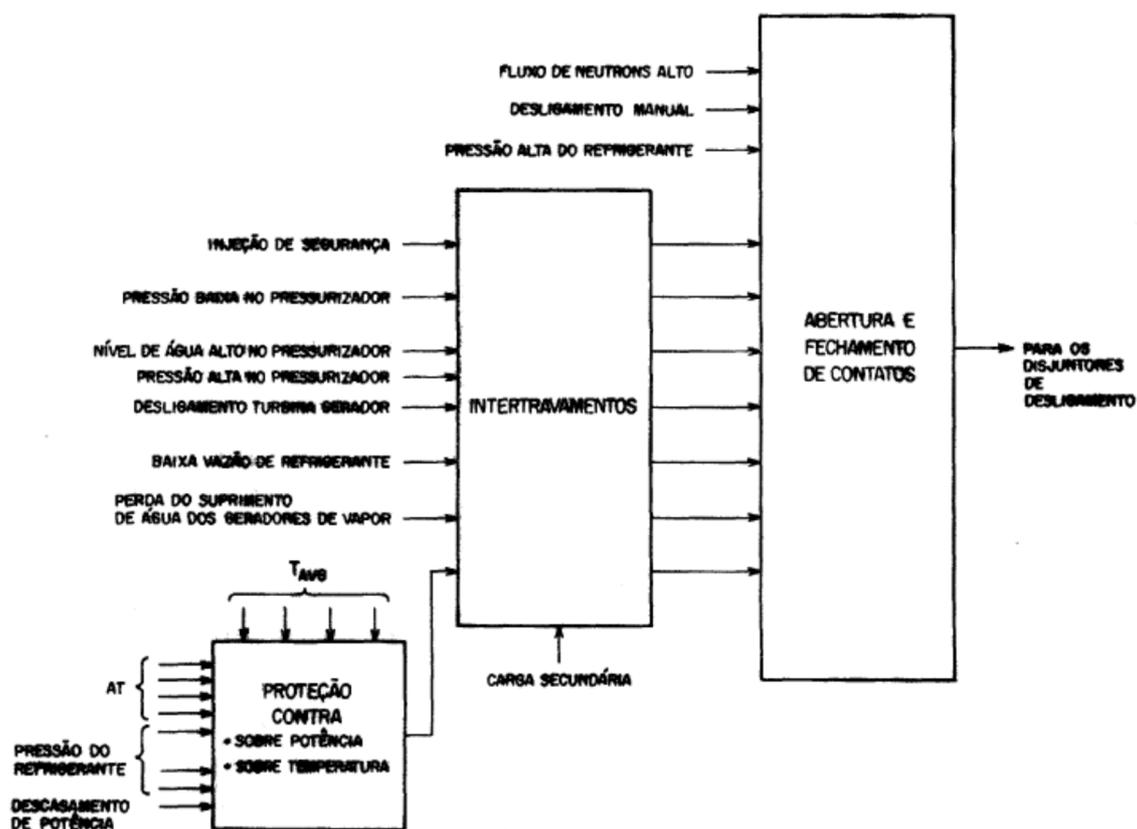


Figura 6: Diagrama em bloco simplificado do sistema de proteção do reator (SPR) (ALVES,1993)

Os principais sinais que provocam o desligamento de um reator são apresentados a seguir:

- Desligamento manual;

- Alta taxa de aumento de potência;
- Fluxo de nêutrons elevado;
- Sinal de injeção de segurança;
- Sobrepotência e sobretemperatura;
- Pressão elevada;
- Vazão reduzida de refrigerante;
- Desligamento do conjunto turbina-gerador;
- Nível baixo de água nos geradores de vapor;

Os sinais de desligamento do reator são bloqueados por indicações de potência nuclear e térmica, pois algumas condições que originam sinais de desligamento só devem ser consideradas se o reator estiver acima ou abaixo de determinado nível de potência.

### **3.1.6. Sistema de Água de Alimentação Principal (SAAP)**

A função do sistema secundário é a de aproveitar o vapor produzido nos geradores de vapor para, através das turbinas a vapor, acionar o gerador para a produção de energia elétrica.

O SAAP, é o responsável pela troca de calor entre os fluidos do sistema primário (refrigerante) e do sistema secundário (água de alimentação).

A água de alimentação fria vinda de um reservatório é bombeada até os geradores de vapor sendo transformada em vapor pela troca de calor que ocorre nos GV's. Esse vapor é a seguir usado para impulsionar as turbinas da usina nuclear, em cujo acoplamento direto através de seu eixo, o gerador elétrico. Existe uma taxa de bombeamento de água de alimentação na qual a eficiência na troca de calor é a adequada para a potência que será gerada pela usina. Uma variação nesta taxa de bombeamento para mais ou menos pode levar a um transiente na usina nuclear.

O circuito secundário é um circuito fechado e constituído por duas linhas em paralelo. O vapor gerado nos GV's segue diretamente para a turbina de alta pressão. O número de unidades de turbina varia, de acordo com a potência da central.

Da saída da turbina de alta pressão, o vapor então segue para o reaquecedor-separador de mistura, com a finalidade de se melhorar a eficiência final do ciclo. A fase líquida sai para o tanque de drenagem dos aquecedores e o vapor passa pelos dois estágios dos reaquecedores, de onde vai em seguida para as turbinas de baixa pressão.

Os reaquecedores são trocadores de calor, com o fluido quente passando por seus tubos no seu interior, e o fluido mais frio, no caso o vapor passando perpendicularmente e por fora dos mesmos.

## 3.2. MÉTODOS DE APRENDIZADO DE MÁQUINA PARA CLASSIFICAÇÃO

### 3.2.1. Algoritmos de Florestas Aleatórias (RFA)

O Algoritmo de Floresta Aleatória (RFA) (GÉRON,2017) é um algoritmo de aprendizagem de máquina com grande flexibilidade e de fácil utilização, que têm se mostrado eficiente em diversas aplicações.

Ele é utilizado em muitas áreas diferentes, tal como setor bancário, mercado financeiro, medicina, comércio eletrônico. No setor bancário ele é utilizado, por exemplo, para detectar clientes que irão utilizar os serviços bancários mais frequentemente que outros e pagar suas dívidas pontualmente. Neste domínio ele também é utilizado para detectar fraudes de clientes que querem lesar o banco. No setor financeiro, ele é utilizado para determinar o desempenho futuro de uma ação. Na área de saúde ele é utilizado para identificar a correta combinação de componentes em medicina, e também é utilizado para analisar o histórico médico de um paciente para identificar doenças. Por último, em comércio eletrônico o Floresta Aleatória é utilizado para determinar se um cliente irá gostar do produto ou não.

É um algoritmo bastante utilizado, devido à sua simplicidade e o fato de que pode ser utilizado tanto para tarefas de classificação como de regressão.

O seu funcionamento se dá através da criação e manipulação de um conjunto (floresta) de árvores de decisão (do inglês, decision trees, DT), visando otimizá-las para a solução de uma tarefa.

A Figura 7 nos mostra um exemplo de uma floresta aleatória.

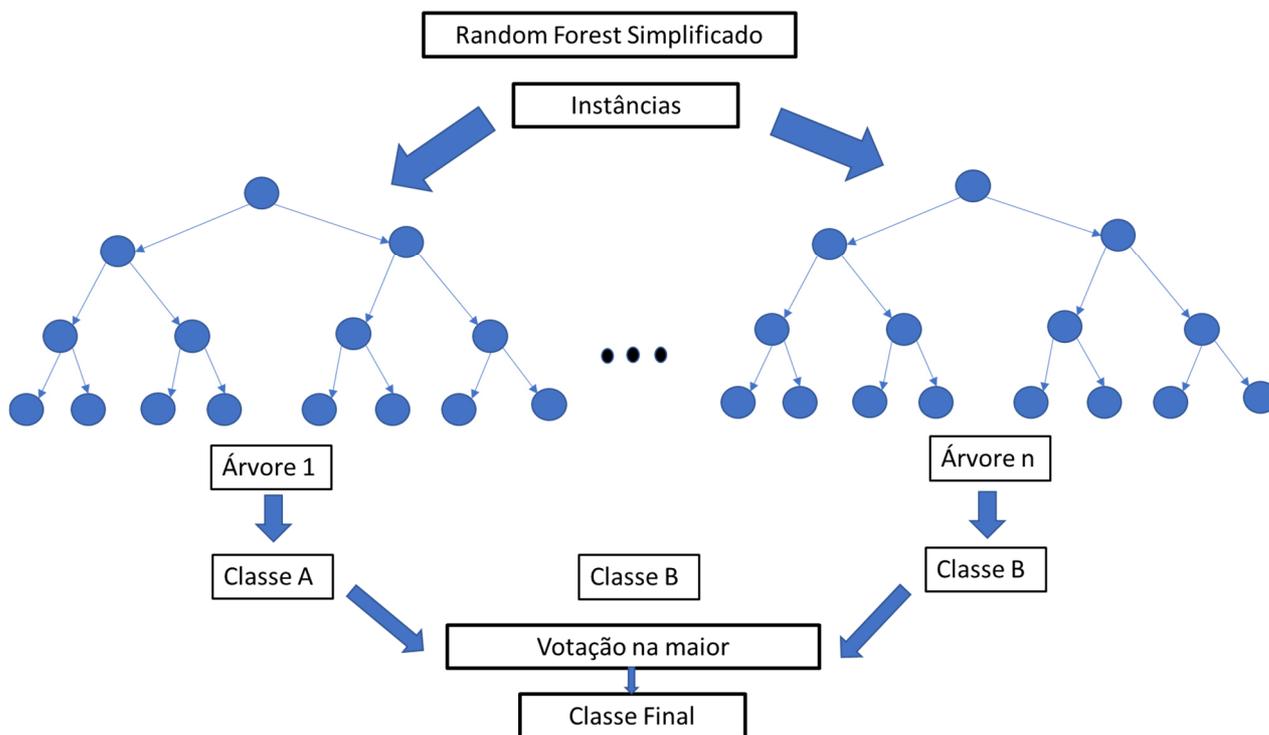


Figura 7: Exemplo de formação de floresta aleatória composta de várias árvores de decisão.

Para uma melhor compreensão das RFA, serão introduzidos a seguir os conceitos básicos sobre árvores de decisão e algoritmos de aprendizagem de máquina “bagging” e “boosting”.

### 3.2.1.1. Árvore de Decisão (DT)

O processo de aprendizagem de máquina pelo método de árvores de decisão (DT) (ROKACH,2014), é um dos métodos de aprendizagem mais utilizados e um dos mais práticos com relação a uma inferência indutiva. É um método para aproximação de funções de valor discreto que são robustas a dados com ruídos.

Este método, é um método feito para aproximação dos resultados de funções de valores discretos, nos quais a função utilizada é representada por uma árvore de decisão. As árvores podem ser representadas por um conjunto de regras do tipo “se, então” para melhorar a capacidade de leitura/entendimento pelo homem.

Estes métodos de aprendizagem, estão entre os mais populares algoritmos de inferência indutiva, e que tem sido utilizados com sucesso em uma vasta gama de tarefas.

As árvores de decisão DT classificam instâncias, através de uma abordagem “de cima para baixo” (ou em inglês top-down), partindo da raiz para algum nó, o qual deve prover a classificação da instância.

Cada nó na árvore especifica um teste de algum atributo da instância, e de cada ramo descendente de cada nó que corresponde a um dos possíveis valores para este atributo.

Segundo DURKIN (1994), indução é o processo de raciocínio sobre um dado conjunto de fatos para princípios gerais ou regras. A indução busca padrões em informações disponíveis com o propósito de inferir conclusões racionais. O aprendizado indutivo tem sido uma importante área de pesquisa em Inteligência Artificial e pode ser visto como uma busca de soluções no espaço de estados do problema.

A Figura 8 nos mostra um exemplo de árvore de decisão, no caso, para uma questão de análise de clima e tempo.

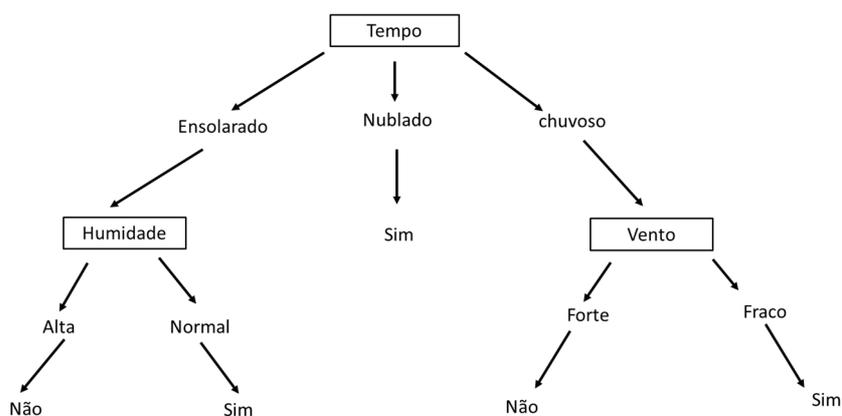


Figura 8: Exemplo de formação de uma árvore de decisão.

Cada ramo descendente de cada nó, corresponde a um dos possíveis valores para este atributo. Uma instância é classificada iniciando-se da raiz (nó raiz) da árvore, testando o atributo especificado para este nó, e então se movendo para baixo para o galho correspondente da árvore cujo valor corresponde ao valor do atributo. Este processo é então repetido para o nó seguinte ao qual está ligado e assim sucessivamente.

As árvores de decisão possuem alguns problemas práticos, incluindo o quão profundo a árvore deve crescer, a manipulação de atributos contínuos, escolhendo uma seleção de medidas apropriada para um determinado atributo, a utilização de dados de treinamento com alguns valores de atributo faltando, e o incremento da eficiência computacional (ROKACH,2014)

O algoritmo de florestas aleatórias (RFA) utiliza várias árvores de decisão em paralelo (“Bagging”) de onde obtém-se o resultado que apresentar maior representatividade. A Figura 9 nos mostra um exemplo.

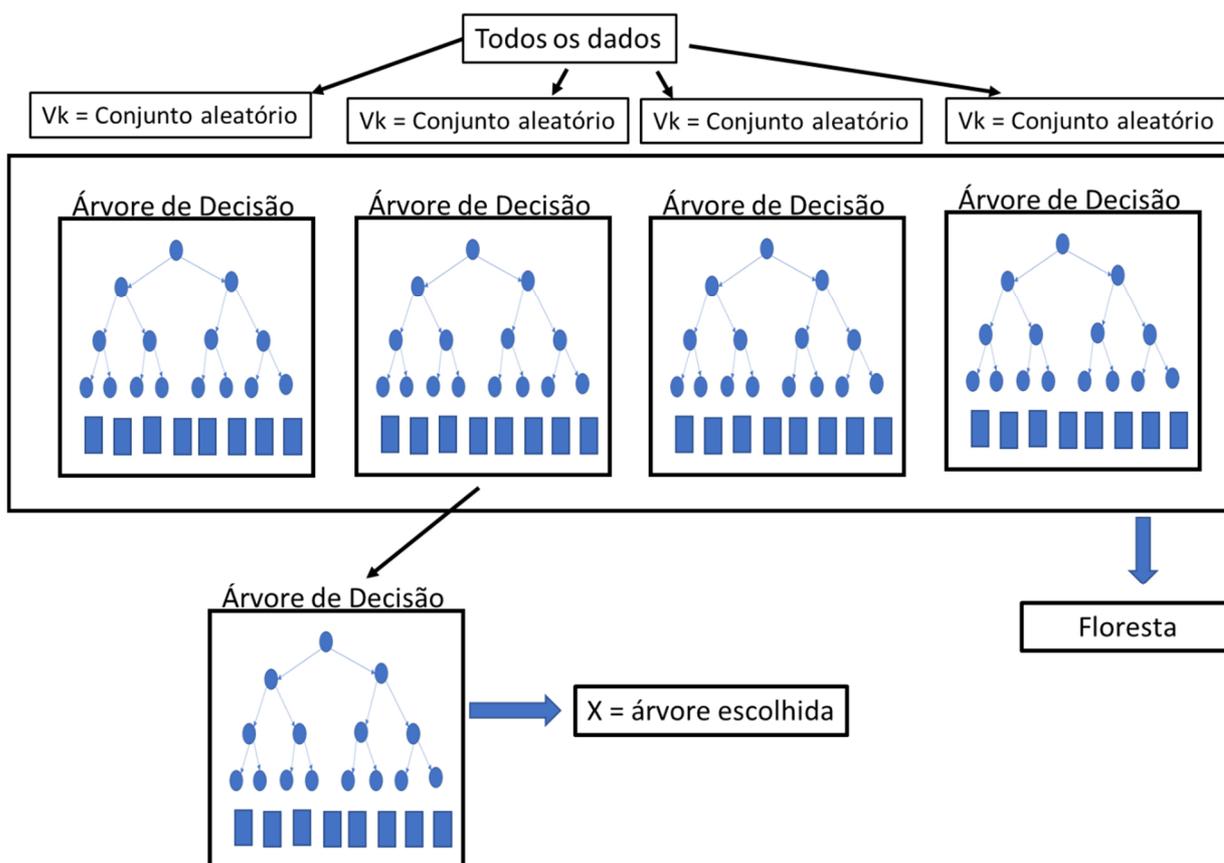


Figura 9: Exemplo de floresta aleatória com árvore escolhida de maior representatividade.

### 3.2.1.2. Bagging

O método *Bagging* (ensacamento) (ROKACH,2014), é a base do algoritmo de florestas aleatórias. *Bagging*, que é um acrônimo de *Bootstrap Aggregating*, é uma técnica que consiste em tomar repetidas amostras do conjunto de treinamento até serem obtidos (n) subconjuntos de treinamento que serão usados na construção de múltiplas árvores de decisão.

Ao final deste processo, será usada para classificação, a média das múltiplas árvores geradas. Quando se utiliza esta média, tem-se uma grande redução na variância, acarretando assim, um aumento na acurácia da classificação.

Nas florestas aleatórias, a cada divisão na árvore, será considerado somente um subconjunto de (m) preditores. Desta forma, uma parte das divisões não irá considerar a variável de entrada forte, com isso, outras variáveis de entrada terão chance de aparecer no topo da árvore.

As várias demonstrações, tanto práticas quanto teóricas, convergem no sentido de que, o método *Bagging* direciona-se para a otimização dos processos de classificação.

### 3.2.1.3. Gradient Boosting

*Gradient Boosting* (ROKACH,2014), na definição da expressão, significa o aumento do gradiente, e é uma técnica ou modelo de aprendizado de máquina utilizado para solução computacional de problemas de regressão e classificação, e que como resultado na questão da previsão, um modelo composto de um conjunto de modelos preditivos fracos, onde geralmente esses modelos são modelos de árvores de decisão.

Esse modelo é normalmente usado com árvores de decisão que possuam tamanho fixo, normalmente são árvores de decisão do tipo CART (Classification And Regression Trees) (ROKACH,2014), que é uma árvore que agrega tanto a função de classificação quanto a função de regressão.

A definição matemática de *Gradient boosting*, é uma forma de expansão ajustando os dados em uma soma ponderada de funções elementares.

$$f(x) = \sum_{m=1}^M \beta_m \cdot b(x; \gamma_m)$$

Onde:

$\beta_m$  = Coeficiente de expansão

$b(x; \gamma)$  = funções simples do argumento  $x$ , que são caracterizadas pelo parâmetro  $\gamma$ .

Sua utilização, é mais adequada para a otimização do erro quadrático médio, também chamado de perda ou custo, sendo que o erro médio quadrático por definição, é a média do quadrado da diferença entre os destinos verdadeiros e os valores previstos de um conjunto de observações, como um conjunto de treinamento ou validação.

Conforme cada modelo fraco é adicionado ao processamento, o erro médio quadrático diminui, fazendo que sua acurácia aumente. A Figura 10, nos mostra graficamente esse processo.

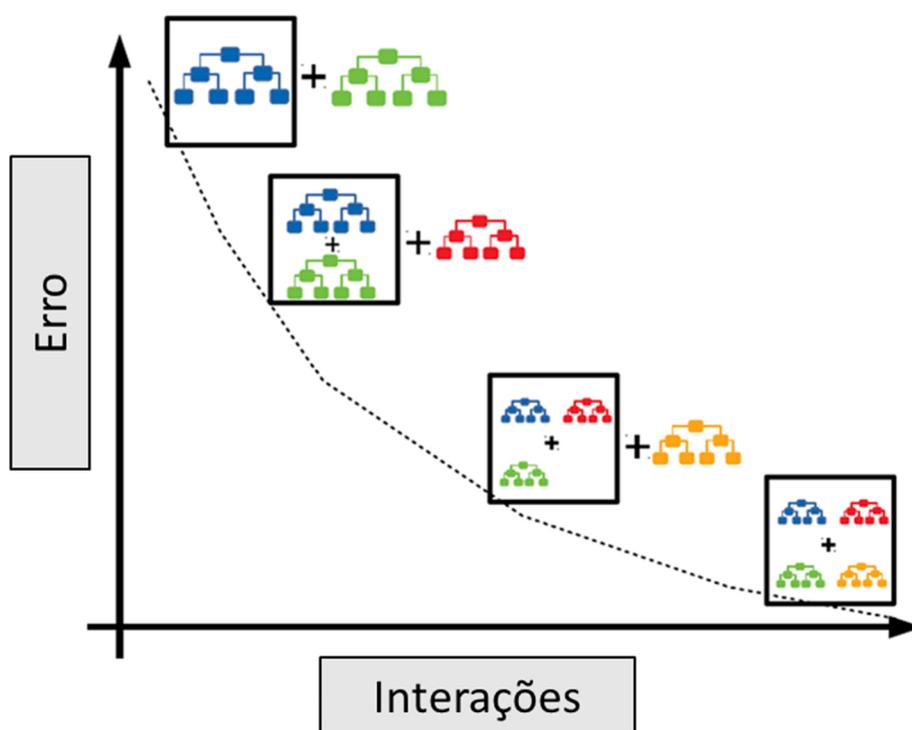


Figura 10: Exemplo gráfico da diminuição do erro em função do aumento de árvores.

### 3.2.2. Rede Neural Multicamadas (MLP)

As redes são redes neurais também conhecidas como redes multicamadas progressivas ou “feed forward multilayer perceptrons”, ou simplesmente multilayer perceptron (MLP) (HAYKIN,2001).

Antes abordar propriamente dito as redes neurais MLP, apresenta-se um breve histórico e as principais definições.

Redes Neurais Artificiais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Uma grande rede neural artificial pode ter centenas ou milhares de unidades de processamento; já o cérebro de um mamífero pode ter muitos bilhões de neurônios.

O sistema nervoso é formado por um conjunto extremamente complexo de células, os neurônios. Eles têm um papel essencial na determinação do funcionamento e comportamento do corpo humano e do raciocínio. Os neurônios são formados pelos dendritos, que são um conjunto de terminais de entrada, pelo corpo central, e pelos axônios que são longos terminais de saída. A Figura 11 nos mostra a representação física de um neurônio biológico.

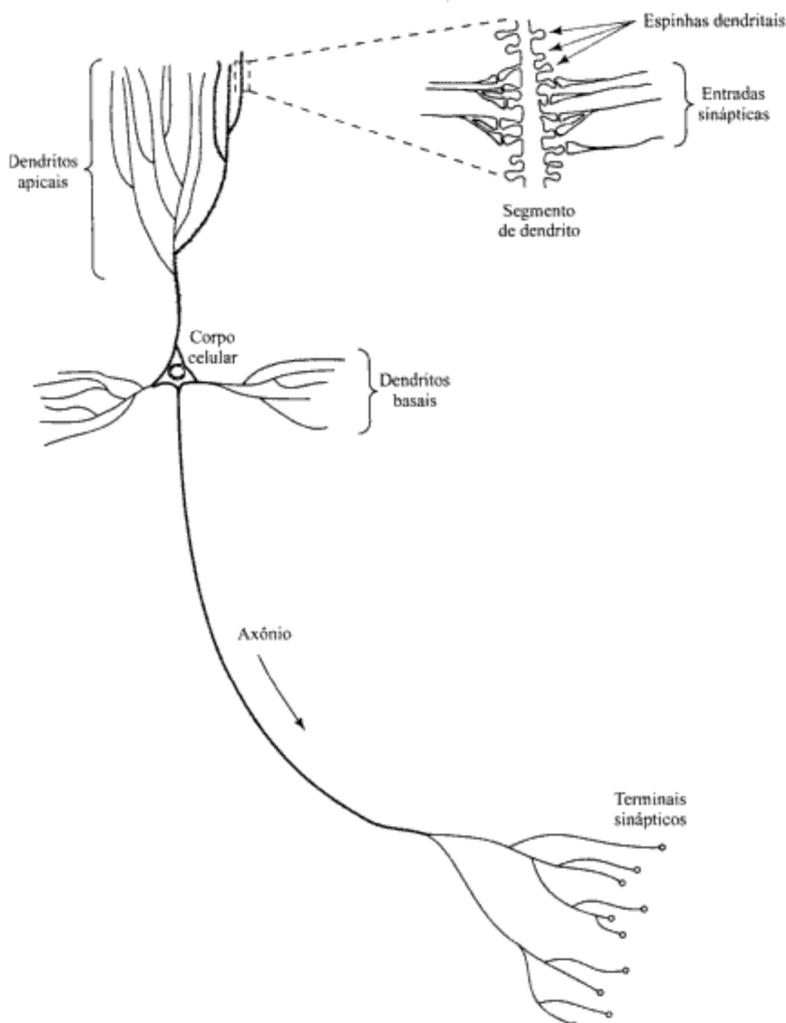


Figura 11: Exemplo de um neurônio biológico. (HAYKIN,2001)

Os neurônios se comunicam através de sinapses. Sinapse é a região onde dois neurônios entram em contato e através da qual os impulsos nervosos são transmitidos entre eles.

Os impulsos recebidos por um neurônio A, em um determinado momento, são processados, e atingindo um dado limiar de ação, o neurônio A dispara, produzindo uma substância neurotransmissora que flui do corpo celular para o axônio, que pode estar conectado a um dendrito de um outro neurônio B. O neurotransmissor pode diminuir ou aumentar a polaridade da membrana pós-sináptica, inibindo ou excitando a geração dos pulsos no neurônio B. Este processo depende de vários fatores, como a geometria da sinapse e o tipo de neurotransmissor.

Em média, cada neurônio forma entre mil e dez mil sinapses. O cérebro humano possui cerca de  $10^{11}$  neurônios, e o número de sinapses é de mais de  $10^{14}$ , possibilitando a formação de redes muito complexa.

Um histórico resumido sobre Redes Neurais Artificiais deve começar por três das mais importantes publicações iniciais, desenvolvidas por: McCulloch e Pitts (1943), Hebb (1949), e Rosenblatt (1958). Estas publicações introduziram o primeiro modelo de redes neurais simulando “máquinas”, o modelo básico de rede de auto-organização, e o modelo Perceptron de aprendizado supervisionado, respectivamente.

Alguns históricos sobre a área costumam “pular” os anos 60 e 70 e apontar um reinício da área com a publicação dos trabalhos de Hopfield (1982) relatando a utilização de redes simétricas para otimização e de Rumelhart, Hinton e Williams que introduziram o algoritmo de aprendizado “Backpropagation” (retropropagação).

Nos anos 60 e 70, importantes trabalhos sobre modelos de redes neurais em visão, memória, controle e auto-organização foram publicados por diversos autores conforme mencionado em (HAYKIN,2001).

Uma rede neural artificial, é composta por várias unidades de processamento, cujo funcionamento é bastante simples. Essas unidades, geralmente são conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões.

O comportamento inteligente de uma Rede Neural Artificial vem das interações entre as unidades de processamento da rede.

A operação de uma unidade de processamento, proposta por McCulloch e Pitts em 1943, pode ser resumida da seguinte maneira:

- Sinais são apresentados à entrada;
- Cada sinal é multiplicado por um número, ou peso, que indica a sua influência na saída da unidade;
- É feita a soma ponderada dos sinais que produz um nível de atividade;

- Se este nível de atividade exceder um certo limite (threshold) a unidade produz uma determinada resposta de saída.

A Figura 12 nos mostra o esquema de unidade McCullock, uma das primeiras concepções de rede neural artificial.

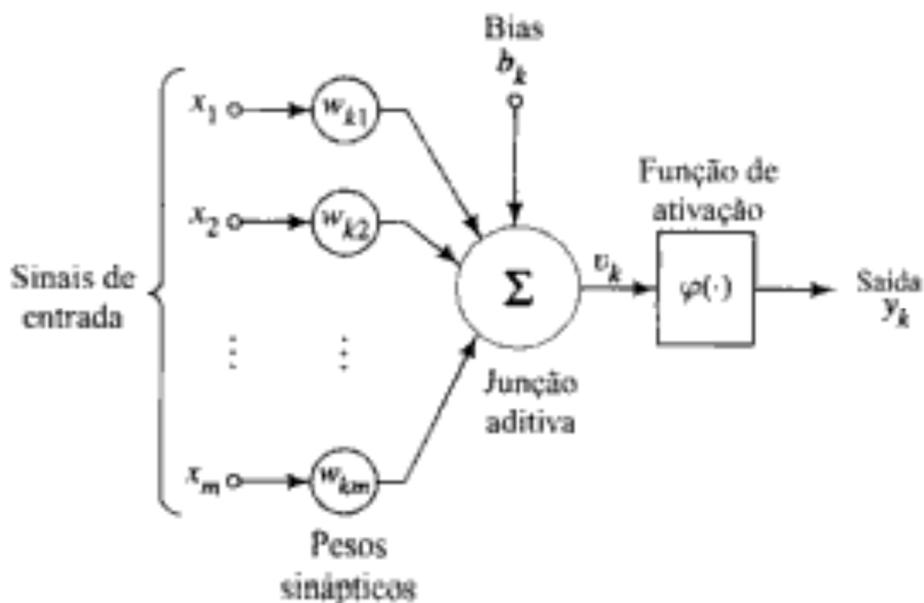


Figura 12: Esquema de unidade McCullock - Pitts. (HAYKIN,2001)

Suponha que tenhamos  $p$  sinais de entrada  $X_1, X_2, \dots, X_p$  e pesos  $W_1, W_2, \dots, W_p$  e um limitador  $t$ , com sinais assumindo valores booleanos (0 ou 1) e pesos valores reais.

Neste modelo, o nível de atividade  $a$  é dado por:

$$a = W_1X_1 + W_2X_2 + \dots + W_pX_p$$

A saída  $y$  é dada por:

$$y = 1, \text{ se } a \geq t \text{ ou}$$

$$y = 0, \text{ se } a < t.$$

A maioria dos modelos de redes neurais possui alguma regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, elas aprendem através de exemplos.

Arquiteturas neurais, são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior.

Usualmente as camadas são classificadas em três grupos:

- **Camada de Entrada:** onde os padrões são apresentados à rede;
- **Camadas Intermediárias ou Escondidas:** onde é feita a maior parte do processamento, através das conexões ponderadas; podem ser consideradas como extratoras de características;
- **Camada de Saída:** onde o resultado final é concluído e apresentado.

Uma rede neural é especificada, principalmente pela sua topologia, pelas características dos nós e pelas regras de treinamento. A Figura 13 nos mostra a estrutura de uma rede neural artificial.

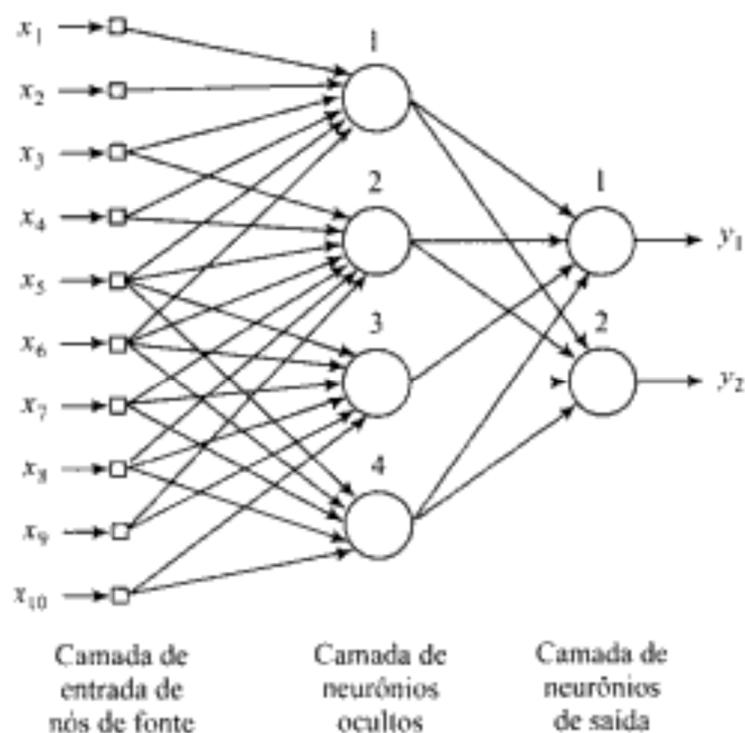


Figura 13: Estrutura de uma rede neural artificial (HAYKIN,2001)

O processo de aprendizado de uma rede neural pode ser considerado como sendo a propriedade mais importante, já que é onde se demonstra a habilidade de aprender de seu ambiente e com isso melhorar seu desempenho.

Isso é feito através de um processo iterativo de ajustes aplicado a seus pesos, o treinamento. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problema.

Denomina-se algoritmo de aprendizado, a um conjunto de regras bem definidas para a solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais, estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.

Outro fator importante é a maneira pela qual uma rede neural se relaciona com o ambiente. Nesse contexto existem os seguintes paradigmas de aprendizado:

- **Aprendizado Supervisionado**, quando é utilizado um agente externo que indica à rede a resposta desejada para o padrão de entrada;
- **Aprendizado Não Supervisionado** (auto-organização), quando não existe um agente externo indicando a resposta desejada para os padrões de entrada;
- **Reforço**, quando um crítico externo avalia a resposta fornecida pela rede.

Denomina-se época, uma apresentação de todos os  $N$  pares (entrada e saída) do conjunto de treinamento no processo de aprendizado. A correção dos pesos num ciclo pode ser executada de dois modos:

**1) Modo Padrão:** A correção dos pesos acontece a cada apresentação à rede de um exemplo do conjunto de treinamento. Cada correção de pesos baseia-se somente no erro do exemplo apresentado naquela iteração. Assim, em cada época ocorrem  $N$  correções.

**2) Modo Batch:** Apenas uma correção é feita por época. Todos os exemplos do conjunto de treinamento são apresentados à rede, seu erro médio é calculado e a partir deste erro fazem-se as correções dos pesos.

A rede perceptron de multicamadas (MLP), é uma rede neural que consiste de uma camada de entrada onde os padrões são apresentados à rede, uma ou mais camadas

intermediárias onde são realizadas a maioria dos processamentos por intermédio das conexões entre os neurônios, ou sinapses, que podem ser consideradas como sendo extratoras de características, e finalmente a camada de saída onde se faz a conclusão e a apresentação do resultado final. A Figura 14 nos mostra uma rede MLP, com duas camadas intermediárias.

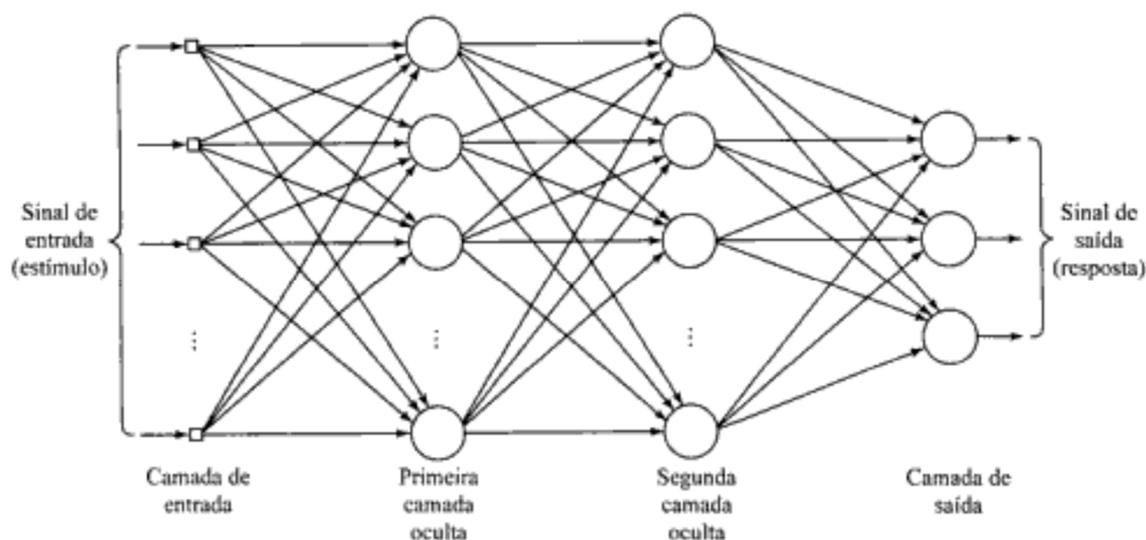


Figura 14: Estrutura de uma rede MLP (HAYKIN,2001)

Para um aprendizado supervisionado de uma rede neural, o algoritmo backpropagation tem sido utilizado para a solução de diversos problemas de classificação, e no que consiste este algoritmo, ele consiste basicamente de uma aprendizagem por retro propagação do erro. Esta aprendizagem se consiste de duas fases, nas quais cada fase percorre a rede em um sentido.

Na primeira fase, o sinal se propaga para a frente através da rede, camada por camada, definindo a saída da rede para um dado padrão de entrada. Na segunda fase, a resposta real da rede é subtraída de uma resposta desejada para produzir um sinal de erro, que então é propagado através da rede, contra a direção das conexões sinápticas para a atualização dos pesos, segundo uma regra para correção deste erro. A Figura 15 ilustra essas duas fases do algoritmo backpropagation.

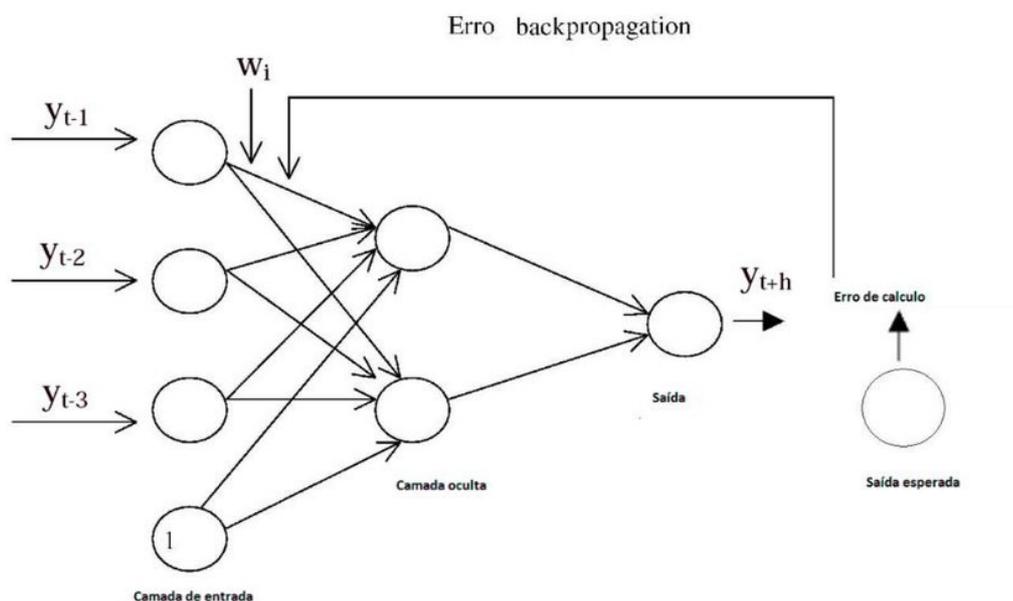


Figura 15: Fases do algoritmo backpropagation (CAMELO et ali,2017)

Para o algoritmo backpropagation, os ajustes dos valores das sinapses são atualizados conforme as equações que seguem:

$$\Delta W_{ji}(n) = \mu * \delta_j(n) * y_i(n)$$

$$\delta_j(n) = \frac{dF(a_j(n))}{da_j(n)} * \sum \delta_k(n) * W_{kj}(n)$$

Onde:

$\mu$  é a taxa de aprendizagem;

$k$  representa um neurônio da camada imediatamente posterior à camada do neurônio  $j$ ;

$\delta(n)$  é o gradiente local;

$y_i$  é a saída do neurônio  $i$ ;

$F(.)$  é a função de ativação;

$a_j(n)$  é a ativação do neurônio  $j$ ;

$W_{ki}$  é a sinapse entre o neurônio  $k$  e o neurônio  $i$ ;

Então desta forma, depreende-se que, uma rede neural possui uma estrutura cujos pesos armazenam o conhecimento, muitas das vezes também denominados memórias da rede, e são ajustados de acordo com o erro que é encontrado. A rede neural é treinada até que o erro entre a saída e o objetivo seja satisfatório. São bastante utilizadas no reconhecimento de padrões ruidosos e/ou incompletos, e em cenários onde regras claras não podem ser facilmente formuladas.

No algoritmo de backpropagation, o desafio principal consiste em definir um algoritmo de aprendizagem para a atualização dos pesos das camadas intermediárias, possuindo a ideia central de que os erros dos elementos processadores da camada de saída (conhecido como treinamento supervisionado), são retro propagados para as camadas intermediárias.

### **3.2.3. Máquinas de Suporte de Vetores (SVM)**

Esta técnica possui uma abordagem estatística de aprendizagem, trazendo resultados com base na experiência e na observação dos dados, funcionando bem com uma dimensionalidade alta.

Basicamente, o algoritmo traz o conceito de hiperplano, o qual é definido como sendo um limite de decisão linear para a classificação. Os vetores de suporte são pontos de ambas as classes as quais deseja-se classificação que estão mais próximos do separador de classes, sendo sempre o número de vetores de suporte menor que a quantidade total de amostras. O separador ótimo é aquele que apresenta a maior margem possível entre a função de separação, que também é chamado de hiperplano de separação ou simplesmente hiperplano, e os vetores de suporte.

A função ou objetivo do algoritmo SVM, é a busca pelo hiperplano de margem máxima, que por definição, é o limite de decisão com maior margem de separação dos dados.

Sua aplicabilidade, consiste em resolver problemas tanto de classificação como problemas de regressão. Na SVM, o tempo de treinamento do modelo pode aumentar consideravelmente com a complexidade do problema e tamanho do conjunto de dados a ser aprendido, porém esta técnica geralmente apresenta boa acurácia, sendo utilizada em

algumas aplicações complexas, tais como reconhecimento de objetos e reconhecimento de fala.

No caso de dados linearmente separáveis, a SVM procura o hiperplano de margem máxima. A Figura 16 nos mostra um exemplo gráfico do SVM.

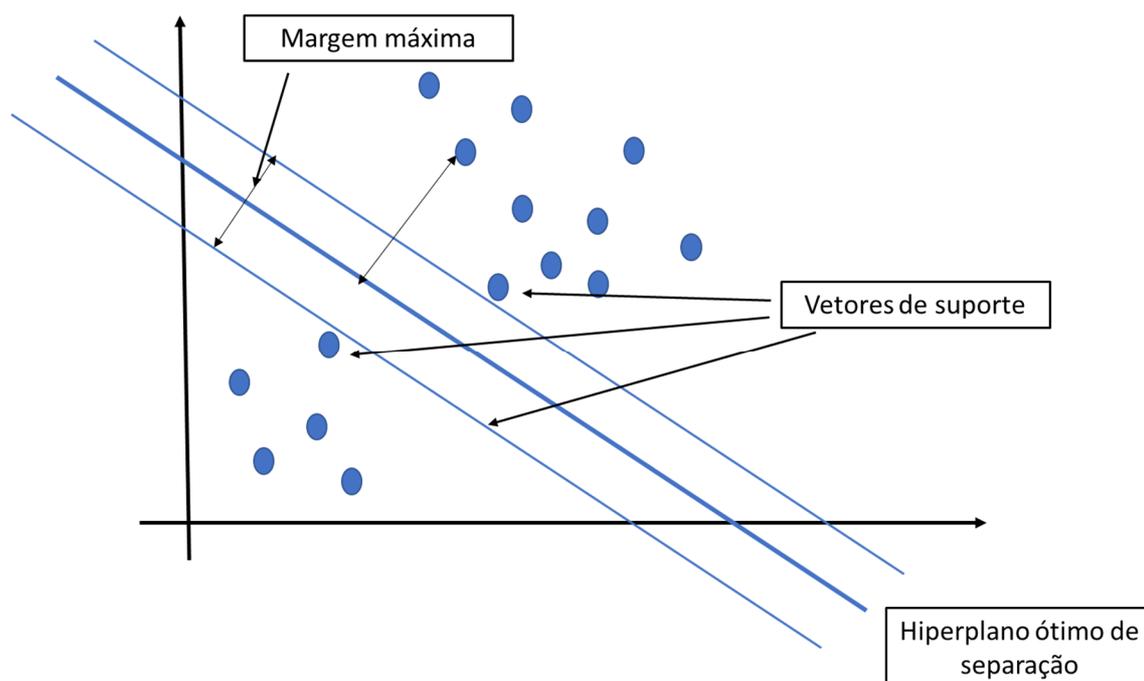


Figura 16: Exemplo gráfico de SVM.

Caso os dados não sejam linearmente separáveis, a SVM utiliza funções (kernel) de forma a transformar os dados de forma que um hiperplano possa ser aplicado. Funções comumente utilizadas podem ser lineares, polinomiais e funções de base radial (do inglês, radial base functions, RBF). Estas últimas têm sido bastante aplicadas a problemas não lineares complexos.

## 4. APLICAÇÃO NO PROBLEMA PROPOSTO

### 4.1. OS TRANSIENTES/ACIDENTES EM USINAS NUCLEARES

#### 4.1.1. A Segurança Operativa de uma Usina Nuclear

Na operação de uma usina nuclear, o papel do operador é fundamental para o funcionamento dentro dos rígidos padrões de segurança e operacionalidade da mesma. Esta tarefa, é uma tarefa bastante complexa, e a tomada de decisão envolve diversos tipos de tarefas conforme mostrado no fluxograma da Figura 17.

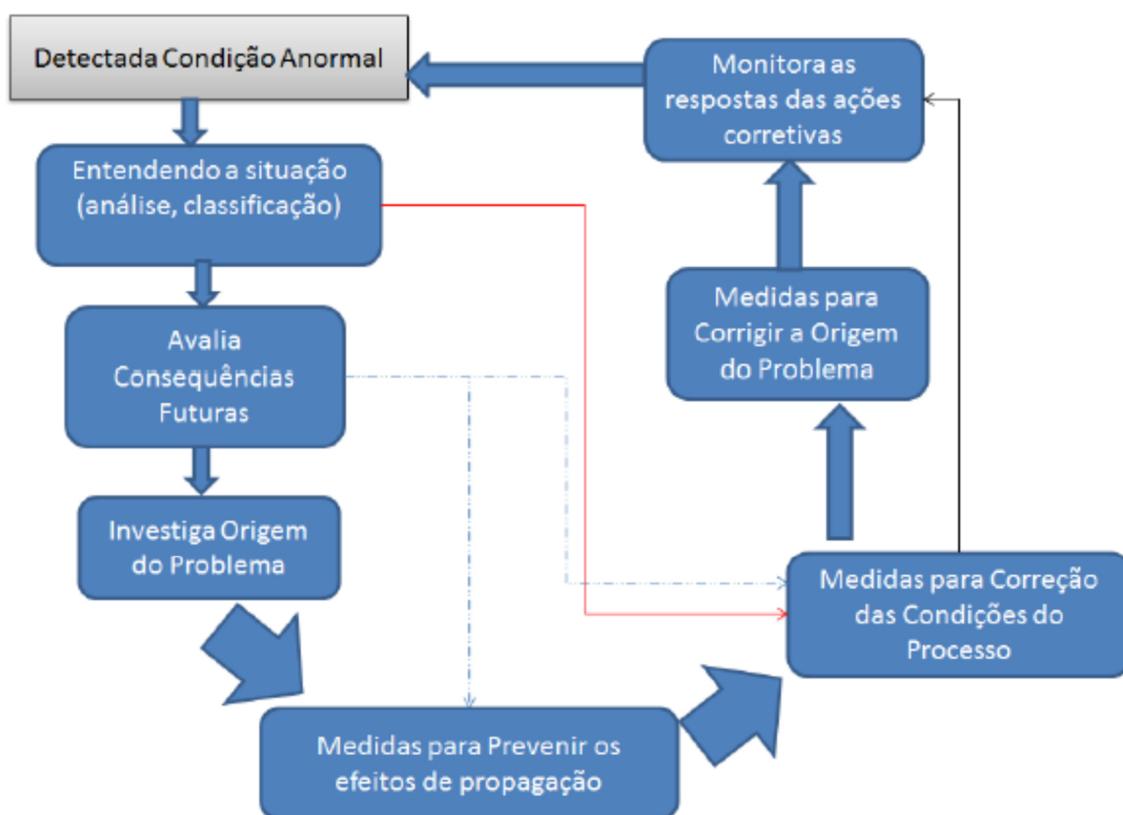


Figura 17: Fluxograma de ações operativas

No caso da ocorrência de uma operação adversa, é necessário que haja um tempo suficiente para que o operador possa atuar, executando as rotinas operativas necessárias para

a correção do defeito. Em uma planta nuclear, diversos sistemas estão envolvidos em sua operação, os quais a qualquer momento podem apresentar uma falha ou defeito.

Dentro de um critério operativo de observabilidade por parte do operador, as condições da usina que são monitoradas, apresentam parâmetros já estudados em várias fases anteriores à operação propriamente dita, os quais são divididos e relacionados dentro de critérios e condições de suas ocorrências quanto à frequência, probabilidade e risco.

Assim, pode-se considerar a seguinte classificação das referidas condições, conforme mostrado em (ALVES,1993):

#### Condição I: Operação normal e transientes operacionais.

As ocorrências de condição I são aquelas consideradas normais ou esperadas no decurso da operação, recarga ou manutenção da usina. Dessa forma, as ocorrências desta condição têm suas margens de segurança fixadas de modo que os parâmetros monitorados estejam bem abaixo dos valores que requerem ações corretivas automáticas ou manuais.

Elas ocorrem de forma regular e frequente, e devem ser consideradas do ponto de vista de afetação de consequências posteriores como sendo, fatores iniciais de falhas de condições II, III e IV. A esse respeito, a análise de cada condição de falha descrita é geralmente baseada em um conjunto conservador de condições iniciais correspondente ao conjunto mais adverso de condições que podem ocorrer durante a operação.

Alguns eventos de condição I, são listados a seguir:

- Variações de até 15% da potência nominal;
- “Hotshutdown” (desligamento a quente): Estado subcrítico e sistema de remoção de calor residual isolado;
- “Coldshutdown” (desligamento a frio): Estado subcrítico e sistema de remoção de calor residual em operação;
- Perda de elemento combustível devido a defeito nas varetas de elemento combustível;
- Alto nível de radioatividade no refrigerante do reator;
- Recarga de elementos combustíveis;

- Testes em equipamentos e sistemas;

#### Condição II: Falhas de frequência moderada.

Estas falhas, quando muito, resultam em “trip” (desligamento) do reator, e após a identificação da falha, a usina pode retomar normalmente a operação.

Por definição, essas falhas ou eventos, não se propagam para causar uma falha mais séria, ou seja, de condições III ou IV.

Da mesma forma, não se espera dos eventos desta condição que ocasionem deterioração do combustível ou pressurização excessiva do sistema de refrigeração do reator.

Alguns eventos desta condição são listados a seguir:

- Retirada descontrolada do banco de barras de controle a partir de uma condição subcrítica;
- Retirada descontrolada do banco de barras de controle em operação normal;
- Desalinhamento do banco de barras de controle;
- Diluição descontrolada de boro;
- Perda parcial da vazão forçada de refrigerante do reator;
- Partida de um loop inativo de refrigerante do reator;
- Perda de energia elétrica externa e/ou “trip” (desligamento) da turbina;
- Perda de água de alimentação principal;
- Perda de energia elétrica externa para operação de equipamentos auxiliares (blackout);
- Remoção excessiva de calor devido ao mau funcionamento do sistema de água de refrigeração principal;
- Incremento excessivo de carga;
- Despressurização acidental do sistema principal de vapor;
- Atuação inadvertida do sistema de injeção de segurança durante a operação normal;

### Condição III: falhas pouco frequentes.

Por definição, as ocorrências desta condição, são falhas muito difíceis de ocorrer durante a vida útil de um reator nuclear. No pior caso, elas provocam apenas falha em uma pequena fração de varetas de combustível.

Entretanto, pode ocorrer um dano no combustível suficiente para impossibilitar a retomada da operação da usina por um período de tempo considerável.

A liberação da radioatividade não é suficiente para interromper ou restringir o uso público das áreas em torno do raio de exclusão.

Esse tipo de falha, não é capaz de gerar, sozinha, uma falha de condição IV ou resultar em consequente perda do funcionamento do sistema de refrigeração do reator ou das barreiras de contenção.

São as seguintes as falhas de condição III:

- Perda de refrigerante do reator a partir de rupturas em pequenos condutos ou de quebras em tubos de grosso calibre, que atuam o sistema de refrigeração de emergência;
- Quebra(s) na(s) tubulação(ões) do sistema secundário;
- Carregamento inadvertido de um banco de elemento combustível em uma posição inapropriada;
- Perda total do fluxo forçado de refrigeração do reator;
- Ruptura do tanque de decaimento de gases radioativos;
- Retirada descontrolada de um banco de barras de controle a plena potência;

### Condição IV: Falhas limitantes.

São falhas que não são esperadas que ocorram, mas que são postuladas porque, entre suas consequências, pode ser incluída a liberação de quantidades significativas de material radioativo. São as falhas mais drásticas que podem ocorrer em uma usina nuclear.

Uma única falha desta condição não deve ser suficiente para causar uma consequente perda das funções requeridas dos sistemas necessários para lidar com a falha em questão,

incluindo-se o sistema de refrigeração da emergência do núcleo do reator e os de integridade da contenção.

Nesta condição, estão inclusas as seguintes falhas:

- Ruptura dos tubos por onde passa o refrigerante do reator até e inclusive a ruptura tipo guilhotina também conhecida como “Double End Rupture” da tubulação mais larga no sistema de refrigeração do reator. Essa falha é mais conhecida como LOCA (Loss of Coolant Accident);
- Ruptura das tubulações do sistema secundário até e inclusive o ponto de ruptura tipo guilhotina das linhas de vapor;
- Ruptura nos tubos de um gerador de vapor;
- Travamento do rotor de uma bomba de refrigeração do reator;
- Acidente no manejo do combustível;
- Ruptura de um montante de mecanismo de barras de controle (RCCA Ejection)

Caso haja, uma evolução das condições adversas, e elas não forem corretamente diagnosticadas, ou mesmo que não haja tempo hábil para sua solução, isto poderá acarretar consequências indesejáveis, tanto para o ser humano, quanto para o meio ambiente.

O objetivo principal da operação de uma usina nuclear, é de que ela seja realizada de forma eficiente e segura, com isso, existe a necessidade veemente de se proceder com o monitoramento dos diversos sistemas nela existentes.

Estes sistemas, tem a função de fornecer ao operador as informações pertinentes aos seus estados operativos, para que as decisões devidas devam ser tomadas e sejam efetuados os procedimentos necessários para se manter a operação da usina em suas condições normais.

Na execução de suas atividades, os operadores efetuam o monitoramento de um grande número de medidas, que são obtidas através dos sistemas de instrumentação, e que na ocorrência de uma condição adversa, devem identificar e diagnosticar a situação que está ocorrendo, de onde partir-se-á para uma análise e posterior classificação das medições correspondentes ao evento em curso.

A grande quantidade de instrumentos junto com a dinâmica da variação das medidas das grandezas que são associadas ao evento em curso, é um fator agregador de dificuldades de nível grande ao processo de identificação para posterior tomada de decisão por parte do operador, aumentando assim, a probabilidade de se ocorrer ações inadequadas, e assim produzir resultados catastróficos, alguns conhecidos na história da geração de energia de fonte termonuclear, que foram os acidentes de “Tree Mile Island” e ‘Chernobyl’.

#### 4.2. SIMULAÇÕES NO LABORATÓRIO DE INTERFACE HOMEM SISTEMA

Para esta dissertação, foram utilizados recursos do LABIHS – Laboratório de Interface Humano Sistema, do Instituto de Engenharia Nuclear (IEN/CNEN). O laboratório é composto de uma sala de controle digital onde, são simulados os processos e a operação de uma planta nuclear de potência, tipo PWR (Pressurized Water Reactor), sendo composto em seu ambiente de treinamento, de 3(três) postos de operadores, 1(um) posto de supervisor de operação, uma sala anexa (sala do instrutor), onde são definidos os cenários de operação do reator nuclear e gravados os dados da operação para posterior avaliação, com base nas ferramentas de análise de fatores humanos.

No LABIHS também são realizados pesquisas e projetos nas áreas de desenvolvimento e avaliação de interfaces avançadas para salas de controle, avaliação de desempenho humano em situações de emergência, análise de confiabilidade humana, que compõem o escopo principal da engenharia de fatores humanos.

O coordenador de treinamento ou instrutor, tem a função de inserir defeitos ou falhas para que os que estejam trabalhando ou treinando, possam praticar de forma mais eficiente, a operação de uma usina nuclear, vivenciando todas as possibilidades de defeitos, falhas e acidentes que são inerentes à operação de uma usina real. Na Figura 18 observa-se uma fotografia da sala de controle do LABIHS.



Figura 18: Vista parcial da sala de controle do LABIHS (IEN 2018)

O simulador possui um banco de dados composto pelos sistemas e equipamentos existentes dentro de uma usina nuclear, e também dos acidentes possíveis de ocorrer durante sua operação. Estes sistemas são inseridos, conforme mencionado anteriormente, para a atuação dos operadores, sendo este o objetivo principal no seu treinamento e formação.

Para a realização da coleta de dados para esta dissertação, foram inseridos acidentes e situações operacionais sem qualquer atuação humana, para se ter, a real noção do que realmente pode acontecer dentro de uma usina nuclear em caso da atuação humana ser ineficaz ou até mesmo nula.

Foram coletados os resultados das simulações operativas existentes no banco de dados de sistemas e acidentes, cujas condições de sua ocorrência são pré-definidas, e estão contidas no manual do simulador, explicitadas nas tabelas 1 a 13.

Em cada uma das tabelas, consta o número relativo ao que foi simulado, com a descrição referente, e o código, que são inseridos no simulador quando foram realizados os experimentos simulados dos transientes e acidentes.

Algumas tabelas, possuem em suas colunas de código e descrição, indicações de se procurar em outra tabela valores e descrições complementares dos acidentes que foram simulados.

As tabelas descrevem, para cada um dos acidentes, sistemas e equipamentos principais componentes de uma usina nuclear, e os possíveis acidentes, que podem vir a ocorrer dentro de uma usina nuclear.

Quando se fala em acidentes, os mais lembrados são os acidentes postulados, acidentes com maior risco e danos tanto para a usina, quanto para seus funcionários, e em caso de acontecer uma perda de material radioativo para fora da contenção da usina, riscos para a população e para o meio ambiente são grandes e com consequências sérias.

Dentro deste escopo, a tabela que trata de acidente com perda de refrigerante, cuja sigla em inglês é LOCA (Loss of Coolant Accident), mostra as causas de sua ocorrência, o vazamento de refrigerante do reator na contenção, ou no sistema secundário, ruptura dos tubos do gerador de vapor, transientes de parada de bomba de refrigeração, ruptura de linha de vapor.

Segue assim, para cada equipamento e sistema contido na usina, tabelas com suas indicações de acidentes.

No pressurizador (Tabela 2), tem-se as indicações de falhas de pressão, e problemas em suas válvulas e controles.

Na bomba de refrigeração do reator (Tabela 3), falhas em seu fluxo, desligamento, falhas na vedação, quebra e travamento de eixo.

Na questão do gerador de vapor (Tabela 4), seus acidentes possíveis, são as indicações de falhas em seus níveis de vapor, com suas respectivas dimensões, falha de pressão e perda do sinal do controlador de nível.

O sistema de controle químico e de volume (Tabela 5), apresenta as falhas, perda de controle de nível, perda de bomba de carregamento, vazamentos nos trocadores de calor do regenerador e de baixa, bloqueio da água de mistura e ruptura da linha de carregamento.

No sistema de remoção do calor residual (Tabela 6), as faltas são, trip do disjuntor da bomba, falhas em posicionamento das válvulas de descarga e by-pass, perda de bomba e vazamento no RHR.

A turbina e seu sistema (Tabela 9), apresentam problemas de trip, falha na válvula de controle e no retorno automático.

Com relação ao condensador e do sistema do condensado (Tabela 10), as falhas listadas são vazamento de ar, perda do ejetor, perda da bomba de água de circulação e trip do disjuntor da bomba.

Nos sistemas de água de alimentação (Tabela 11) e seu sistema auxiliar (Tabela 12), as falhas são referidas a trip de disjuntor e bombas, posicionamento incorreto das válvulas, tanto em fechamento, quanto em abertura e rupturas das linhas de alimentação de água.

Os sistemas diversos (Tabela 13), tem suas falhas indicadas em falha de instrumentação nuclear, rejeição de carga e perda de alimentação de energia externa.

Cabe-se ressaltar que nem todas as falhas foram listadas, elas são melhores elencadas em seus referidos sistemas e equipamentos nas tabelas a seguir.

Tabela 1 – Acidente com Perda de Refrigerante (LOCA)

NÚMERO	DESCRIÇÃO	CÓDIGO	DESCRIÇÃO
12	vazamento de refrigerante do reator na contenção ou no sistema secundário com dimensões de até 10% da área do tubo primário	80050 (1)	Vide Tabela 14
13	ruptura dos tubos do gerador de vapor	30005 (2)	Vide Tabela 14
14	transientes da parada da bomba de refrigeração do reator	1	RCP #1
15	PORV do pressurizador com abertura trancada	50%	abertura (1-100 %)
16	SV do pressurizador com abertura trancada	50%	abertura (1-100 %)
17	vazamento não isolável da água de alimentação	20010 (3)	Vide Tabela 14
18	ruptura da linha de vapor (isolável)	10020 (4)	Vide Tabela 14

Tabela 2 – Pressurizador

NÚMERO	DESCRIÇÃO	CÓDIGO	DESCRIÇÃO
19	indicação de falha alta (high)/ baixa (low) (dimensões ampla(W) / estreita(N)) da pressão no pressurizador	11	falha alta (W)
		12	falha baixa (W)
		21	falha alta (N)
		22	falha baixa (N)
20	indicação de falha alta ou baixo do nível do pressurizador	1	falha alta
		2	falha baixa
21	perda proporcional dos aquecedores do pressurizador	1	perda dos aquecedores
22	válvula de spray do pressurizador aberta, falha no fechamento ou emperramento	1	totalmente aberta
		2	falha no fechamento
		3	emperrada
23	falha no controladore de pressão do pressurizador (para máximo ou mínimo)	1	falha máxima
		2	falha mínima

Tabela 3 – Bomba de Refrigeração do Reator (RCP)

NÚMERO	DESCRIÇÃO	CÓDIGO	DESCRIÇÃO
24	1 bomba de refrigeração do reator (RCP) com fluxo alto de retorno na vedação	1	RCP #1
		2	RCP #2
		3	RCP #3
25	1 bomba de refrigeração do reator (RCP) com fluxo baixo de retorno na vedação & alta temperatura	1	RCP #1
		2	RCP #2
		3	RCP #3
26	desligamento (trip) da bomba de refrigeração do reator (RCP)	1	RCP #1
		2	RCP #2
		3	RCP #3
27	falha do fechamento da vedação da válvula de injeção	1	falha no fechamento
28	quebra do eixo a bomba	1	RCP #1
		2	RCP #2
		3	RCP #3
29	travamento do rotor	1	RCP #1
		2	RCP #2
		3	RCP #3

Tabela 4 – Gerador de Vapor (S/G)

NÚMERO	DESCRIÇÃO	CÓDIGO	DESCRIÇÃO
30	indicação de falha de nível alto(H)/baixo(L) de grande dimensão (W) e pequena dimensão(N) do nível do gerador de vapor(S/G)	11	S/G #1 high failure (W)
		12	S/G #1 low failure (W)
		13	S/G #1 high failure (N)
		14	S/G #1 low failure (N)
		21	S/G #2 high failure (W)
		22	S/G #2 low failure (W)
		23	S/G #2 high failure (N)
		24	S/G #2 low failure (N)
		31	S/G #3 high failure (W)
		32	S/G #3 low failure (W)
		33	S/G #3 high failure (N)
		34	S/G #3 low failure (N)
31	indicação de falha de pressão (alta(H)/baixa(L)) do gerador de vapor (S/G)	11	S/G #1 high failure
		12	S/G #1 low failure
		21	S/G #2 high failure
		22	S/G #2 low failure
		31	S/G #3 high failure
32	perda de sinal de nível do gerador de vapor (do controlador de nível)	32	S/G #3 low failure
		1010 (5)	Vide Tabela 14

Tabela 5 – Sistema de Controle Químico e de Volume

NÚMERO	DESCRIÇÃO	CÓDIGO	DESCRIÇÃO
33	falha na parte alta do SI	1	falha
34	falha no controle de nível VCT	1	Level high failure
		2	Level low failure
35	perda da bomba de carregamento	1	Charging pump #1
		2	Charging pump #2
		3	Charging pump #3
36	vazamento do trocador de calor do regenerador	50%	Leak in % (1-100)
37	vazamento do trocador de calor de baixa	50%	Leak in % (1-100)
38	ruptura da linha de carregamento (isolável)	50%	Rupture in % (1-100)
39	bloqueio da água de mistura	100%	falha

Tabela 6 – Sistema de Remoção do Calor Residual

NÚMERO	DESCRIÇÃO	CÓDIGO	DESCRIÇÃO
40	trip" do disjuntor da bomba	1	Trip
41	falha de posicionamento da válvula de descarga	1	Fully open
		2	Fails close
		3	Stuck in position
42	falha de posicionamento da válvula de "bypass"	1	Fully open
		2	Fails close
		3	Stuck in position
43	RHR vazamento do trocador de calor	50%	Leak in % (1-100)
44	perda da bomba do RHR	1	Loss

Tabela 7 – Sistema de Ejeção de Vapor

NÚMERO	DESCRIÇÃO	CÓDIGO	DESCRIÇÃO
45	HP TBN bypass v/v e despejo de vapor v/v fechado sem demanda	1	Closed
46	HP TBN bypass v/v e despejo de vapor v/v travado aberto	1	Open
47	HP TBN bypass v/v e despejo de vapor v/v aberto sem demanda	1	Open

Tabela 8 – Sistema Principal de Vapor

NÚMERO	DESCRIÇÃO	CÓDIGO	DESCRIÇÃO
48	Indicação de falha alta/baixa do fluxo principal de vapor	1	High failure
		2	Low failure
49	Indicação de falha alta/baixa de pressão de vapor no header principal	1	High failure
		2	Low failure
50	Fechamento MSIV	1	MSIV #1
		2	MSIV #2
		3	MSIV #3
51	Falha no fechamento MSIV	1	MSIV #1
		2	MSIV #2
		3	MSIV #3
52	Ruptura não isolável na tubulação de vapor principal (dentro ou fora da contenção)	110000	#1 (inside)
		120000	#2 (inside)
		130000	#3 (inside)
		210000	#1 (outside)
		220000	#2 (outside)
		230000	#3 (outside)
53	Válvula de segurança do gerador de vapor travada em aberto	1	#1
		2	#2
		3	#3
54	Válvula de controle de suprimento de vapor do reaquecedor fechada	1	closed

Tabela 9 – Sistema da Turbina

NÚMERO	DESCRIÇÃO	CÓDIGO	DESCRIÇÃO
55	Trip (desligamento) da turbina	1	Trip
56	Falha na válvula de controle da turbina	1	Close
		2	Open
57	Bloqueio da válvula de controle da turbina	1	Stuck
58	Falha no retorno automático da turbina	1	Failure

Tabela 10 – Condensador e Sistema do Condensado

NÚMERO	DESCRIÇÃO	CÓDIGO	DESCRIÇÃO
59	Vazamento de ar no condensador	50%	Leak area in % (1-100)
60	perda do ejetor de ar	1	Activate
61	Vazamento no tubo do condensador	1	Flow rate
62	Perda da bomba de água de circulação do condensador	1	Trip
63	Trip do disjuntor da bomba de condensado	1	Pump #1
		2	Pump #2
		3	Pump #3

Tabela 11 – Sistema de Água de Alimentação

NÚMERO	DESCRIÇÃO	CÓDIGO	DESCRIÇÃO
64	Aquecedor de Alta pressão da água de alimentação nível alto	1	High-high level
65	Perda dos aquecedores de água de alimentação	1	Loss of heaters
66	Bypass dos pré-aquecedores da água de alimentação	1	Bypass
67	Trip da bomba de água de alimentação	1	Pump #1
		2	Pump #2
		3	Pump #3
68	Todas as válvulas de água de alimentação abertas	1	Activate
69	Ruptura da linha de água de alimentação dentro da contenção	10020	loop #1 break size 20 cm <sup>2</sup>
70	Fechamento de todas as válvulas da água de alimentação	1	Activate
71	Falha no controlador da água de alimentação (perda do sinal do fluxo)	1	Loop #1
		2	Loop #2
		3	Loop #3

Tabela 12 – Sistema Auxiliar de Água de Alimentação

NÚMERO	DESCRIÇÃO	CÓDIGO	DESCRIÇÃO
72	Perda da água de alimentação auxiliar	1	Loss of AFW
73	Fluxo incontrolável da água de alimentação auxiliar	1	Uncontrollable
74	Trip da bomba do sistema da água de alimentação auxiliar (AFWP1)	1	Trip
75	Trip do disjuntor da bomba de água de serviço	1	Trip

Tabela 13 – Sistemas Diversos

NÚMERO	DESCRIÇÃO	CÓDIGO	DESCRIÇÃO
76	Falha de Instrumentação nuclear (NIS)	1	SRM
		2	IRM
		3	PRM
77	Falha axial	1	Bank #1
		2	Bank #2
		3	Bank #3
		4	Bank #4
		5	Bank #5
		6	Bank #6
		7	Bank #7
		8	Bank #8
78	Rejeição de carga	1	Activate
79	Perda da energia de alimentação externa	1	Activate

Conforme pode ser notado, em algumas tabelas anteriormente mostradas, existe uma indicação para se buscar maiores informações na tabela de descrição de códigos.

Esta descrição está presente, pois os sistemas e/ou acidentes a elas referidos, possuem um “set” de condições para o evento em si, diferente dos demais, e que possui uma gama muito grande de variações e combinações possíveis, logo, nas tabelas dos acidentes e/ou sistemas, estão os códigos referentes ao que foi simulado para cada evento em questão. A tabela 14 nos mostra estes códigos.

Tabela 14 – Descrição dos Códigos

Tabela Descrição de Código			Código
1	node 8 *1000	break size 50 cm <sup>2</sup>	80050
2	loop 3 *1000	break size 5cm <sup>2</sup>	30005
3	loop 2*1000	leak size 10 cm <sup>2</sup>	20010
4	loop 1*1000	leak size 20 cm <sup>2</sup>	10020
5	loop 1*1000	level 10%	1010

#### 4.2.1. Procedimento para realização das Simulações

O primeiro passo para a realização das simulações, no simulador do LABIHS, foi a escolha das variáveis que teriam os seus dados coletados.

Como grupo de variáveis escolhidas, escolheu-se um grupo de variáveis pertencente ao “Loop #2”, dentro da opção de três “Loops” existentes. Esta escolha foi baseada em (MOL,2002), e devido ao simulador possuir três Loops, o que poderia vir a constituir uma combinação de variáveis para simulação de acidentes muito grande, e que poderiam em alguns casos, serem similares e/ou repetitivas.

A tabela 15 a seguir, nos mostra as variáveis que foram escolhidas, bem como as suas respectivas descrições.

Tabela 15 - Listagem das Variáveis Utilizadas do Simulador

Variáveis	Descrição
UHOLEG2	hot leg #2 temperature
UCOLEG2	cold leg #2 temperature
ZINST80	% loop 2 flow
ZINST77	% S/G 2 level (narrow)
ZINST71	% S/G 2 level (wide)
ZINST74	S/G pressure (kg/cm <sup>2</sup> )
ZINST58	prz pressure (narrow range) (kg/cm <sup>2</sup> )
ZINST63	% prz level
WFWLN2	steam line #2 flow (kg/sec)
WSTM2	feed water line #2 flow (kg/sec)
KBCDO15	subcooled temperatura margin
KBCDO23	not used (but in this log have numbers)

Após a seleção de variáveis, foram executadas as simulações, das quais, obtiveram-se como resultados, os “logs” dos acidentes/transientes que foram utilizados como a base de dados, para posteriormente, serem utilizados nas técnicas de aprendizado de máquina para classificação, alvo desta dissertação, com seu objetivo na realização dos seus estudos comparativos.

Para a aquisição dos “logs”, que são os arquivos de saída das simulações contendo as variáveis escolhidas com os seus respectivos valores, foram utilizadas as seguintes condições de contorno conforme seguem:

- Tempo total de cada simulação para cada log: 7 minutos
- Intervalo de medição em cada um dos logs: 1 segundo
- Inserção do acidente/transiente em cada log: minuto 3

De posse destas condições de contorno, foram realizadas as simulações para obtenção dos referidos logs, sendo que cada log obtido se refere a uma condição mostrada nas tabelas de 1 a 13, anteriormente apresentadas dos sistemas e/ou acidentes.

Após a execução, os resultados foram exibidos em formato de arquivo texto padrão (formato .txt). Como dessa forma, os tratamentos dos dados ficam muito difíceis de se

realizar, optou-se, para facilitar seu tratamento para posterior utilização nas técnicas computacionais, utilizou-se a ferramenta EXCEL, onde o conjunto de dados foi tabulado em uma única planilha e pôde ser tratado de uma melhor forma para sua utilização posterior nas ferramentas computacionais.

A seguir temos um exemplo, na tabela 16, de como ficou o formato dos dados após sua aquisição e preparados para as aplicações das técnicas de aprendizado de máquina.

Tabela 16 – Tabela Exemplo com os dados de Saída do Simulador com as Variáveis utilizadas

System Parameter Logging Data														
SIM_TIME	UHOLEG2	UCOLEG2	ZINST80	ZINST71	ZINST77	ZINST74	WFWLN2	WSTM2	ZINST58	KBCDO23	KBCDO15	ZINST63	LOG ACIDENTE	GRUPO ACIDENTE
00:00:00	325.534	290.889	100.380	89.183	50.001	64.361	455.396	452.801	158.929	100	17	55.788	PARAMLOG_B-12	GRUPO B LOSS OF COOLANT ACCIDENT
00:00:01	325.534	290.890	100.380	89.184	50.002	64.361	455.403	452.793	158.928	100	17	55.789	PARAMLOG_B-12	GRUPO B LOSS OF COOLANT ACCIDENT
00:00:02	325.533	290.891	100.380	89.184	50.002	64.361	455.417	452.796	158.927	100	17	55.790	PARAMLOG_B-12	GRUPO B LOSS OF COOLANT ACCIDENT
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
00:00:00	325.534	290.889	100.380	89.183	50.001	64.361	455.396	452.801	158.929	100	17	55.788	PARAMLOG_B-13	GRUPO B LOSS OF COOLANT ACCIDENT
00:00:01	325.534	290.890	100.380	89.184	50.002	64.361	455.403	452.793	158.928	100	17	55.789	PARAMLOG_B-13	GRUPO B LOSS OF COOLANT ACCIDENT
00:00:02	325.534	290.891	100.380	89.184	50.002	64.361	455.415	452.807	158.928	100	17	55.790	PARAMLOG_B-13	GRUPO B LOSS OF COOLANT ACCIDENT
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
00:00:00	325.534	290.889	100.380	89.183	50.001	64.361	455.396	452.801	158.929	100	17	55.788	PARAMLOG_B-14	GRUPO B LOSS OF COOLANT ACCIDENT
00:00:01	325.534	290.890	100.380	89.184	50.002	64.361	455.403	452.793	158.928	100	17	55.789	PARAMLOG_B-14	GRUPO B LOSS OF COOLANT ACCIDENT
00:00:02	325.533	290.891	100.380	89.184	50.002	64.361	455.416	452.804	158.928	100	17	55.790	PARAMLOG_B-14	GRUPO B LOSS OF COOLANT ACCIDENT
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
00:00:02	325.533	290.891	100.380	89.184	50.002	64.361	455.417	452.796	158.927	100	17	55.790	PARAMLOG_B-15	GRUPO B LOSS OF COOLANT ACCIDENT
00:00:03	325.534	290.891	100.380	89.184	50.003	64.361	455.437	452.797	158.927	100	17	55.791	PARAMLOG_B-15	GRUPO B LOSS OF COOLANT ACCIDENT
00:00:04	325.534	290.891	100.380	89.184	50.003	64.361	455.456	452.794	158.926	100	17	55.791	PARAMLOG_B-15	GRUPO B LOSS OF COOLANT ACCIDENT
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
00:00:00	325.534	290.889	100.380	89.183	50.001	64.361	455.396	452.801	158.929	100	17	55.788	PARAMLOG_B-16	GRUPO B LOSS OF COOLANT ACCIDENT
00:00:01	325.534	290.890	100.380	89.184	50.002	64.361	455.403	452.793	158.928	100	17	55.789	PARAMLOG_B-16	GRUPO B LOSS OF COOLANT ACCIDENT
00:00:02	325.533	290.891	100.380	89.184	50.002	64.361	455.418	452.799	158.927	100	17	55.790	PARAMLOG_B-16	GRUPO B LOSS OF COOLANT ACCIDENT
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
00:08:00	303.717	287.376	4.480	50.849	0.000	73.311	12.000	0.000	151.570	0	37	35.825	PARAMLOG_N-79	GRUPO N MISCELANEUS SYSTEMS
00:08:01	303.717	287.385	4.479	50.865	0.000	73.317	12.000	0.000	151.607	0	37	35.843	PARAMLOG_N-79	GRUPO N MISCELANEUS SYSTEMS
00:08:02	303.718	287.393	4.479	50.880	0.000	73.323	12.000	0.000	151.644	0	37	35.861	PARAMLOG_N-79	GRUPO N MISCELANEUS SYSTEMS
00:08:03	303.718	287.402	4.478	50.893	0.000	73.329	12.000	0.000	151.681	0	37	35.879	PARAMLOG_N-79	GRUPO N MISCELANEUS SYSTEMS

Depois de tudo preparado, o conjunto de dados foi importado em um programa em linguagem PYTHON, implementando os algoritmos de classificação através da utilização do pacote SciKitLearn. As principais classes de objetos utilizados foram os listados a seguir:

- Classe SVC para Support Vector Machines, utilizado para classificação.
- Classe Redes Neurais Multi Layer Perceptron (MLP).

- Classe Random Forest Algorithm (RFA), com suas ferramentas intrínsecas “bagging” e “boosting”.

Devido a uma enorme gama de possíveis combinações de acidentes, escolheu-se para as simulações, alguns dos que foram considerados os mais severos e representativos dentro dos acidentes na operação de uma usina nuclear, cujas descrições encontram-se listadas nas tabelas anteriores, e com isso, foi preparado o conjunto de dados formado pelos 20 logs listados na Tabela 17 a seguir.

Tabela 17 – Lista dos logs utilizados

<b>Logs Escolhidos</b>	<b>Sistema</b>
PARAMLOG_B-12	Acidente com Perda de Refrigerante
PARAMLOG_B-13	Acidente com Perda de Refrigerante
PARAMLOG_B-14	Acidente com Perda de Refrigerante
PARAMLOG_B-15	Acidente com Perda de Refrigerante
PARAMLOG_B-16	Acidente com Perda de Refrigerante
PARAMLOG_B-17	Acidente com Perda de Refrigerante
PARAMLOG_B-18	Acidente com Perda de Refrigerante
PARAMLOG_L-64_OPTION-1	Sistema de Água de Alimentação
PARAMLOG_L-65_OPTION-1	Sistema de Água de Alimentação
PARAMLOG_L-66_OPTION-1	Sistema de Água de Alimentação
PARAMLOG_L-67_OPTION-1	Sistema de Água de Alimentação
PARAMLOG_L-67_OPTION-2	Sistema de Água de Alimentação
PARAMLOG_L-67_OPTION-3	Sistema de Água de Alimentação
PARAMLOG_L-68_OPTION-1	Sistema de Água de Alimentação
PARAMLOG_L-69_OPTION-10020	Sistema de Água de Alimentação
PARAMLOG_L-70_OPTION-1	Sistema de Água de Alimentação
PARAMLOG_L-71_OPTION-1	Sistema de Água de Alimentação
PARAMLOG_L-71_OPTION-2	Sistema de Água de Alimentação
PARAMLOG_L-71_OPTION-3	Sistema de Água de Alimentação
PARAMLOG_N-79_OPTION-1	Sistemas Diversos

A normalização de conjuntos de dados é um requisito comum para muitos estimadores de aprendizado de máquina implementados no scikit-learn, eles podem vir a se comportar de forma indevida se os recursos individuais não se parecerem mais ou menos com dados padrão normalmente distribuídos: Gaussiano com média zero e variância unitária.

Na prática, muitas vezes ignora-se a forma da distribuição e apenas transforma-se os dados para centralizá-los, removendo o valor médio de cada recurso e, em seguida, dimensionamos dividindo recursos não constantes por seu desvio padrão.

A pontuação padrão de uma amostra  $x$  é calculada como:

$$Z = (x - u) / s$$

Onde:

$u$  é a média das amostras de treinamento.

$s$  é o desvio padrão das amostras de treinamento.

A centralização e o dimensionamento acontecem independentemente em cada recurso, calculando as estatísticas relevantes nas amostras no conjunto de treinamento. A média e o desvio padrão são então armazenados para serem usados em dados posteriores usando a transformação.

Por exemplo, muitos elementos usados na função objetivo de um algoritmo de aprendizado (como o kernel RBF de Support Vector Machines ou os regularizadores L1 e L2 de modelos lineares) assumem que todos os recursos estão centrados em 0 e têm variância na mesma ordem. Se um recurso tem uma variância que é ordens de magnitude maior do que outros, ele pode dominar a função objetivo e tornar o estimador incapaz de aprender com outros recursos corretamente como esperado.

## 5. EXPERIMENTOS COMPUTACIONAIS E RESULTADOS OBTIDOS

Nas simulações feitas nesta dissertação, para cada um dos métodos utilizados, os principais hiperparâmetros foram variados de forma empírica (tentativas, análises e ajustes) na busca do melhor resultado (no caso presente, a acurácia de acertos). Todos os experimentos foram executados no ambiente Google COLAB e seguiram os seguintes passos elencados a seguir:

- Importação dos dados;
- Pré-processamento os dados;
- Selecionando os dados;
- Treinamento dos modelos de classificação;
- Aplicação dos modelos treinados em conjunto de testes;
- Avaliação dos modelos;
- Otimização dos modelos através de ajustes dos hiperparâmetros;

### 5.1. APLICAÇÃO DE REDES NEURAIIS MLP

Na aplicação das redes neurais, conforme mencionado anteriormente, foram realizadas algumas variações em seus parâmetros na busca para obtenção do melhor resultado a ser apresentado e tomado como melhor escolha para o mesmo, sendo obtidos os seguintes resultados com suas respectivas combinações paramétricas como segue.

#### 5.1.1. Rede Neural MLP1

Os resultados obtidos pela rede neural MLP1 são exibidos nas tabelas 18 e 19, respectivamente.

Tabela 18 - Parâmetros da rede neural MLP1

Função de Ativação	Relu
Camadas Escondidas (quantidade/tamanho)	1/32
Solver	lbfgs
Learning Rate	-

Tabela 19 – Resultados obtidos com a rede neural MLP1

Acurácia Treinamento	0,759
Acurácia Teste	0,762

### 5.1.2. Rede Neural MLP2

Os resultados obtidos pela rede neural MLP2 são exibidos nas tabelas 20 e 21, respectivamente.

Tabela 20 - Parâmetros da rede neural MLP2

Função de Ativação	Relu
Camadas Escondidas (quantidade/tamanho)	1/32
Solver	adam
Learning Rate	adaptative

Tabela 21 – Resultados obtidos com a rede neural MLP2

Acurácia Treinamento	0,823
Acurácia Teste	0,801

Sendo aqui limitado o número máximo de épocas em 20.000

### 5.1.3. Rede Neural MLP3

Os resultados obtidos pela rede neural MLP3 são exibidos nas tabelas 22 e 23, respectivamente.

Tabela 22 - Parâmetros da rede neural MLP3

Função de Ativação	Relu
Camadas Escondidas (quantidade/tamanho)	2/(32/32)
Solver	adam
Learning Rate	adaptative

Tabela 23 – Resultados obtidos com a rede neural MLP3

Acurácia Treinamento	0.828
Acurácia Teste	0.816

Sendo aqui limitado o número máximo de épocas em 20.000

#### 5.1.4. Rede Neural MLP4

Os resultados obtidos pela rede neural MLP4 são exibidos nas tabelas 24 e 25, respectivamente

Tabela 24 - Parâmetros da rede neural MLP4

Função de Ativação	Relu
Camadas Escondidas (quantidade/tamanho)	2/(32/32)
Solver	lbfgs
Learning Rate	-

Tabela 25 – Resultados obtidos com a rede neural MLP4

Acurácia Treinamento	0.850
Acurácia Teste	0.812

#### 5.1.5. Rede Neural MLP5

Os resultados obtidos pela rede neural MLP5 são exibidos nas tabelas 26 e 27, respectivamente.

Tabela 26 - Parâmetros da rede neural MLP5

Função de Ativação	Relu
Camadas Escondidas (quantidade/tamanho)	2/(64/64)
Solver	adam
Learning Rate	adaptative

Tabela 27 – Resultados obtidos com a rede neural MLP5

Acurácia Treinamento	0.772
Acurácia Teste	0.768

Sendo aqui limitado o número máximo de épocas em 20.000

### 5.1.6. Rede Neural MLP6

Os resultados obtidos pela rede neural MLP6 são exibidos nas tabelas 28 e 29, respectivamente.

Tabela 28 - Parâmetros da rede neural MLP6

Função de Ativação	Relu
Camadas Escondidas (quantidade/tamanho)	2/(64/64)
Solver	lbfgs
Learning Rate	-

Tabela 29 – Resultados obtidos com a rede neural MLP6

Acurácia Treinamento	0.850
Acurácia Teste	0.817

Sendo nesta simulação, o número máximo de épocas limitado a 10.000 interações.

### 5.1.7. Rede Neural MLP7

Os resultados obtidos pela rede neural MLP7 são exibidos nas tabelas 30 e 31, respectivamente.

Tabela 30 - Parâmetros da rede neural MLP7

Função de Ativação	Relu
Camadas Escondidas (quantidade/tamanho)	2/(64/64)
Solver	lbfgs
Learning Rate	-

Tabela 31 – Resultados obtidos com a rede neural MLP7

Acurácia Treinamento	0.850
Acurácia Teste	0.817

### 5.1.8. Rede Neural MLP8

Os resultados obtidos pela rede neural MLP8 são exibidos nas tabelas 32 e 33, respectivamente.

Tabela 32 - Parâmetros da rede neural MLP8

Função de Ativação	Relu
Camadas Escondidas (quantidade/tamanho)	2/(64/64)
Solver	lbfgs
Learning Rate	-

Tabela 33 – Resultados obtidos com a rede neural MLP8

Acurácia Treinamento	0.850
Acurácia Teste	0.817

Sendo aqui nesta simulação, a inserção do parâmetro de limitação de números máximos da função em 30.000.

### 5.1.9. Rede Neural MLP9

Os resultados obtidos pela rede neural MLP9 são exibidos nas tabelas 34 e 35, respectivamente.

Tabela 34 - Parâmetros da rede neural MLP9

Função de Ativação	Relu
Camadas Escondidas (quantidade/tamanho)	3/(64/128/64)
Solver	lbfgs
Learning Rate	-

Tabela 35 – Resultados obtidos com a rede neural MLP9

Acurácia Treinamento	0.850
Acurácia Teste	0.817

Sendo aqui nesta simulação, a inserção do parâmetro de limitação de números máximos da função em 30.000.

#### 5.1.10. Rede Neural MLP10

Os resultados obtidos pela rede neural MLP10 são exibidos nas tabelas 36 e 37, respectivamente.

Tabela 36 - Parâmetros da rede neural MLP10

Função de Ativação	Relu
Camadas Escondidas (quantidade/tamanho)	3/(64/128/64)
Solver	adam
Learning Rate	-

Tabela 37 – Resultados obtidos com a rede neural MLP10

Acurácia Treinamento	0.774
Acurácia Teste	0.755

Sendo aqui limitado o número máximo de épocas em 20.000.

#### 5.1.11. Rede Neural MLP11

Os resultados obtidos pela rede neural MLP11 são exibidos nas tabelas 38 e 39, respectivamente.

Tabela 38 - Parâmetros da rede neural MLP11

Função de Ativação	Relu
Camadas Escondidas (quantidade/tamanho)	1/32
Solver	adam
Learning Rate	0.01

Tabela 39 – Resultados obtidos com a rede neural MLP11

Acurácia Treinamento	0.819
Acurácia Teste	0.811

Sendo aqui inserido o tamanho de batch em 1.000, e, limitado o número máximo de épocas em 30.000

#### 5.1.12. Rede Neural MLP12

Os resultados obtidos pela rede neural MLP12 são exibidos nas tabelas 40 e 41, respectivamente.

Tabela 40 - Parâmetros da rede neural MLP12

Função de Ativação	Relu
Camadas Escondidas (quantidade/tamanho)	1/64
Solver	adam
Learning Rate	0.001

Tabela 41 – Resultados obtidos com a rede neural MLP12

Acurácia Treinamento	0.783
Acurácia Teste	0.768

Sendo aqui inserido o tamanho de batch em 1.000, e, limitado o número máximo de épocas em 30.000

Diante de todos os resultados apresentados nas simulações com suas respectivas variações de parâmetros, e tendo em vista também da grande variedade de possibilidades

para se testar parâmetros dentro das redes neurais, e em face do escopo da dissertação que se trata da comparação entre métodos classificatórios, o melhor resultado obtido com a rede neural foi o apresentado na Tabela 42:

Tabela 42 – Melhor resultado obtido com a rede neural

<b>Acurácia Treinamento</b>	<b>0.850</b>
<b>Acurácia Teste</b>	<b>0.817</b>

## 5.2. APLICAÇÃO DE FLORESTAS ALEATÓRIAS RFA

Na aplicação do algoritmo de florestas aleatórias (RFA), foram executadas simulações, com suas variações pertinentes aos parâmetros, apresentando os resultados, conforme mostrado na Tabela 43.

Tabela 43 – Parâmetros e Resultados obtidos com as simulações do Algoritmo RFA

n_estimators	criterion	bootstrap	Random state	Acurácia treinamento	Acurácia teste
10	gini	true	123	0.987	0.820
10	gini	false	123	0.986	0.823
10	entropy	true	123	0.986	0.823
10	entropy	false	123	1.000	0.817
100	gini	true	123	1.000	0.821
100	gini	false	123	1.000	0.835
100	entropy	true	123	1.000	0.817
100	entropy	false	123	1.000	0.832
1000	gini	true	123	1.000	0.821
<b>1000</b>	<b>gini</b>	<b>false</b>	<b>123</b>	<b>1.000</b>	<b>0.836</b>
1000	entropy	true	123	1.000	0.820
1000	entropy	false	123	1.000	0.829

Em face dos resultados apresentados nas simulações, temos que:

- 1 - Os resultados sofrem apenas pequenas variações com diferentes parâmetros.

- 2 - bootstrap = False melhor com todos os n\_estimators e criterion.  
 3 - criterion = 'gini' é melhor para mesmos n\_estimators e bootstrap.

Dentro do exposto de todos os resultados apresentados, nas simulações com suas respectivas variações de parâmetros, o melhor resultado obtido com o RFA foi o que está mostrado na Tabela 44:

Tabela 44 – Melhor resultado obtido com as simulações do Algoritmo RFA

<b>Acurácia Treinamento</b>	<b>1.000</b>
<b>Acurácia Teste</b>	<b>0,836</b>

### 5.3. APLICAÇÃO DE MÁQUINAS DE SUPORTES DE VETORES SVM

Na aplicação de SVM, utilizou-se o pacote SVC específico para classificação, e onde foram inseridas variações de parâmetros na busca de resultados ótimos, os quais são mostrados na Tabela 45.

Tabela 45 – Parâmetros e Resultados obtidos com as simulações de SVM

Kernel	C	gamma( $\gamma$ )	Random state	Acurácia treinamento	Acurácia teste
rbf	1.000.000	10.000	123	1.000	0.750
rbf	1.000.000	1.000	123	0.998	0.941
rbf	1.000.000	100	123	0.990	0.964
rbf	1.000.000	10	123	0.954	0.924
rbf	100.000	10.000	123	0.998	0.748
rbf	100.000	1.000	123	0.980	0.885
rbf	100.000	100	123	0.929	0.874
rbf	100.000	10	123	0.886	0.858

Em face dos resultados apresentados nas simulações, temos que:

- 1 - Testes prévios mostraram que o kernel = 'rbf' é o melhor, pois kernel = 'sigmoid', apresentou resultados muito piores em relação ao "rbf".
- 2 – Quanto maior for o hiperparâmetro C, o que parece é que se melhora a acurácia em geral.
- 3 – O hiperparâmetro gamma mais alto parece melhorar a acurácia no treinamento, entretanto, se o mesmo for muito alto, parece penalizar a acurácia do teste.

Dentro do exposto de todos os resultados apresentados nas simulações com suas respectivas variações de parâmetros, o melhor resultado obtido com o SVC foi o que está mostrado na Tabela 46.

Tabela 46 – Melhor resultado obtido com as simulações do SVC

<b>Acurácia Treinamento</b>	<b>0,990</b>
<b>Acurácia Teste</b>	<b>0,964</b>

Os resultados apresentados pelas diferentes técnicas utilizadas, são representados, de forma comparativa, na Tabela 47, com os resultados escolhidos de cada uma das técnicas aplicadas.

Tabela 47 – Resultados finais das simulações

<b>Método Aplicado</b>	<b>Acurácia Treinamento</b>	<b>Acurácia Teste</b>
<b>Redes Neurais(ANN)</b>	<b>0.850</b>	<b>0.817</b>
<b>Algoritmo de Florestas Aleatórias (RFA)</b>	<b>1.000</b>	<b>0,836</b>
<b>Máquina de Suporte Vetorial (SVM)</b>	<b>0,99</b>	<b>0,964</b>

Observa-se que as redes neurais tiveram um desempenho expressivamente inferior. Este fato pode ser dividido ao fato de terem sido utilizadas modelos mais básicos com poucas camadas e sem a utilização de mecanismos que pudessem proporcionar uma melhor convergência e generalização. Constatou-se que, para a aplicação de redes neurais, o problema torna-se mais complexo do ponto de vista de sua adaptação. A utilização de arquiteturas mais elaboradas, como redes profundas (com muitas camadas) e técnicas de regularização, talvez pudesse colocar os resultados em um patamar mais competitivo com

as outras técnicas. Entretanto o custo computacional para treinamento seria muito mais elevado, o que já é uma desvantagem da rede neural em relação aos outros métodos seria ainda mais acentuada. Enquanto as redes neurais testadas demoravam de 20 a 30 minutos para serem treinadas, as SVMs e RFAs gastam, no máximo, algo além de um minuto. Por conta disso, e do expressivo resultado obtido principalmente pelas SVMs, a investigação de redes mais elaboradas foi descartada.

Observa-se que tanto as SVMs quanto os RFAs foram capazes de obter uma acurácia de 100% no conjunto de treinamento, entretanto, a generalização ficou depreciada (acurácia de 75% para a SVM e 83% para o RFA).

Considerando o compromisso entre o treinamento e o teste, pode-se eleger a SVM (com acurácia de 99% para o treinamento e 96% para o teste), como sendo o melhor modelo encontrado neste trabalho para resolver o problema proposto.

## 6. CONCLUSÃO

Dentro do objetivo e escopo principal desta dissertação, foi desenvolvido um estudo comparativo, de três métodos de classificação baseados em aprendizado de máquina, aplicados à identificação de transientes em usinas nucleares, visando melhor entender ou até mesmo ampliar as possibilidades de contribuição das técnicas de aprendizado de máquina, nos estudos de segurança operativa das usinas nucleares, servindo de auxílio a operadores e engenheiros de planejamento.

Baseados nos resultados obtidos os modelos que apresentaram melhores acurácias no conjunto de treinamento foram SVM e RFA. Dentre elas, as SVMs foram superiores com relação à generalização (acurácia no conjunto de teste), sendo assim tomada como o melhor resultado aqui obtido (Acurácia de 99% no treinamento, e 96% no teste).

As redes neurais, por sua vez, tiveram resultados notadamente inferiores e, como já foi dito anteriormente, seu desempenho pode ter sido prejudicado pela utilização de arquiteturas mais básicas. Entretanto, devido ao alto custo computacional para treinamento, e grande quantidade de hiperparâmetros dos modelos de rede mais complexos, somado ao fato das SVMs já terem sido expressivamente superiores em acurácia e velocidade de treinamento, decidiu-se não se investir, por hora, em modelos mais robustos de redes neurais.

## 7. PROPOSTAS DE TRABALHOS FUTUROS

Ainda dentro do escopo desta dissertação, coloca-se como propostas para trabalhos futuros, a investigação de novas técnicas de aprendizado de máquina na predição de transientes.

Esses estudos e trabalhos futuros com as técnicas acima mencionadas, também se aplicam, ou podem vir a ser aplicados, a novas tecnologias de reatores nucleares que estão emergindo, dentre elas, a tecnologia dos reatores nucleares tipo SMR (do inglês Small Modular Reactor), com suas características construtivas, operativas e aplicações.

Como as SVMs já tiveram acurácias próximas a 100%, sugere-se aplicação a problemas mais complexos para os quais arquiteturas mais robustas de redes neurais já tenham sido desenvolvidas e aplicadas. Esta investigação pode expandir o conhecimento comparativo a respeito destas duas técnicas.

## 8. REFERÊNCIAS

ALVES, A.C.P.D. **Um Sistema de Análise de “Trip” em Reatores PWR Usando Redes Neurais**. Dissertação de Mestrado COPPE-UFRJ. Rio de Janeiro, 1993.

AHMED, W. **Nuclear Power Practical Aspects**. Intech. Croatia, 2012.

AWADALLA, M., et ali. **Classification of Faults in Nuclear Power Plant**. Wseas Transactions on Systems, volume 3; Oman, 2014.

AYODEJI, A., et ali. **Support Vector Ensemble for Incipient Fault Diagnosis in Nuclear Plant Components**. Nuclear Engineering and Technology, Elsevier; Nigeria, 2018.

BARTLETT, E., URIGH, E. **Nuclear Power Plant Diagnostics Using Artificial Neural Networks**. Proceedings of the Frontiers in Innovative Computing for the Nuclear Industry. Wyoming, 1991.

BRENNEN, C.F. **An Introduction to Nuclear Power Generation**. Danks Publishing Company. California, 2005.

CAMELO, H. et ali. **Modelagem da Velocidade do Vento Usando Metodologias ARIMA, HOLT-WINTERS e RNA na Previsão de Geração Eólica no Nordeste Brasileiro**. Revista Brasileira de Climatologia. Ano 13 – Vol. 21 – Jul/Dez 2017.

COLLUM, B. **Nuclear Facilities: A Designer’s Guide**. Elsevier. United Kingdom, 2017.

COSTA, R.G.C. **Sistema de Auxílio para o Direcionamento da Atenção no Diagnóstico de Acidentes em Usinas Nucleares Baseado em Inteligência Artificial**. Dissertação de Mestrado IEN. Rio de Janeiro, 2009.

DURKIN, J. **Expert systems: design and development**. Prentice Hall. New Jersey, 1994.

EL-WAKIL, M.M. **Nuclear Energy Conversion**. Intext Educational Publishers. London, 1971.

EVSUKOFF, A., GENTIL, S. **Recurrent Neuro-Fuzzy System for Fault Detection and Isolation in Nuclear Reactors**. Advanced Engineering Informatics, Elsevier. Rio de Janeiro, 2005.

FREDERICK, L. **Implementation of Breiman's Random Forest Machine Learning Algorithm**. Machine Learning Journal Paper research, ECE591Q, fall 2005.

FRIEDMAN, D. et ali. **The Elements of Statistical Learning Vol.1-Springer Series in Statistics**. Springer. New York, 2001.

GERARD, B. **Analysis of a Random Forest Model**. Journal of Machine Learning Research Vol. 13, pp.1063-1095, 2018.

GÉRON, A. **Hands-On Machine Learning With Scikit-Learn and Tensor Flow: Concepts, Tools, and Techniques to Build Intelligent Systems**. O'Reilly. New York, 2017.

HADAD, K. et ali. **Fault Diagnosis and Classification Based on Wavelet Transform and Neural Network**. Progress in Nuclear Energy, N.53, P.41-47, Elsevier. Iran, 2011.

HAYKIN, S. **Redes Neurais: Princípios e Prática** 2ª ed. Bookman. Porto Alegre, 2001.

KONAR, A. **Artificial Intelligence and Soft Computing: Behavioral and Cognitive Modelling of the Human Brain**. CRC Press. New York, 1999.

KONAR, A. **Computational Intelligence: principle Techniques and Applications**. Springer-Verlag. Netherlands, 2005.

LAMARSH, J.R. **Introduction to Nuclear Engineering** 3ª ed. Prentice-Hall. New Jersey, 2001.

LEWIS, E. E. **Nuclear Power Reactor Safety**. John Wiley and Sons. New York, 1977.

MOL, A.C.de Abreu. **Um Sistema de Identificação de Transientes com Inclusão de Ruídos e Indicação de Eventos Desconhecidos**. Tese de Doutorado COPPE-UFRJ. Rio de Janeiro, 2002.

PEREIRA, Cláudio Márcio N. Abreu. **Notas de Aula – Inteligência Artificial II**. Mestrado em Ciência e tecnologia Nucleares – IEN. Rio de Janeiro, 2018.

PINHEIRO, Victor Henrique Cabral. **Redes Neurais de Aprendizado Profundo Aplicadas a Problemas Complexos da Engenharia Nuclear**. Tese de Doutorado COPPE-UFRJ. Rio de Janeiro, 2020.

ROKACH, L., MAIMOM, O..**Data Mining With Decision Trees: Theory and Applications.** World Scientific. London, 2014.

SANTOS, M.C. et ali. **Deep Rectifier Network Applied to The Accident Identification Problem in a Nuclear Power Plant.** Annals of Nuclear Energy, N.133, P.400-408, Elsevier. Rio de Janeiro, 2019.

ZHANG, B. et ali. **Transient Trend Prediction of Safety Parameters for Small Modular Reactor Considering Equipment Degradation.** Fundamental Science on Nuclear Safety and Simulation Laboratory; China, 2020.

ZHOU, H. **Ensemble Methods: Foundations and Algorithms.** CRC Press. New York, 2012.