

Detecção de Falha Aplicada na Atualização de Probabilidade de Falha.

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais como parte dos requisitos exigidos para obtenção do título de Mestre em Engenharia Elétrica.

por

Renan Nominato Oliveira Souza

Engenheiro Eletricista (UFV)

Orientador: Prof. Dr. Reinaldo Martinez Palhares

Co-Orientador: Prof. Dr. Walmir Matos Caminhas

Agradecimentos

À Universidade Federal de Minas Gerais e ao Programa de Pós-Graduação em Engenharia Elétrica (PPGEE), pela oportunidade de realização do mestrado.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão inicial da bolsa de estudos.

Ao professor Reinaldo Martinez Palhares, pela paciência, orientação e confiança.

Ao professor Walmir Matos Caminha pela coorientação.

Ao professor Marcos Flávio S. V. Dangelo pela ajuda e disponibilidade. Seu apoio teve grande papel para a realização deste trabalho.

À professora Alessandra Carvalho e ao professor André Paim Lemos pelas correções e contribuições.

À todos os amigos, professores e funcionários do PPGEE/UFMG pela colaboração e bons momentos de convivência e amizade.

Aos professores e colegas do Laboratório de Detecção de Falhas, Controle, Otimização e Modelagem (DFCOM) pelo local agradável de trabalho.

Aos amigos que estão distantes, pela torcida.

À minha família pelo apoio e atenção.

À Mariana pelo amor, carinho e estímulo constantes.

À todos aqueles que, de uma forma ou outra, tornaram este trabalho possível e concluído.

Sumário

Resumo	vii
Abstract	ix
Lista de Figuras	xii
Lista de Tabelas	xiii
Lista de Abreviações	xv
1 Introdução	1
1.1 Definição do Problema	1
1.2 Objetivos	8
1.3 Organização do Trabalho	8
2 Atualização da Probabilidade de Falhas	9
2.1 Definição do Problema	9
2.2 Detecção de Falhas	10
2.2.1 Abordagem <i>fuzzy/Bayesiana</i> :	10
2.2.2 Formulação do Algoritmo Metropolis-Hastings	11
2.3 Ajuste de modelo estatístico/atualização de probabilidades	11
2.3.1 Curva da Banheira	11
2.3.2 Análise de Weibull	14
2.4 Teste de aderência	16
2.4.1 Kolmogorov-Smirnov	16

3	Atualização de Probabilidade de Falhas Considerando Tipos de Falha Diferentes	17
3.1	Definição do Problema	17
3.2	Classificação de Falhas	18
3.3	Metodologia para determinação do tipo de falha	18
3.3.1	Classificador <i>Neuro-Fuzzy</i>	20
3.4	Atualização da Distribuição de Falha	24
4	Sistemas para Estudos de Casos	25
4.1	Aplicação em Sistemas	25
4.2	Sistema de Tanques Interativos	25
4.3	Transformadores	27
5	Resultados da Atualização	29
5.1	Atualização da Probabilidade de Falhas	29
5.1.1	Aplicação em um Sistema de Tanques Interativos	29
5.2	Atualização de Taxa de Falhas Considerando Tipos de Falhas Diferentes	32
5.2.1	Aplicação em um Sistema de Tanques Interativos	34
5.2.2	Aplicação em um Transformador	35
6	Considerações Finais	41
6.1	Conclusões	41
6.2	Trabalhos Futuros	41
	Bibliografia	45

Resumo

A coleta de dados de manutenção, a curto e longo prazo, é tarefa de grande relevância num contexto que envolve questões relacionadas ao planejamento orçamentário da indústria. Um conjunto de dados de falha confiável possibilita a definição de estratégias que geram redução de custos, diminuição de incidentes, aumento da produtividade, satisfação dos clientes e fazem com que ampliações do sistema possam ser realizadas considerando informações importantes que podem ser visualizadas nos históricos de falha.

O presente trabalho trata da aplicação de técnicas de detecção de falhas com o objetivo de atualizar, em tempo real, a vida útil de componente. Para isso a vida útil dos componentes foi ajustada em sistemas com falhas de um único tipo, ou seja, a partir de um único modo de falha ajustou-se a taxa de falha do componente; e em sistemas com falhas diferentes, onde além da etapa de detecção, foi necessária uma etapa da classificação da falha e posteriormente a atualização da probabilidade de falha.

Para a detecção de falhas foi utilizado um algoritmo para detecção de pontos de mudança. Já para o ajuste do modelo de falhas foi utilizada a distribuição estatística de Weibull, que é aplicada a problemas relacionados a vida útil de componentes e manutenção de maneira geral. O vetor de dados de falha, após atualização, foi testado a partir de um teste de Kolmogorov-Smirnov para validar se a distribuição de Weibull se ajustou aos dados de falhas. Em sistemas que ocorreram mais de um tipo de falha foi utilizado um classificador NFC (*Neuro Fuzzy Classifier*) com o objetivo de determinar o tipo de falha. Após a determinação do tipo de falha o problema foi tratado da mesma maneira de quando ocorreu um único tipo de falha. O classificador alcançou uma taxa de acerto de 85,04% quando aplicado em classificação de falhas em um transformador e 88,88% quando aplicado em classificação de falhas em Sistemas de Tanques Interativos.

A partir dos resultados obtidos foi possível observar que a metodologia aplicada pode direcionar a política de manutenção a ser utilizada. Outro ponto importante foi que os dados passaram a ter maior confiabilidade tanto para serem coletados como para serem classificados. Assim, percebe-se que os resultados da utilização do sistema são altamente benéficos para armazenamento de dados em um ambiente de manutenção.

Palavras-Chave : Confiabilidade, Detecção de Falha e Manutenção.

Abstract

Maintenance data collection , short and long term, is a task of great importance in a context that involves issues related to budget planning in industry. A reliable dataset of failures enables the definition of strategies that generate cost savings, reduction of incidents, increased productivity, customer satisfaction and make system upgrades can be performed considering important information that can be viewed in the history of failures.

The present work deals with the application of techniques for fault detection in systems subject to failures with the objective is update the life of component in real time . For this, the life of the components was adjusted in systems with a single type of failures, in others words, with only one failure mode the life of component was adjusted. Moreover in systems whose two or more types failure could happen, that's why was necessary another stage which occur the failure classification as well as then the life of component was updated.

For fault detection was used Fuzzy / Bayesian algorithm. In order to failure modeling was used statistical distribution of Weibull which generally is applied in problems related to life time of the component. The dataset of fails after upgrade, was tested from a Kolmogorov-Smirnov test to validate if the Weibull distribution fit to the failure data. In systems that occurred more than one type of failure was used a classifier NFC (Neuro Fuzzy Classifier) for the purpose of to determine the type of failure. After determining the type of failure the problem was treated in the same way when there was only one type of failure. The classifier achieve an accuracy rate of 85.04 % when applied to the classification of faults in electrical transformers as well as 88.88 % when applied in a interactive tank system.

From the results obtained it was observed that the methodology can direct the maintenance policy to be used. Another important point was that the data now have much greater reliability to be collected as well as be classified. Thus, it is clear that the results of using the system are highly beneficial for data storage in a maintenance environment.

Keywords: Fault Detection, Reliability and Maintenance

Lista de Figuras

1.1	Exemplo de Algoritmo de Criticidade.	3
1.2	Tipos de Falha	5
1.3	Confiabilidade, Custo de Manutenção e Custo de Produção	7
2.1	Fluxograma de Atualização	9
2.2	Curva da Banheira	12
2.3	Função Weibull para dois parâmetros baseada em [15]	15
3.1	Esquema de detecção com um classificador adicionado.	17
3.2	Classificador Neuro-Fuzzy	22
3.3	Divisão do Espaço de Características	23
4.1	Simulador de Tanques Interativos apresentado em [10]	27
5.1	Esquema de Janelas para Atualização de Probabilidades	30
5.2	Deteção de Falha para um dos Pontos	30
5.3	Função de Densidade de Probabilidade para a falha de entupimento	32
5.4	Função de Distribuição Acumulada para a falha de entupimento	33
5.5	Gráfico de Probabilidade Weibull	33
5.6	PDF para a falha de entupimento TQ1-TQ3 e Agarramento FCV1	35
5.7	CDF para a falha de entupimento TQ1-TQ3 e Agarramento FCV1	36
5.8	Gráfico de Probabilidade de weibull - falha Entupimento e Agarramento FCV1	38
5.9	PDF para a falha no Enrolamento do Transformador	38
5.10	CDF para a falha no Enrolamento do Transformador	39
5.11	Gráfico de Probabilidade de Weibull para falha no enrolamento do Trafo.	39

Lista de Tabelas

2.1	da Curva da Banheira e causas de falha. Adaptado de [5]	15
3.1	Mapeamento dos estados de falha de um Motor	19
5.1	Função Densidade de probabilidade acumulada	32
5.2	Taxa de Falha em Função do Tempo entre Falhas de Entupimento e Agarramento	36
5.3	Classificação de Falhas em Tanques e Transformadores utilizando NFC .	37

Lista de Abreviações

CDF	<i>Cumulative Distribution Function;</i>
CMMS	<i>Computerized Maintenance Management System;</i>
DTM	<i>Down Time Monitor;</i>
FDI	<i>Fault Detection and Isolation;</i>
FMEA	<i>Failure Mode and Effects Analysis;</i>
FTA	<i>Fault Tree Analysis;</i>
Hh	<i>Homen-hora;</i>
iid	<i>independentes e identicamente distribuidos;</i>
K-S	<i>Kolmogorov-Smirnov;</i>
MES	<i>Manufacturing Execution System;</i>
NFC	<i>Neuro Fuzzy Classifier;</i>
PDF	<i>Probability Density Function;</i>
PdM	<i>Predictive Maintenance;</i>
PIMS	<i>Plant Information Management System;</i>
RAM	<i>Reliability, Availability and Maintainability;</i>
RCA	<i>Root Cause Analysis;</i>
RNA	<i>Redes Neurais Artificiais;</i>
SCADA	<i>Supervisory Control and Data Acquisition;</i>
SMED	<i>Single-Minute Exchange of Die;</i>

Introdução

Este capítulo consiste na exposição preliminar do problema e na determinação da política de manutenção utilizando atualização de probabilidades. São apresentados os tipos de manutenção usualmente utilizados na literatura e indústria, os cenários em que cada um deve ser utilizado, além de conceitos de confiabilidade. É apresentada ainda uma breve revisão de algoritmos de detecção de falhas e algumas metodologias para classificação de falhas. Em seguida, define-se o problema e são apresentados a motivação e os objetivos deste trabalho.

1.1 Definição do Problema

O termo manutenção teve origem no segmento militar e tinha como principal objetivo preservar, nas unidades de combate, os níveis tanto de materiais como também de efetivo [22].

De acordo com a [1], manutenção é a combinação de ações técnicas, administrativas e de supervisão com o objetivo de manter ou recolocar um item em um estado no qual possa desempenhar uma função requerida, ou seja, fazer o que for preciso para assegurar que um equipamento ou máquina opere dentro das condições mínimas de requerimentos e especificações.

A manutenção corretiva é a maneira mais rudimentar de se executar o reparo de equipamentos/componentes. Neste tipo de manutenção espera-se o problema ocorrer para ser realizada alguma tratativa e quando não planejada pode se tornar a maneira mais cara de recolocar os equipamentos em funcionamento. Uma das maiores consequências da manutenção corretiva é a diminuição da disponibilidade física de equipamentos e conseqüentemente da planta de uma maneira global.

Existem várias maneiras de se calcular a disponibilidade física de um equipamento, mas em linhas gerais ela é determinada pelo percentual de tempo de um ciclo em que o equipamento está disponível para operação considerando um ciclo pré-definido. Desta maneira, existe um custo para alcançar a disponibilidade máxima dos equipamentos, o que significa que aumentar a disponibilidade física, nem sempre minimizam os custos

globais da. Assim, manter um nível aceitável de disponibilidade física é interessante em alguns cenários [17]. Com isso, a manutenção corretiva pode se tornar viável em alguns casos. Uma ferramenta que gera bons resultados na manutenção corretiva é o SMED (*Single-Minute Exchange of Die*). O SMED é uma metodologia na qual se prepara ferramentas para realização de reparos de maneira rápida, assim o tempo que o equipamento fica indisponível é menor.

Outra metodologia de manutenção bastante utilizada é a manutenção preventiva. Normalmente, este tipo de manutenção ocorre baseada em estudos estatísticos de confiabilidade, informações de vida útil disponibilizadas por fabricantes e por conhecimentos de operação e manutenção fornecidos por pessoas que conhecem o processo de manutenção. Como o nome já diz, é uma medida preventiva e, desta forma, geralmente, antes que o equipamento quebre é realizado o reparo de maneira programada buscando minimizar custos com atividades não planejadas, como por exemplo a aquisição não planejada de um componente. A manutenção preventiva trás uma série de vantagens quando comparada com a corretiva, pois devido a um maior planejamento consegue-se ter um maior controle de quando o problema irá ocorrer e assim, o número e tempo de intervenções sem planejamento são menores quando comparado com uma política corretiva. Outro ponto bastante importante é que os recursos podem ser utilizados quando possuem seus melhores custos. Por exemplo, ao invés de realizar uma manutenção não programada em um período noturno em que normalmente não se dispõe de todo o efetivo de trabalho de uma planta, executa-se a tarefa em um horário diurno no qual toda a equipe de trabalho está disponível e pode ser mobilizada da melhor maneira possível para atender a intervenção. Um grande entrave da manutenção preventiva é que nem sempre se consegue acompanhar o equipamento na situação real de operação. Muitos dos fatores como má substituição de um componente, desgastes prematuros de componentes e outros fatores que não podem ser previstos em modelos estatísticos, costumam interferir retirando um pouco da assertividade da metodologia de manutenção.

Desta maneira, surge uma metodologia que se torna complementar e muitas das vezes pode fornecer ao gerenciador um maior número de informações. Esta metodologia alternativa é denominada manutenção baseada na condição ou manutenção preditiva. Este tipo de manutenção utiliza monitoramento de sinais de equipamentos para prever a evolução de uma falha.

Sinais como vibração (medido normalmente com acelerômetro), temperatura (medido com infra-vermelho e termografia), particulado em óleo (técnicas de tribologia) e penetração de líquidos são algumas das ferramentas utilizadas para monitorar as falhas. Estes sinais fazem com que a manutenção preditiva se torne bastante interessante, pois se tem conhecimento do status do equipamento em intervalos desejados. Isso faz com que não se desperdice recursos financeiros com componentes e paradas de manutenção por meio da antecipação ou postergação das tratativas de manutenção. Um ponto que precisa ser trabalhado quando se fala em manutenção baseada na condição

são os números de inspeções realizadas (frequência) em cada equipamento, isto porque muitas das vezes pode-se subdimensionar ou superdimensionar o número de recursos neste tipo de metodologia. O superdimensionamento pode gerar sobre custo com Homen-hora (Hh) em campo. Já o subdimensionamento pode trazer as características da manutenção baseada na condição próximas das de manutenção corretiva, em que uma quebra não prevista eventualmente ocorre.

Existem outros fatores que podem influenciar na execução de uma manutenção preditiva, como por exemplo equipamentos que podem gerar riscos ambientais ou riscos para a vida das pessoas. Assim, é muito comum existir uma definição de algoritmo de criticidade dos ativos, em que se separa os ativos críticos dos não críticos utilizando fatores que nem sempre geram retornos financeiros diretos. A Figura 1.1 apresenta um exemplo de algoritmo de criticidade de uma empresa de mineração:

NÍVEL		ALTA (1)	MÉDIA (2)	BAIXA (3)
S	Segurança	A falha provoca graves efeitos sobre o homem, o meio ambiente ou instalações	A falha acarreta riscos para o homem, o meio ambiente ou instalações	A falha não produz consequências
	Riscos potenciais para as pessoas e o meio ambiente.			
Q	Qualidade e Produtividade	A falha afeta muito a qualidade, gerando produtos fora da especificação	A falha faz variar a qualidade do produto	A falha não produz efeito sobre a qualidade do produto
	Efeito de falha dos equipamentos sobre a qualidade dos produtos e o rendimento da empresa.			
RT	Regime de Trabalho	Equipamento opera 24 horas	Equipamento opera em regime de revezamento	Uso ocasional
	Tempo de trabalho do equipamento.			
A	Atendimento	A falha provoca interrupção total do processo produtivo	A falha provoca interrupção parcial na produção ou cria restrições operacionais	A falha não provoca interrupções do processo produtivo ou existe componente reserva
	Efeito da falha dos equipamentos sobre o processo produtivo.			
F	Frequência	Muitas paradas devido as falhas (mais de 1 por ano)	Paradas ocasionais (1 a cada ano)	Paradas pouco frequentes (menos de 1 por ano)
	Quantidade de falhas por período de utilização.			
C	Custo	O tempo de reparo e custos são muito elevados (Acima de R\$10.000,00)	O tempo de reparo e custos são elevados (Acima de R\$5.000,00e abaixo de R\$10.000,00)	O tempo de reparo e custo não são relevantes (Abaixo de R\$5.000,00)
	Valores e tempos envolvidos na correção das falhas.			

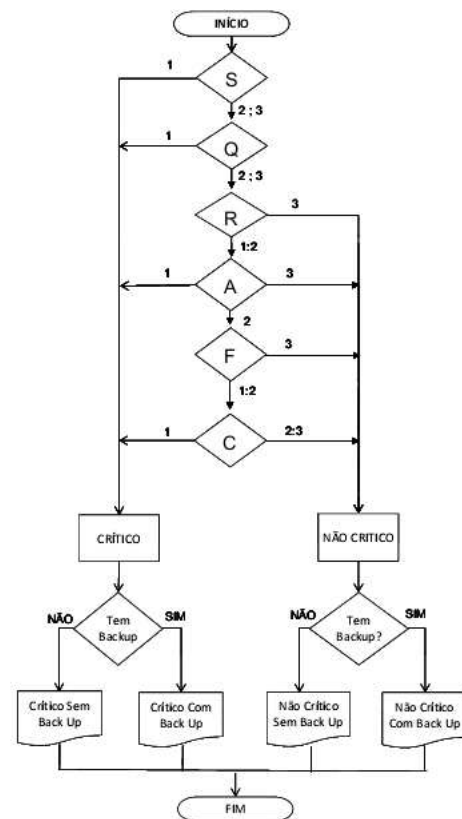


Figura 1.1: Exemplo de Algoritmo de Criticidade.

Atualmente, no contexto em que a competição industrial se torna cada vez mais acirrada, buscando aumento de disponibilidade dos equipamentos, diminuição de custos de operação, diminuição do número de incidentes com pessoas e diminuição dos efeitos gerados ao meio ambiente, surge o conceito de manutenção de excelência.

A manutenção de excelência utiliza-se de todas as metodologias de manutenção e baseia-se principalmente no gerenciamento de ativos.

O Gerenciamento de ativos consiste na aplicação de técnicas quantitativas para tomada de decisão [15] e precisa de um longo processo para ser implantado e desenvolvido dentro de qualquer indústria. Inicialmente, se faz a etapa de conscientização da liderança em que gestores necessitam querer implantar a metodologia e definirem uma estratégia para isso. O segundo passo é o aumento dos controles relacionados as táticas de manutenção, planejamento e controle e gerenciamento de materiais.

Nesta escalada em busca da excelência da manutenção, um dos grandes problemas é a coleta de dados. A coleta de dados geralmente é deficiente e feita de maneira manual e sem integração com os sistemas especialistas SCADA (*Supervisory Control and Data Acquisition*) ou softwares CMMS (*Computerized Maintenance Management System*).

As falhas são as grandes ameaças aos equipamentos e estão normalmente relacionadas a qualidade da manutenção que é realizada. De acordo com a [1] as falhas podem ser definidas como a finalização da capacidade requerida de um item.

Em [11] as falhas foram classificadas em dois tipos. A primeira seria a falha abrupta, que resulta em grandes desvios nas condições normais de operação, ou em variáveis do processo, e acontece em um curto espaço de tempo. Esta falha é de mais fácil detecção, pois normalmente retira a máquina de operação ou gera condições que são perceptíveis em uma inspeção. A segunda é a falha incipiente, que afeta gradualmente o funcionamento normal do processo e por isso, pode requerer um esforço maior para ser detectada. A Figura 1.2 apresenta o comportamento de uma falha abrupta e de uma falha incipiente.

As falhas abruptas, na maior parte das vezes, tem que ser combatidas com a manutenção corretiva. Já as falhas incipientes podem ser monitoradas utilizando manutenção baseada na condição ou ainda a manutenção preventiva.

Como um exemplo prático, pode-se utilizar um transformador trifásico com tensão no primário de 13,8 kV e tensão no secundário de 220 V. Um tipo de falha incipiente que pode ocorrer é o curto-circuito entre bobinas do primário. Neste tipo de falha, ao longo do tempo, a tensão do primário será cada vez menor, resultando em uma tensão de secundário também menor. Esta falha na maior parte das vezes é uma falha de lenta detecção. Já uma falha abrupta para este tipo de equipamento poderia ser um curto-circuito entre duas fases em decorrência de baixa isolação entre o meio físico dos condutores de cada fase. Este é um tipo de falha que deve ser automaticamente detectado, fazendo com que o sistema de proteção seja acionado. Caso o sistema de proteção não atue, o transformador pode ser destruído pela falha em um intervalo de tempo muito curto.

Uma alternativa para amenizar as consequências geradas pelas falhas é o processo de detecção de falhas. Normalmente, denomina-se este sistema de supervisão aplicados em detecção de falhas como FDI (*Fault Detection and Isolation*). De acordo com [11] um sistema FDI reconhece um comportamento anormal dos componentes de um processo. Esta situação anormal pode ser observada a partir da análise de variáveis.

Em geral, os sistemas FDI podem ser divididos em duas classes, sendo a primeira

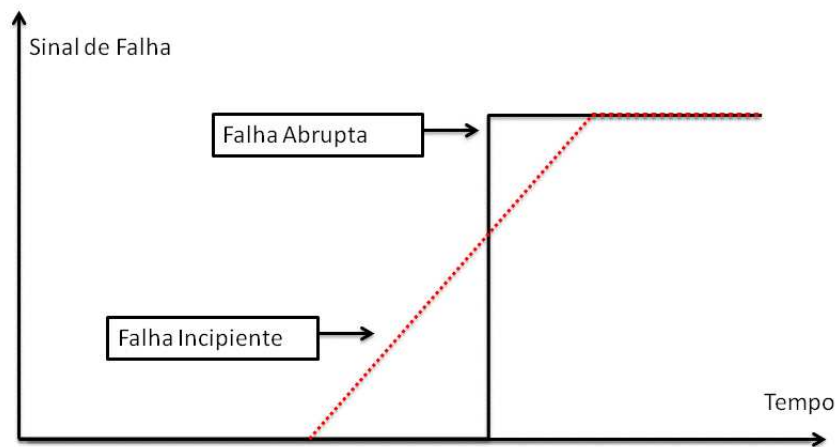


Figura 1.2: Tipos de Falha

uma abordagem baseada em modelos qualitativos e a segunda em modelos quantitativos. Uma revisão das técnicas de detecção de falhas tanto qualitativas como quantitativas pode ser encontrada em [11].

As abordagens quantitativas baseiam-se em modelos matemáticos como os observadores, filtro de Kalman e relações de paridade. Já as abordagens qualitativas tem como base os padrões que são fornecidos pelo histórico de funcionamento dos equipamentos. Como exemplos de técnicas pode-se citar as redes neurais, os sistemas fuzzy e a análise qualitativa de tendências. Os métodos quantitativos geralmente são aplicados em sistemas nos quais são necessários alto grau de precisão e confiabilidade do sistema de detecção, como exemplo a industria aeronáutica. Já os sistemas qualitativos podem ser aplicados em casos que a complexidade do modelo é elevada, e não é tão interessante ter toda esta complexidade modelada. Como exemplo, o sistema de ciclonagem dentro do processo de mineração. Este sistema possui um modelo complexo que poderia ter suas falhas detectadas a partir de um FDI qualitativo. O FDI atua aumentando a robustez do sistema de coleta de dados de falha, pois indica o momento real em que a falha ocorreu alimentando de maneira direta o banco de dados de um CMMS. Existem generalizações dos algoritmos FDI que podem ser associados a manutenção preditiva, pois os mesmos podem detectar mais de um ponto de mudança. Um exemplo em que mais de um ponto de mudança é detectado pode ser encontrado em [20].

Outra ferramenta importante no processo de armazenamento de dados de falha que pode dar suporte aos operadores durante um evento de falha são os classificadores. Existe uma infinidade de classificadores que é usada para determinar padrões. Como exemplos de classificadores podemos citar os bayesianos, as redes neurais, os sistemas baseados em redes fuzzy e os modelos ocultos de markov.

No caso das falhas, os padrões são tipos de falhas diferentes que podem gerar distúrbios ao sistema. Quando existem vários tipos de falhas que podem afetar um

sistema é necessário que se determine a causa raiz da ocorrência, ou chegue o mais próximo disto. O objetivo em se determinar a causa raiz é alimentar o banco de dados gerando uma cadeia de dados de falha pertinente, entretanto, muitas das vezes as falhas tem sinais e comportamentos bastante similares, mas essencialmente a causa que gerou a falha pode ser totalmente diferente uma de outra. Quando isto ocorre o impacto de classificar a falha erroneamente é grande, pois grande parte dos esforços são direcionados para combater um tipo de problema e na verdade o que afeta o sistema é um outro tipo de perturbação. Desta maneira, como os sintomas de falha são altamente parecidos, o classificador se torna uma ferramenta de apoio ao operador na hora de determinar a causa ou tipo de falha que ocorreu. Assim, efeitos como falsos positivos durante a classificação de uma falha são minimizados tornando o banco de dados de falha mais confiável e podendo gerar resultados promissores em análises de confiabilidade.

A confiabilidade, de acordo com a [1], é a capacidade de um item desempenhar a função requerida, sob condições de operação estabelecidas, por um período de tempo pré-determinado. Ela pode ser aplicada tanto na etapa de projeto do produto, como na etapa de operação/manutenção dos itens. Quanto mais bem trabalhada for a confiabilidade durante a etapa de projeto do produto, melhor será seu desempenho durante a etapa de operação/manutenção. Outros pontos que podem ser definidos com a utilização de técnicas de confiabilidade de produto são a garantia e capacidade produtiva de um sistema, que pode ser determinada por meio de uma análise RAM (*Reliability, Availability and Maintainability*). Algumas das vezes as especificações de desempenho definidas em fase de projeto não são alcançadas durante a fase de operação e desta maneira é necessário um reprojeto. Outras vezes, os parâmetros que foram definidos na fase de projeto do produto são subdimensionados e, com dados de operação/manutenção do sistema, pode-se aumentar o desempenho do sistema utilizando alguns indicadores como intervalo entre manutenções, disponibilidade de equipamentos e parâmetros que melhorem o desempenho global do sistema. A figura 1.3 apresenta relações entre Confiabilidade, Produção e Custos de Manutenção.

Uma ferramenta bastante utilizada na análise de confiabilidade e análise de riscos, e que dá suporte na tomada de decisão, é a Árvore de falhas - do termo em inglês *Fault Tree Analysis* (FTA). Esta ferramenta pode calcular riscos de processo, ser aplicada em análises financeiras e, ainda, no cálculo de vida útil de equipamentos. Além disso, é uma técnica amplamente aplicada em ações corretivas, facilitando a identificação da causa raiz - do termo em inglês *Root Cause Analysis* (RCA). Estas árvores podem ser desenhadas a partir de um estudo de FMEA (*Failure Mode and Effects Analysis*), uma metodologia que de forma analítica identifica as principais partes do equipamento, os tipos de falhas que podem ocorrer e as ações que podem ser tomadas para combater estes tipos de falha. Geralmente estas árvores são desenhadas por um grupo de pessoas que tem um bom conhecimento do processo, tanto de maneira operacional, como na visão da manutenção. Assim, utilizando os cálculos de confiabilidade, as probabilidades




Figura 1.3: Confiabilidade, Custo de Manutenção e Custo de Produção

de falhas das árvores de falhas irão depender do tempo e das condições de operação. Existe uma grande variedade de distribuições que são usadas para modelar dados de confiabilidade. Como exemplo, pode-se citar a distribuição exponencial, a log-normal, a normal e a Weibull. Em [18] encontra-se uma revisão sobre estes modelos.

Utilizando a Árvore de Falha de Confiabilidade aliada aos sistemas de detecção/classificação de falha é possível gerar ganhos no armazenamento de dados, pois desta forma a coleta é realizada de maneira automatizada e em tempo real. Isto garante que a informação do tempo em que a falha ocorreu seja registrada com bastante acurácia. Outro ponto importante é que os alarmes falsos são minimizados com a utilização do sistema de detecção.

As informações armazenadas pelo sistema podem ser utilizadas para verificar por qual distribuição de probabilidade a falha é regida, bem como qual é o percentual de chances do sistema falhar em intervalos pré-determinados de tempo, combatendo um dos principais problemas quando se trata de excelência da manutenção, que é a coleta de dados [19].

A coleta de dados passa a ser realizada de maneira automatizada usando o algoritmo de detecção de falhas que irá garantir o armazenamento do tempo em que a falha ocorreu e com um classificador de falha que irá dar suporte ao usuário para classificar a falha ocorrida. Assim, o banco de dados irá ser armazenado de maneira padronizada seguindo regras pré-definidas e o aprendizado de funcionamento do sistema será melhorado.

1.2 Objetivos

Dentro do contexto apresentado acima, o presente trabalho teve o objetivo de, no primeiro momento, coletar os dados de maneira segura utilizando um sistema de detecção e classificação de falhas. Desta forma, fica garantido o armazenamento do tempo em que a falha ocorreu e do tipo de falha que ocorreu.

Num segundo momento, os dados obtidos foram trabalhados a partir da confiabilidade com o objetivo de atualizar os modelos e taxas de falhas de equipamentos. Uma ferramenta que auxiliou nesta atualização foram os classificadores que ajudaram a determinar o tipo de falha que perturbou um sistema. Desta forma, com um novo modelo ajustado pode-se, por meio dos parâmetros de confiabilidade, direcionar qual política de manutenção poderá minimizar os custos.

1.3 Organização do Trabalho

No Capítulo 2 desta dissertação, é apresentada a metodologia para atualização de probabilidade de um sistema em que ocorre apenas uma falha. O Capítulo 3 aborda o mesmo problema com a adição de um maior número de falhas e um classificador com objetivo de determinar a falha automaticamente. O Capítulo 4 aplica em sistemas os métodos apresentados nos Capítulos 2 e 3. O Capítulo 5 apresenta os resultados obtidos e, por fim, o Capítulo 6 trará as conclusões.

Atualização da Probabilidade de Falhas

2.1 Definição do Problema

Na execução deste trabalho foi utilizada uma Abordagem *fuzzy/Bayesiana* para a detecção de falhas. Em seguida, foi realizada uma avaliação da distribuição de falha atual verificando se os dados disponíveis se ajustaram a ela. Quando sim, foi realizada a atualização dos parâmetros e das probabilidades de falhas de um componente pré-definido. A figura 2.1 representa as etapas que foram realizadas neste trabalho.

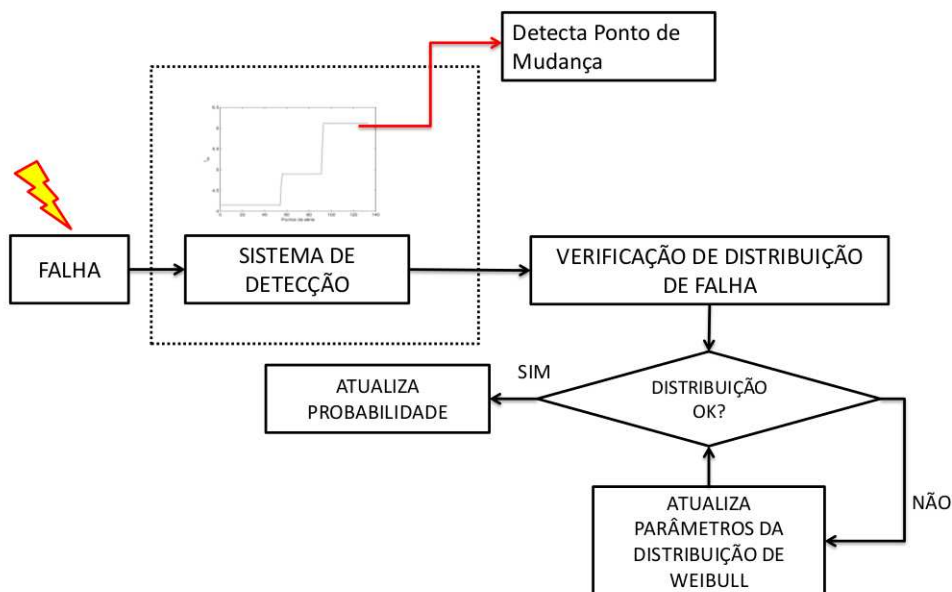


Figura 2.1: Fluxograma de Atualização

2.2 Detecção de Falhas

2.2.1 Abordagem *fuzzy/Bayesiana*:

De acordo com [12], a primeira etapa na detecção do ponto de mudança é a transformação de uma série temporal qualquer, $y(t)$, em uma outra série com propriedades particulares. Para isto, utiliza-se técnicas de conjuntos fuzzy. A série transformada passa a ser regida por uma distribuição *beta*.

Considerou-se a série temporal $y(t)$ dada. Definiu-se o conjunto:

$$C = \{C_i \mid \min \{y(t)\} \leq C_i \leq \max \{y(t)\}, \\ \text{para } i = 1, 2, \dots, k\}$$

O conjunto $C = C_i, i = 1, 2, \dots, k$ que satisfaz:

$$\min \sum_{i=1}^k \sum_{y(t) \in C_i} |y(t) - C_i|^2 \quad (2.1)$$

é denominado centro do *cluster* da série temporal $y(t)$. A relação na qual se determina o grau de pertinência *fuzzy*, isto é, a relação *fuzzy* $y(t) \in C_i$ é definida por:

$$\mu_i(t) \triangleq \left[\sum_{j=1}^k \frac{|y(t) - C_i|^2}{|y(t) - C_j|^2} \right]^{-1} \quad (2.2)$$

Veja que dado um conjunto C de centro de *clusters*, pode-se medir o afastamento de cada ponto da série temporal $y(t)$ em relação a cada centro C_i . Para a determinação dos centros dos *clusters* pode-se usar técnicas como *K-means*, *C-means* e as redes de Kohonen.

A partir de [12] conclui-se que $\mu_i(t)$ segue uma família de distribuições *beta* com diferentes parâmetros, e para $t \leq m$ obtém-se uma distribuição *beta*(a,b), ou então uma distribuição *beta*(c,d) se $t > m$.

Com isso, observa-se que $\mu_i(t)$ tem como característica uma distribuição fixa e portanto a formulação *Bayesiana* tem como entrada sempre o mesmo modelo para a detecção de ponto de mudança na série temporal. Então independentemente das propriedades estatísticas da série temporal original $y(t)$, obtém-se sempre o mesmo padrão probabilístico para a fase *Bayesiana*. A ideia desse tipo de abordagem é tratar a ocorrência de ponto de mudança em uma série temporal como uma ocorrência de falha, portanto detectando-a.

2.2.2 Formulação do Algoritmo Metropolis-Hastings

Em [12] aplica-se o Algoritmo Metropolis-Hastings a fim de construir uma cadeia de Markov com uma distribuição de equilíbrio π .

Supondo uma cadeia que esteja no estado x e que um valor x' é gerado de uma distribuição proposta $q(\cdot | x)$ (candidata a ser aceita), nota-se que a distribuição proposta pode depender do estado atual da cadeia. Como exemplo, considere que $q(\cdot | x)$ é uma distribuição normal centrada em x . O novo valor x' é aceito com probabilidade da forma:

$$\alpha(x, x') = \min\left(1, \frac{\pi(x')q(x, x')}{\pi(x)q(x', x)}\right)$$

Assim, pode-se sumarizar o algoritmo da seguinte maneira:

1. Inicializar o contador de iterações em $t = 0$ e especificar um valor inicial $x_0 = (a_0, b_0, c_0, d_0, m_0)$;
2. Gerar um valor de referência x' usando uma distribuição de referência dada por $q(\cdot, x)$;
3. Calcular a probabilidade de aceitação em $\alpha(x, x')$ e gerar $u \sim U(0, 1)$;
4. Se $u \leq \alpha$ então aceitar o novo valor e fazer $x^{t+1} = x'$, caso contrário rejeitar e fazer $x^{t+1} = x^t$;
5. Incrementar o contador t para $(t + 1)$ e voltar ao passo 2 até o número de iterações especificadas.

O algoritmo Metropolis-Hastings estima os valores de a, b, c e d e o ponto de mudança m . O ponto de mudança é detectado como sendo a maior massa do histograma de m , com exceção das bordas.

2.3 Ajuste de modelo estatístico/atualização de probabilidades

2.3.1 Curva da Banheira

A curva da banheira é uma tradicional representação do comportamento de falha em vários itens como componentes mecânicos, eletrônicos, materiais de vários tipos de formação e até mesmo seres humanos. Esta representação gráfica ocorre em virtude da vida útil se alterar ao longo do tempo. Conforme a Figura 2.2 é possível observar os três comportamentos distintos.

- Quebra prematura ou mortalidade infantil;
- Quebra durante a vida útil;
- Quebra durante o envelhecimento.

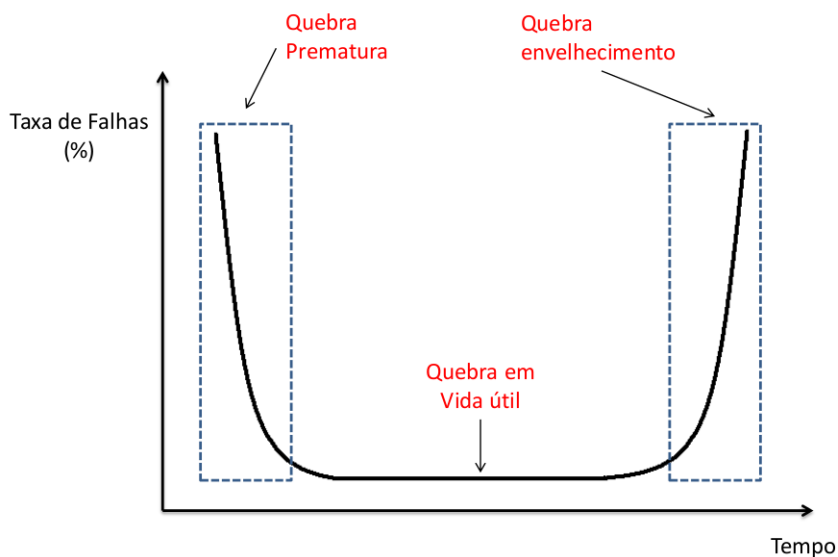


Figura 2.2: Curva da Banheira

A quebra prematura geralmente ocorre em elementos com baixo padrão de qualidade no projeto, instalação, ou aplicação. Desta maneira, o item deixa de desempenhar seu papel de uma maneira precoce. Um ponto que pode diminuir a taxa de quebra prematura é a aplicação de uma análise FMEA na etapa de projeto/produto. Com esta análise muitos dos pontos falhos durante a implantação podem ser mitigados eliminando a causa raiz.

Em [21], foi apresentado estudo mostrando que quanto mais cedo descobre-se e corrige-se um erro, menor será seu custo nas etapas subsequentes de um projeto. Um caso clássico de falha em produto, é de uma empresa produtora de discos rígidos para armazenamento de informações em micro-computadores. Os discos rígidos vinham sofrendo travamento de maneira recorrente e tendo diversos problemas de garantia com os clientes finais. Após uma análise RCA foi possível perceber que o mecanismo de giro travava em virtude do aparecimento de formigas e que o chamariz para as formigas era o lubrificante do elemento rotativo. Assim, o lubrificante foi substituído por um outro que não gerava atração nas formigas e o modo de falha foi adicionado

ao FMEA do disco rígido passando a ser considerado também na produção de novos modelos de discos rígidos.

A quebra durante a vida útil pode ocorrer em qualquer momento e nesta etapa as características da curva da banheira se tornam parecidas com uma distribuição exponencial, a qual possui um caráter aleatório na ocorrência de falha. Componentes eletrônicos geralmente são regidos por distribuições exponenciais, sendo considerado que as falhas ocorrem aleatoriamente, o que na verdade deixa de ser verdade quando se analisa profundamente o comportamento da falha nestes componentes. A curva destes componentes é a mesma curva da banheira sendo que a fase de quebra prematura e a fase de quebra durante o envelhecimento são encurtadas e a quebra em vida útil é alongada.

Já a quebra no fim da vida útil ocorre devido ao desgaste de longo tempo de utilização de um componente e se relaciona com equipamentos de características mecânicas como rolamentos e mancais. O ideal é que se alcance uma maior utilização do componente alongando ao máximo a etapa de fim da vida útil. Assim quando se realiza uma manutenção, a vida útil é alongada e a etapa de envelhecimento é deslocada no tempo. Um fato bastante importante é que quando se repara um componente não se pode considerar que ele irá assumir características de como se fosse um componente novo, ou *as good as new* como mostra estudo apresentado em [19]. Assim devem existir estudos mais complexos para o cálculo do tempo ótimo para substituição de um componente quando se trata de sistemas que possuem interferências entre múltiplos componentes, ou seja, que os dados de falhas em diversos componentes não são independentes e identicamente distribuídos (iid).

Um outro fator que afeta bastante a detecção de um modelo que seja pertinente é que no ambiente de manutenção industrial faltam dados para análises estatísticas. Isto é de fato de se esperar já que a função da manutenção é fazer que as falhas se tornem eventos raros, entretanto, quando a falha não ocorre, muitas da vezes, intervenções são realizadas por questões de segurança ou outros motivos que podem comprometer planta e resultados. Existe uma classe de dados denominada dados censurados e, neste tipo de classe, as intervenções preventivas ocorrem em momento anterior a falha e podem ser utilizadas como dados para cálculo de confiabilidade, mas nem sempre trazem o comportamento limite para intervenção ótima em um sistema. Uma maneira alternativa para se combater os problemas de dados é a combinação de dados de sistemas similares. Isto é feito a partir da combinação de dados de componentes de sistemas parecidos, os quais fazem parte do mesmo processo. Pode-se citar como exemplo um sistema de bombeamento de fluidos no qual existe um elevado número de bombas operando em paralelo. Características importantes para que os equipamentos tenham dados compartilhados seguem abaixo:

- Projeto Similar
- Parte Física similar (Exemplo: Forma construtiva do motor, número de polos,

grau de proteção)

- Função Similar (Exemplo: Bombeamento de água bruta)
- Instalação Similar
- Mesmo time de execução de manutenção e operação de equipamentos
- Ambiente e localização similares

Desta forma, muitas informações podem ser correlacionadas e calculadas para determinar o tempo ótimo de substituição de um componente. Existem alguns grupos empresariais que fazem estudos avançados, utilizam a análise RAM para implantação de novos projetos utilizando informações de outras plantas similares do mesmo grupo que já operam. Outra prática bastante comum quando o grupo não possui dados de falhas, é comprar no mercado dados similares ao projeto que está sendo implantado.

A Tabela 2.1 sumariza os principais causadores de falha durante cada etapa da curva da banheira.

2.3.2 Análise de Weibull

Quando se menciona a Análise de Confiabilidade, um dos modelos mais aplicados em manutenção é o da distribuição de Weibull. Alguns exemplos de aplicação desta distribuição são as medições de tempo entre falhas de equipamentos eletrônicos e mecânicos. A função de Weibull consegue representar trechos similares aos apresentados para a curva da banheira e seu caso mais geral possui três parâmetros. A função com três parâmetros é representada a seguir e na Figura 2.3:

$$f(t) = \begin{cases} \frac{\beta}{\eta} \left(\frac{t-\gamma}{\eta} \right)^{\beta-1} e^{-\left(\frac{t-\gamma}{\eta} \right)^{\beta}}, & p/t > \gamma \\ 0, & p/t \leq \gamma \end{cases}$$

Os três parâmetros da distribuição de Weibull são: o parâmetro de forma β ; o parâmetro de escala da distribuição η e o parâmetro de posição γ . Os parâmetros β e η são maiores que 0. Já o parâmetro γ , que é relacionado com a vida inicial do item, grande parte das vezes, é desprezado em análises relacionadas a manutenção.

A figura 2.3 apresenta o comportamento da função Weibull quando se mantém o valor de η constante e varia-se o valor de β . Observando o gráfico verifica-se os vários comportamentos que a distribuição pode assumir. Correlacionando os valores de β com a curva da banheira pode-se chegar na sumarização abaixo:

- $0 < \beta < 1$ - Período de Mortalidade Infantil

Tabela 2.1: da Curva da Banheira e causas de falha. Adaptado de [5]

Quebra Prematura	Quebra em Vida Útil	Quebra por envelhecimento
Processos de Fabricação deficientes	Cargas Aleatórias Maiores que as esperadas	Envelhecimento
Baixo controle de qualidade	Acompanhamento ineficaz da manutenção baseada na condição	Desgaste/abrasão
Mão de Obra não qualificada	Erros humanos durante o uso	Degradação de resistência
Não aplicação de Técnicas de Confiabilidade de Projeto	Aplicação indevida	Fadiga
Materiais fora da Especificação	Sobrecarga	Corrosão
Falhas devido a transporte inadequado e questões de acondicionamento	Falhas não detectáveis pelos equipamentos de manutenção baseados na condição	Deterioração mecânica, elétrica, química ou hidráulica
Erro Humano	Causas inexplicáveis (Ocultas)	Manutenção preventiva/preditiva insuficiente ou deficiente
Sobrecarga nos testes de comissionamento	Fenômenos Naturais Imprevisíveis	Vida de projeto muito curta




Figura 2.3: Função Weibull para dois parâmetros baseada em [15]

- $\beta = 1$ - Período de Vida Útil
- $\beta > 1$ - Período de Desgaste

Desta forma, a partir dos parâmetros anteriormente citados consegue-se determinar as chances de um item falhar dado um intervalo de tempo de funcionamento. Assim, é possível assumir, ou não riscos de uma falha neste intervalo. Um exemplo seria um sistema que precisa operar 24 horas ininterruptas e caso este sistema quebre neste intervalo de tempo pode gerar perdas financeiras em unidades de moeda no valor de x ; entretanto, sabe-se que para trocar o componente que está com sua vida útil quase no fim custará um valor monetário y . A partir dos dados de falhas é possível determinar o quão grande será o risco caso se decida operar e quanto será perdido em uma troca antecipada. Com isso é viável direcionar as ações a serem tomadas. Uma outra finalidade da modelagem de confiabilidade refere-se a determinação do lucro cessante. Nele se pode quantificar quanto a hora parada de um equipamento irá custar em rentabilidade para o negócio e, assim, pode-se comparar com os valores de novos investimentos e aquisição de novos equipamentos para um projeto.

Um outro exemplo seria a compra de um equipamento sabendo-se que será necessário a operação contínua durante X dias. Desta forma, se o equipamento não operar em um dos dias destes X dias a empresa compradora perderá, em lucro cessante, um valor Y em moeda. Assim acerta com a empresa vendedora que durante o período de garantia deverá utilizar o equipamento durante X dias com uma taxa de confiabilidade de 100% e caso não alcance este percentual a empresa vendedora será multada em um VALOR= $W * Y * Z$ para ressarcimento de prejuízos, sendo W (peso multiplicativo sobre o valor total <1) e Z (número de dias parados).

2.4 Teste de aderência

2.4.1 Kolmogorov-Smirnov

Para verificar se a distribuição se ajusta ao conjunto de dados coletados foi utilizado o teste de Kolmogorov-Smirnov, teste (K-S). Este teste pode ser utilizado tanto em conjunto de dados pequenos, como em conjuntos maiores. O teste verifica a hipótese da função de distribuição acumulada $F_o(t)$ ser igual a $F(t)$. Se existem grandes desvios de uma amostra de distribuição acumulada $\widehat{F}(t)$ em relação a $F(t)$ então a hipótese é rejeitada, senão a hipótese é aceita e a distribuição pode ser usada para o cálculo dos valores da vida útil dos componentes.

Atualização de Probabilidade de Falhas Considerando Tipos de Falha Diferentes

3.1 Definição do Problema

Sabe-se que um ponto importante na operação de sistemas é a detecção de falhas, entretanto, muitas vezes o sistema pode estar sujeito a um elevado número de falhas que não são regidas pela mesma distribuição de probabilidade, ou seja, o comportamento das falhas afeta o sistema com características diferentes. Desta maneira, para que a atualização da probabilidade de cada falha ou componente seja regida pela distribuição correta, é necessário que a classificação das falhas ocorra em um momento anterior ao da atualização das probabilidades. A Figura 3.1 apresenta o esquema de atualização de probabilidades com o acréscimo de um classificador.

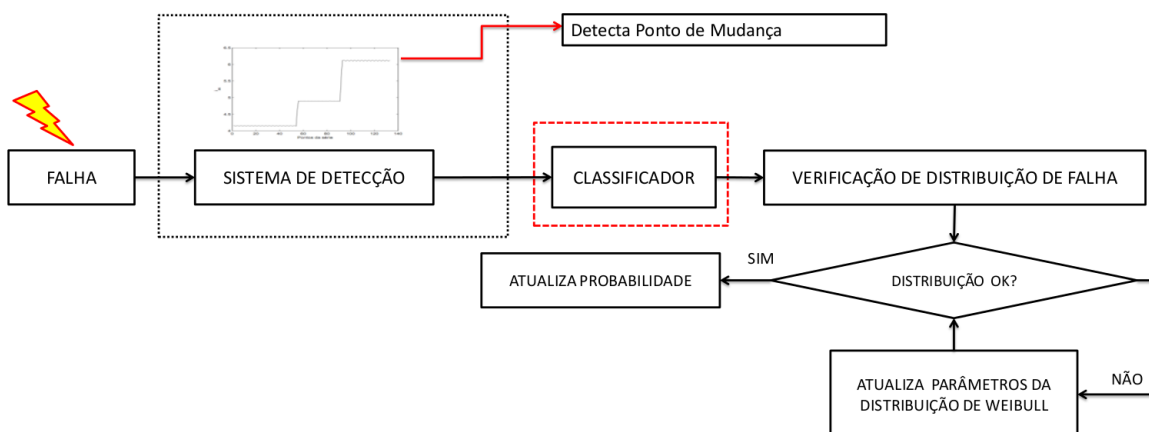


Figura 3.1: Esquema de detecção com um classificador adicionado.

3.2 Classificação de Falhas

Na indústria a classificação é realizada de diversas maneiras, sendo a mais usual a utilização do conhecimento dos operadores/mantenedores. Esta é uma tarefa que demanda grande esforço das equipes de campo (operação/manutenção) e nem sempre geram os resultados desejados, pois os dados nem sempre são devidamente coletados, armazenados e classificados. Algumas vezes, a equipe de avaliação de campo tem um parecer polarizado, o que pode prejudicar análises futuras quando da necessidade de utilização dos dados.

Atualmente, algumas empresas de consultoria realizam diagnóstico e criam estratégias de manutenção em empresas de diversos segmentos. Outras empresas utilizam ferramentas com suporte para armazenamento de dados em tempo real, como por exemplo o MES (*Manufacturing Execution System*) que pode ser visto como um sistema de planejamento e controle de produção, controle de estoques, histórico das variáveis de processo PIMS (*Plant Information Management System*) e controle de paradas de equipamentos DTM (*Down Time Monitor*).

O DTM módulo do MES que faz o gerenciamento de paradas da planta, tem o objetivo de registrar os eventos de perda de produtividade, seja por causas operacionais, de manutenção ou de força maior. Com isto é possível gerar uma priorização nos eventos de maiores perdas focando em estratégias que diminuam as paradas não planejadas a fim de aumentar a disponibilidade da planta e também sua utilização. Esta ferramenta vem se disseminando nos últimos anos para a coleta de dados de paradas, entretanto, sua classificação de falhas utiliza-se de dados binários para classificação e muitas das vezes não leva a ser desvendada a causa raiz de uma falha. A Tabela 3.1 apresenta um esquema de falhas para um equipamento (esquema similar ao usado no DTM), estas são falhas que podem ser detectadas em um motor de uma planta genérica. Nesta tabela percebe-se o monitoramento de 2 bytes (16 estados), os estados são divididos em falha, equipamento ligado e equipamento pronto para operar. Como as falhas são binárias e se baseiam em sinais elétricos/eletrônicos sua análise fica bastante limitada não abordando problemas operacionais e algumas vezes problemas mecânicos do equipamento. Outro ponto importante e que pode ser considerado falho é a definição de uma regra geral para caso exista a ocorrência de duas falhas de maneira simultânea, ou seja, caso ocorram duas falhas o usuário irá definir qual falha tem prioridade. Desta forma, quando se fala em estudos de confiabilidade, grande parte do tempo consumido pelas empresas ainda é no diagnóstico e na conversão dos dados coletados pelas equipes de campo em dados classificáveis.

3.3 Metodologia para determinação do tipo de falha

Uma outra opção seria a utilização de técnicas de *soft-computing* e aprendizado de máquina [26], na qual existe um conjunto de dados com padrões definidos, e que são

Tabela 3.1: Mapeamento dos estados de falha de um Motor

Bit de Memória	Estado do Equipamento	Diagnósticos	Prioridade	Intertravamentos
0	Pronto para Operar	Aguardando comando para início de operação		
1	Ligado (Sem falha)	Em operação		
2	Falhas Ocultas	Falhas Elétricas ou outra de qualquer tipo	2	
3	Falha	Falha por Intertravamento		Válvula Solenoide Fechada
4	Falha	Falha por Intertravamento		Gaveta do Motor extraída na subestação por equipe de manutenção
5	Falha	Sobrecorrente	3	
6	Falha	Sobretensão	4	
7	Falha	Falha por Intertravamento	6	Problemas no Inversor de Frequência
8	Falha	Sobrecarga	5	
9	Falha	Emergência Acionada em Campo	1	
10	reserva			
11	reserva			
12	reserva			
13	reserva			
14	reserva			
15	bypass ativo			Motor sofrerá bypass para não parar o processo.

utilizados para treinar uma estrutura que será responsável por classificar os dados a partir disto. Esta estrutura será capaz de realizar a classificação de padrões de novos dados de falha que tenham características similares. Desta forma, o sistema ganha em agilidade na coleta, classificação e armazenamento de falhas sendo o único entrave para utilização do mesmo a coleta de informação dos instrumentos/sensores de processo e o desenvolvimento da ferramenta computacional que será responsável pelo processo de classificação. Outro ponto é que esta ferramenta pode combinar um conjunto de sinais com o objetivo de definir uma falha, diferentemente da estrutura do DTM que se baseia em sinais binários e diretos. O problema de priorização ainda continua, mas de maneira mais atenuada, pois o banco de dados pode ser alimentado com novas informações rotuladas e assim o classificador será treinado favorecendo a classificação de outras falhas que ocorrerem de maneira simultânea.

Os classificadores de aprendizado supervisionado, no qual as amostras de treinamento normalmente são rotuladas, são ferramentas de grande utilidade em vários tipos de processo produtivo e em problemas do mundo real, em que o principal objetivo ao se utilizar um classificador é a determinação de um padrão a partir de suas características identificadoras. Por exemplo, deseja-se verificar se um determinado tipo de fruta é uma maçã ou uma laranja sem utilizar nenhuma intervenção humana. Para isto, utiliza-se alguns parâmetros como peso da fruta, tamanho e dureza. Após uma etapa de treinamento com um grande banco de dados de informações sobre laranjas e maçãs e amostras de teste rotuladas, coloca-se a prova a capacidade de classificação do sistema utilizando-se dos parâmetros descritos anteriormente. Os classificadores podem ser utilizados em uma grande variedade de aplicações para determinação de um padrão desejado. Bancos de dados em áreas de saúde, tecnologia, indústria e diversas outras aplicações podem ser encontrados em UCI Machine Learning Repository (www.ics.uci.edu/~mllearn/).

3.3.1 Classificador *Neuro-Fuzzy*

Na literatura existe uma grande variedade de classificadores que podem ser utilizados para determinação de padrões. Quando se fala em aprendizado supervisionado, alguns dos mais aplicados pela literatura são as Redes Neurais artificiais [23]; o SVM (*Support Vector Machine*) [3] e o Classificador Bayesiano.

As Redes Neurais Artificiais (RNA) são estruturas matemáticas com forte apelo em aplicações de reconhecimento de padrões [11]. Outra estrutura similar as redes neurais são os Sistemas Fuzzy, onde os classificadores Fuzzy são dependentes de regras linguísticas que normalmente são transmitidas por meio de conhecimento de pessoas especialistas ou por regras. As regras normalmente são extraídas de um conjunto de dados. Quando este conjunto de regras é extraído utilizando as redes neurais na fase de treinamento este sistema passa a ser chamado de sistema neuro-Fuzzy [7]. Um classificador que é recorrentemente empregado em reconhecimento de padrões é o

NFC (*Neuro Fuzzy Classifier*), que combina técnicas de inferência fuzzy com a capacidade de aprendizado das RNAs. O NFC realiza a classificação particionando o espaço de características em classes Fuzzy [25], assim são definidas as distribuições das classes e as relações entre entrada e saída. Como as redes neurais, o aprendizado do NFC é feito utilizando exemplos onde é comum encontrar algoritmos com gradiente de primeira ordem sendo utilizado no treinamento. Outros exemplos de algoritmo de otimização que agilizam a etapa de treinamento de um NFC podem ser encontrados em [9] e [7].

Uma outra técnica bastante importante quando se fala em complexidade do conjunto de dados é a extração de características. A extração de características diminui o número de características irrelevantes para o reconhecimento do padrão e desta forma torna o classificador mais robusto. Um exemplo de diminuição da complexidade utilizando extração de características pode ser encontrado em [8].

O NFC é formado pelas seguintes camadas: camada de entrada, camada de pertinência, camada de fuzzificação, camada de defuzzificação, camada de normalização e camada de saída. Este classificador possui várias entradas, as quais denominamos como características e várias saídas que podemos considerar como os rótulos ou classes. Os pesos na camada de defuzzificação afetam as regras e aumentam a flexibilidade na classificação. O método de clusterização *k-means* é usado para obter os parâmetros iniciais e as regras se-então [25].

A regra de classificação fuzzy que descreve a relação do espaço das características entrada e classes, pode ser definida conforme segue abaixo [25]:

$$\text{Se } X_1 \text{ é } A \text{ e } X_2 \text{ é } \dot{B} \text{ então } Z \text{ é } C$$

Em que X_1 e X_2 são características da variável de entrada. A e B são termos linguísticos caracterizados pela função de pertinência apropriada a qual descreve as características de um objeto C .

Na Figura 3.2 é apresentado um NFC com características similares ao apresentado em [25] e [9]. O espaço de características apresentado possui duas características de entrada, já a saída pode ser classificada em três diferentes tipos de padrões.

Uma representação dos espaço de características é apresentada na Figura 3.3. Cada característica possui três termos linguísticos definidos e como resultado existem nove regras fuzzy. Em outros trabalhos como [8] existe um pré-processamento com o objetivo de diminuir a complexidade das características de entrada.

Na primeira camada calcula-se o grau de pertinência com que as entradas satisfazem os termos linguísticos associados aos nós, isto determina o grau de pertinencia da função em forma de normal, dada por:

$$\mu_A(X_i) = \frac{1}{1 + \left[\left(\frac{x_i - c_i}{a_i} \right)^2 \right]^b}$$

Em que X_i é uma das variáveis de entrada, A é um dos termos linguísticos associado neste nó da função e $[a_i, b_i, c_i]$ é o conjunto de parâmetros. Inicialmente são definidos

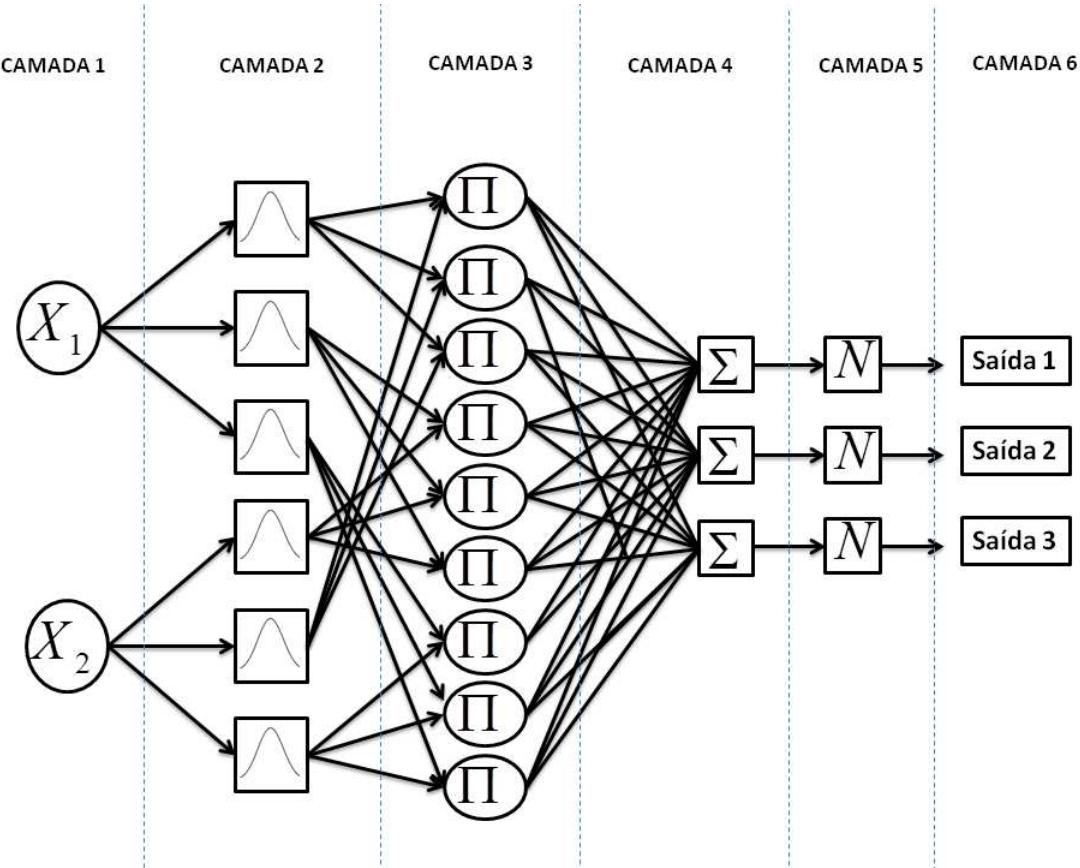


Figura 3.2: Classificador Neuro-Fuzzy




Figura 3.3: Divisão do Espaço de Características

valores com o objetivo de satisfazer as duas condições que caracterizam uma função de pertinência Fuzzy:

- Normalidade $\mu_A = 1$. pelo menos em um ponto
- Convexidade $\mu_A(x') \geq \mu_A(x_1) \wedge \mu_A(x_2)$, onde $\mu_A(x) \in [0,1]$ e $\forall x' \in [x_1, x_2]$

Após a definição inicial, os parâmetros são ajustados utilizando método baseado no gradiente descendente.

Na segunda camada cada nó gera um sinal correspondente à uma combinação conjuntiva e assim verifica-se os graus individuais de correspondência [25]. O sinal de saída corresponde ao grau de cumprimento de uma regra Fuzzy com relação a um objeto a ser categorizado. Na maior parte dos processos de classificação de padrões o operador conjuntivo realiza um papel importante e sua interpretação muda de acordo com o contexto. Desta maneira, não existe um operador que pode ser aplicado em qualquer tipo de problema. Um exemplo de norma que pode ser utilizada é a norma de Hamacher, que é dada por:

$$T_H(x_1, x_2, \gamma) = \frac{x_1 x_2}{\gamma + (1-\gamma)(x_1 + x_2 - x_1 x_2)}$$

Onde x_i 's são os operadores e γ é um parâmetro não negativo.

É importante notar que podem existir diferentes operadores matemáticos para cada nó da segunda camada, sendo que dependendo do compartimento dos operadores matemáticos alguns terão alcance local e outros terão abrangência global. Os parâmetros combinacionais também são ajustados por meio da utilização do gradiente.

Na terceira camada é realizada a combinação linear dos resultados dos operadores matemáticos e na quarta camada é feita uma normalização por meio de uma função sigmoide ou de outro tipo parecido. Assim calcula-se se o padrão pode fazer parte daquele tipo de classe ou não.

3.4 Atualização da Distribuição de Falha

Para atualização das probabilidades de falha foi usado o mesmo procedimento apresentado no capítulo 2, porém o vetor de dados de falha só foi atualizado após a classificação da falha.

Sistemas para Estudos de Casos

4.1 Aplicação em Sistemas

As abordagens de detecção de falhas e a atualização de probabilidades de falha propostas anteriormente, podem ser aplicadas em diversos tipos de sistemas. Exemplos de casos interessantes para aplicações seriam sistemas de transmissão de energia, sistemas de geração de energia, sistemas de transporte e sistemas de bombeamento de fluidos.

4.2 Sistema de Tanques Interativos

Para este trabalho um dos sistemas utilizados é o de Tanques Interativos, um tipo de sistema de bombeamento de fluidos onde o raciocínio aplicado seria o mesmo que em outros tipos de sistemas.

O sistema de tanques que foi apresentado em [4] e citado em [13] é um modelo matemático obtido a partir do balanço de massa entre os tanques TQ-2 e TQ-3 e utiliza a lei de Bernoulli conforme apresentado em [6]. Considerando que $x_1 = h_2, x_2 = h_3, y_1 = h_3, y_2 = q_o$ e $y_3 = q_i$, o modelo do sistema é representado pelas equações abaixo:

$$\begin{aligned} \dot{x}_1 &= \frac{1}{A}[q_1(R_1, U_1, P_1) - q_{23}(x_1, x_2)] \\ \dot{x}_2 &= \frac{1}{A}[q_{23}(x_1, x_2) - q_o(R_2, U_2, P_2)] \\ y_1 &= x_2 \\ y_2 &= q_o(R_2, U_2, P_2) \\ q_i(R_1, U_1, P_1) &= Q_i \max\{R_1, U_1, P_1\} \\ q_o(R_2, U_2, P_2) &= Q_o \max\{R_2, U_2, P_2\} \\ q_{23}(x_1, x_2) &= \frac{\sqrt{x_1 - x_2}}{R_h} \end{aligned}$$

A expressão para o cálculo de q_f é dada conforme abaixo:

$$q_f(R_i, u_i, p_i) = \frac{1}{\sqrt{1 + \left(\frac{1}{R_i^{2(u_i-1)}} - 1 \right) p_i}}$$

Além disso:

$q_o(R_2, U_2, P_2)$: é a vazão de saída do tanque TQ-3, em m^3/s ;

$q_i(R_1, U_1, P_1)$: é a vazão de entrada do tanque TQ-2, em m^3/s ;

$q_{23}(X_1, X_2)$: é a vazão entre os tanques TQ-2 e TQ-3, em m^3/s ;

$q_f(R_i, u_i, p_i)$: é a vazão fracionária da válvula "i";

Q_i max: vazão máxima de entrada do tanque TQ-2, em m^3/s ;

Q_o max: vazão máxima de saída do tanque TQ-3, em m^3/s ;

A : Área da base dos Tanques TQ-2 e TQ-3;

R_1 : Representa o alcance da válvula FCV-1;

R_2 : Representa o alcance da válvula FCV-2;

ρ_1 : razão entre a queda de pressão mínima e máxima da válvula FCV-1;

ρ_2 : razão entre a queda de pressão mínima e máxima da válvula FCV-2;

R_h : resistência hidráulica no duto entre os tanques;

u_1 : sinal de controle fracionário da válvula FCV-1;

u_2 : sinal de controle fracionário da válvula FCV-2.

Uma grande variedade de falhas pode ser simulada em um sistema semelhante ao descrito acima como, por exemplo, falhas de atuadores, falhas nos sistemas de medição, entupimento nos dutos de comunicação entre os tanques e perda de pressão na tubulação entre tanques devido a um furo. Um extenso trabalho abordando a maior parte destas falhas pode ser encontrado em [6].

Para o presente trabalho, o simulador é utilizado para verificar o comportamento de detecção e atualização de probabilidades de uma falha de entupimento entre Tanque 1 (TQ1) e Tanque (TQ3). O Simulador de Tanques Interativos é apresentado na Figura 4.1.

Em um segundo momento serão utilizadas as técnicas apresentadas no capítulo 3 para classificação de falhas. As características de entrada para defição do padrão serão as seguintes:

- nível do tanque TQ-3
- q_o vazão de saída do tanque TQ-3
- q_i vazão de entrada do tanque TQ-2

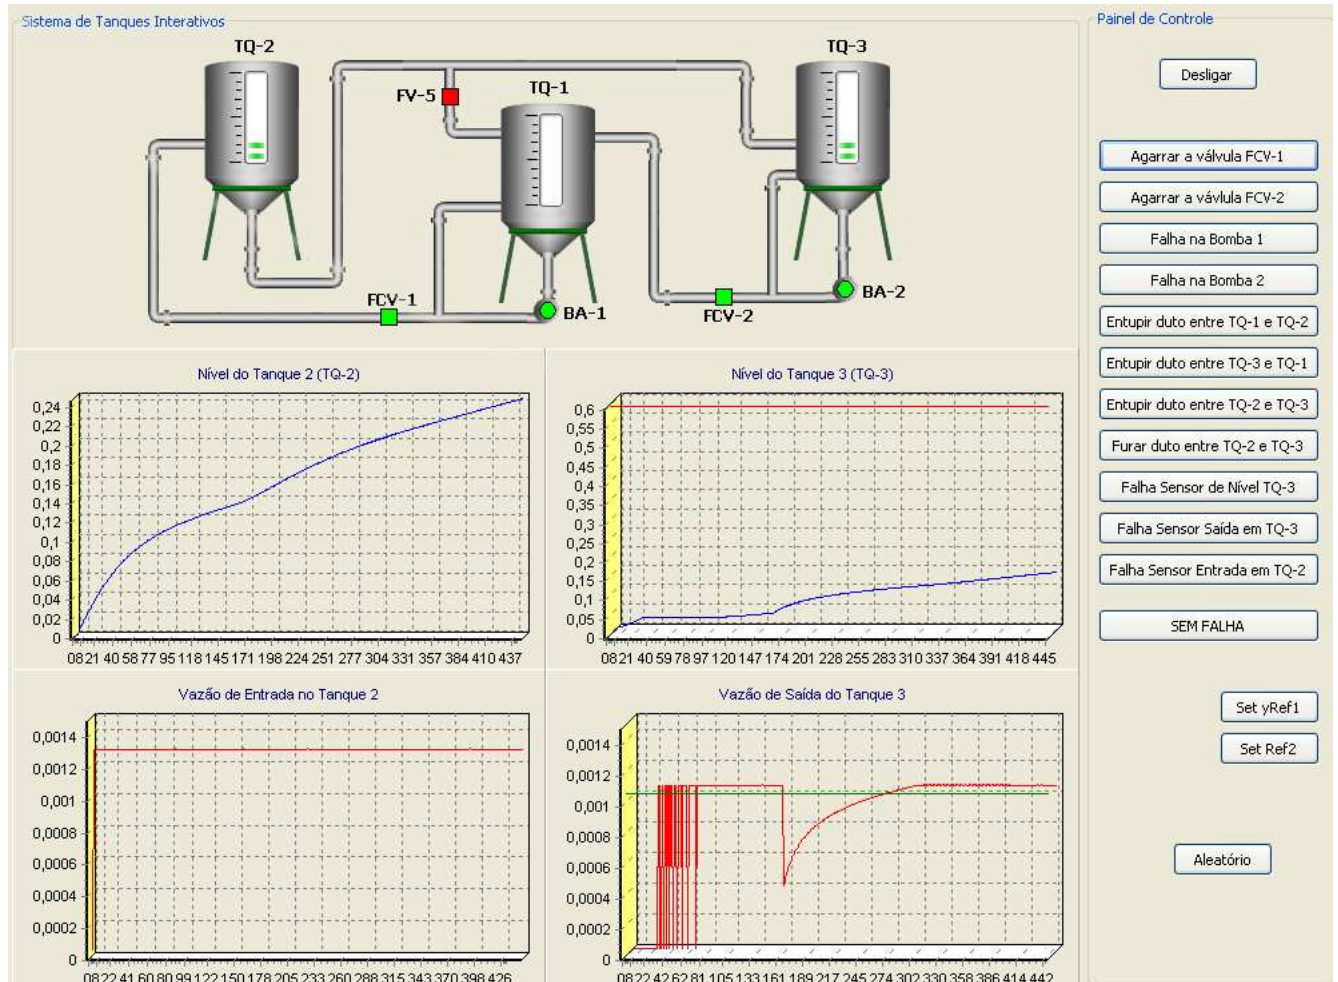


Figura 4.1: Simulador de Tanques Interativos apresentado em [10]

4.3 Transformadores

O outro sistema que será utilizado neste trabalho para testes de reconhecimento de padrões utilizando o NFC são os transformadores. Transformadores são elementos bastante importantes em redes de distribuição e estão sujeitos a diversos tipos de falha, como por exemplo descargas parciais, descargas de baixa e alta dissipação de energia e falhas térmicas. Em transformadores que utilizam óleo como isolante, é possível verificar a saúde do equipamento a partir dos gases liberados, para isto utiliza-se de

técnicas baseadas em análise cromatográfica. A severidade do evento de falha também pode ser determinada pela quantidade de gás liberado. Atualmente, já existem sistemas que fazem monitoramento *on-line* do funcionamento do transformador, o que em alguns casos faz com que a vida útil do equipamento aumente e que os *blackouts*, devido a falhas do transformador, sejam raros. Este fato aumenta consideravelmente a importância de se conhecer o comportamento de falhas em função da alteração da composição dos gases do sistema de isolamento.

Para subsidiar este trabalho, utilizou-se os dados disponibilizados em [14]. Este banco de dados é composto por 150 dados de falhas e as características de entrada são baseadas em taxas de gases C_2H_2/C_2H_4 , CH_4/H_2 e C_2H_4/C_2H_6 . Os tipos de falha que podem ser encontradas neste banco de dados são as seguintes:

1. Descargas Parciais
2. Descargas com baixa dissipação de Energia
3. Descargas com alta dissipação de Energia
4. Falhas térmicas abaixo de 300°C
5. Falhas térmicas acima de 700°C

Um outro estudo com o mesmo banco de dados pode ser encontrado em [2].

Resultados da Atualização

Neste capítulo são apresentados os resultados obtidos com todos os modelos de atualizações de probabilidades descritos nos capítulos anteriores. Inicialmente aplicou-se o que foi descrito no capítulo 2 para detectar falhas e atualizar as probabilidades de falha de um único modo de falha. Em um segundo momento detecta-se a falha, coletando os dados identificadores e aplicando-os em um classificador NFC para determinação do tipo de falha.

5.1 Atualização da Probabilidade de Falhas

5.1.1 Aplicação em um Sistema de Tanques Interativos

Foi montado um vetor de dados a partir de janelas de detecção de falhas. A primeira janela foi identificada como marco zero dos dados, (conforme Figura 5.1), e a partir deste marco foram ajustadas todas as probabilidades de falhas em função do tempo utilizando a distribuição de Weibull. Com o vetor de dados alterado foi realizado o teste K-S para verificar se o modelo ajustado seria válido para aquele conjunto de dados de falha.

Os parâmetros do sistema foram definidos para um ambiente com elevado grau de severidade, no qual as falhas são aceleradas em função das características de exposição a intempéries climáticas, químicas e partículas em suspensão no ar. Estas características foram escolhidas por comodidade, para aceleração do momento da falha. As janelas foram definidas em intervalos de 20000 segundos e o conjunto de dados de falhas foi composto por 9 amostras.

Sabe-se de antemão que as falhas criadas respeitam a distribuição de Weibull. A falha simulada foi o entupimento do duto que interliga o Tanque 1 e o Tanque 3. Para este trabalho esta falha foi considerada uma falha abrupta. Os tempos em que as falhas ocorreram em minutos são os seguintes 366, 788, 1136, 1342, 1739, 2227, 2728, 3145 e

3244. A figura 5.2 apresenta um gráfico do momento em que a falha é detectada para $t = 2227$ minutos ou 133.620 segundos.




Figura 5.1: Esquema de Janelas para Atualização de Probabilidades




Figura 5.2: Detecção de Falha para um dos Pontos

Desta forma, após as duas primeiras medidas, foi possível ajustar os parâmetros em uma distribuição de Weibull. Os dados foram testados a partir de um teste K-S, a um nível de 10% de significância, e em nenhum momento a hipótese nula foi rejeitada. A hipótese nula foi definida como sendo aquela cujo os dados se ajustam a uma distribuição de Weibull.

As Figuras 5.3 e 5.4 respectivamente, apresentam a Função de Densidade de Probabilidade - do termo em inglês *Probability Density Function* (PDF) - e Função de Distribuição Acumulada - do termo em inglês *Cumulative Distribution Function* (CDF).

Na Tabela 5.1 são apresentados os parâmetros ajustados após cada ponto de falha que foi acrescentado no conjunto de dados. A Figura 5.5 apresenta a curva de Weibull obtida após a coleta das 9 amostras, onde o eixo das abcissas representa o tempo de

operação do componente e o eixo das ordenadas a probabilidade da falha ocorrer dado aquele intervalo de tempo.

Decisões importantes podem ser tomadas com os dados obtidos a partir de um modelo de detecção/atualização/estimação como este. Caso queira-se, por exemplo, determinar qual é o tempo em que se deseja que uma tubulação como esta opere sem entupimento pode-se escolher um percentual de confiabilidade que seja relevante para o processo e o seu intervalo de confiança para o tempo desejado. Para ilustrar a situação, considere que a tubulação deve funcionar por 200 minutos ininterruptos para que o processo em batelada seja executado. Sabe-se que este tipo de tubulação transporta fluido perigoso que pode gerar complicações em caso de vazamento. Desta maneira, a partir da distribuição obtida chega-se que para $t = 200$ minutos tem-se a confiabilidade de 83,21% do equipamento ainda estar operando. Para um nível de significância de 5% chega-se a um limite inferior do intervalo de confiança com 59,38% e o limite superior não pode ser determinado. Assim, pode-se adotar medidas como a inserção de uma nova tubulação *by-pass* que possa substituir a primeira caso ocorra entupimento, aumentando assim a disponibilidade do sistema. Outro fato importante é que a partir deste tempo pode-se prever qual será o instante que o custo-benefício da manutenção terá os melhores valores e ainda pode-se dimensionar o quadro de mão de obra, visando atingir as metas de indicadores de desempenho especificadas para sistemas, equipamentos e componentes.

Um fato importante para avaliar a política de manutenção a ser utilizada é o parâmetro β . Neste caso como ele é maior que 1, as características de desgaste já são perceptíveis, o que favorece a utilização das políticas de manutenção preventiva/preditiva.

Tabela 5.1: Função Densidade de probabilidade acumulada

t	F(t)	$\beta - \eta$
60	0,12%	3,52 400,15
120	1,43%	3,52 400,15
180	5,82%	3,52 400,15
240	15,22%	3,52 400,15
300	30,40%	3,52 400,15
360	49,79%	3,52 400,15
420	69,46%	3,52 400,15
480	85,02%	3,52 400,15
540	94,36%	3,52 400,15
600	98,45%	3,52 400,15




Figura 5.3: Função de Densidade de Probabilidade para a falha de entupimento

5.2 Atualização de Taxa de Falhas Considerando Tipos de Falhas Diferentes

A partir do item anterior é possível perceber a importância de se conhecer a taxa de falha de um sistema. Assim, quando mais de uma falha começa a ocorrer de maneira simultânea em qualquer tipo de sistema fica difícil de determinar quais são os reais motivos da falha. Para tornar o processo mais fácil, considera-se que os

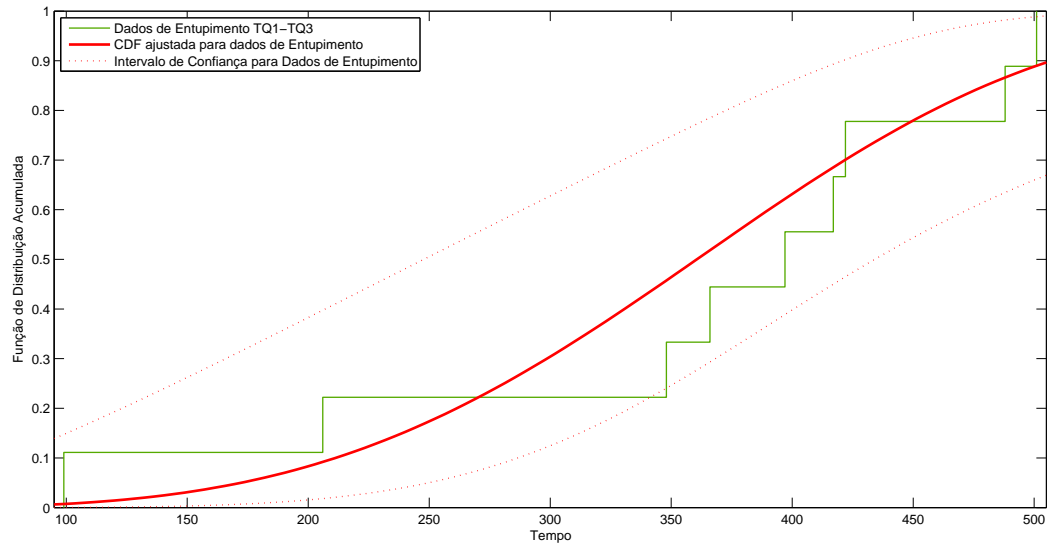


Figura 5.4: Função de Distribuição Acumulada para a falha de entupimento




Figura 5.5: Gráfico de Probabilidade Weibull

sistemas possuem eventos de falhas independentes e identicamente distribuídos. Desta forma, quando existe substituição do item é como se ocorresse a recuperação total do componente (*as good as new*).

Para testar o classificador apresentado no capítulo 3 utilizou-se dois conjuntos de dados. O primeiro deles é um conjunto de dados artificiais em que simulou-se diversas falhas no sistema de tanques interativos. Em um segundo momento foram utilizados os dados reais de falhas apresentado em [14].

5.2.1 Aplicação em um Sistema de Tanques Interativos

Para aplicação no sistemas de Tanques Interativos foram simulados 200 tipos de eventos. Dentro destes eventos podem ser verificadas falhas de agarramento em válvulas, falhas de entupimento e também casos que o sistema opera de maneira normal. O estado normal pode ser ainda uma verificação para um falso positivo, ou seja, uma falha detectada que não ocorreu e, assim, o sistema de classificação pode confirmar o que é avaliado pelo sistema de detecção de falha.

Nos testes com três tipos de eventos (agarramento da válvula FCV1, agarramento da válvula FCV2 e estado normal; ou agarramento da válvula FCV1; entupimento Tanque TQ1 e estado normal) foram utilizados 150 padrões para treinamento e validação. Já para quatro tipos de eventos (agarramento da válvula (FCV1), agarramento da válvula (FCV1), entupimento (TQ1-TQ3) e estado normal) foram utilizadas 200 amostras. Elaborou-se um software para simulação que variava os dados de treinamento do NFC entre 10% e 90% com um passo de 10%. Para cada estrutura de dados de treinamento o algoritmo foi repetido por 20 iterações. As amostras foram aleatorizadas com o objetivo de retirar qualquer possibilidade de polarização dos dados, ou seja, eliminar quaisquer possíveis tendências que poderiam prejudicar a generalização do classificador. Os melhores resultados obtidos ocorreram utilizando 70% das amostras para treinamento. Conforme pode ser visualizado na Tabela 5.2 os valores para validação, dados que não fazem parte do conjunto de treinamento, alcançaram um percentual de acerto de 88,88% com três estados diferentes e 70% com quatro estados diferentes.

Após a etapa inicial de classificação foi realizado o processo de atualização das probabilidades de falha com o objetivo de determinar a política de manutenção. Neste caso foram apresentados análises estatísticas de dois tipos de modo de falha que tiveram seus dados de falha gerados de maneira artificial. Considerando-se que os eventos são iid chega-se nos gráficos de PDF, CDF e Weibull apresentados nas Figuras 5.6, 5.7 e 5.8 para os modos de falha, consideradas falhas abruptas para este trabalho, entupimento do Tanque (TQ1-TQ3) e agarramento da válvula (FCV1).

Os dados para o entupimento do tanque são os mesmos apresentados anteriormente, já para o agarramento de válvula temos a seguinte sequência simulada artificialmente: 396, 876, 1204, 1629, 2096, 2435, 2814 e 3186. A tabela 5.2 apresenta o aumento da taxa de falha em função dos tempos para as duas falhas. Percebe-se que a falha de

agarramento começa com uma taxa de falha maior que a de entupimento e a medida que o tempo vai correndo ela é superada pelo outro modo de falha. Pode-se perceber que o fator de escala da falha de agarramento é um pouco menor do que da falha de entupimento e o mesmo ocorre para o fator de forma. De toda maneira, para este valor de forma ainda se recomenda a adoção de uma manutenção preventiva/preditiva, mas de toda forma a idade de envelhecimento, no modo de falha agarramento, é um pouco mais lenta quando comparada com o entupimento.




Figura 5.6: PDF para a falha de entupimento TQ1-TQ3 e Agarramento FCV1

5.2.2 Aplicação em um Transformador

No transformador foram realizados procedimentos parecidos ao Tanque Interativo. Para isto foram utilizados dados de falha em transformadores em serviço, que foram obtidos por meio da base de dados de [14].

Em virtude do número de amostras para realizar a classificação das falhas, 142 amostras, as classes foram concentradas em três tipos de falha (Falhas por Descargas; Falhas Térmicas e o Estado Normal). As falhas por descargas aglomeram as falhas com alta e baixa descarga de energia, já as falhas térmicas englobam falhas abaixo de 300°C e acima de 700°C. O treinamento novamente contou com 20 iterações e as amostras também foram aleatorizadas.

Após a etapa de treinamento chegou-se a uma taxa de acerto de validação de 86.04%. Assim, percebe-se que o classificador pode ser usado com bastante eficiência nos problemas de classificação de falhas em transformadores.

A partir disto, foi utilizado o histórico de falhas de transformadores com as seguintes características que foram obtidos em [16]:

Tabela 5.2: Taxa de Falha em Função do Tempo entre Falhas de Entupimento e Agarramento

t	F(t) $\beta : 3,52 - \eta : 400,15$	F(t) $\beta : 2,03 - \eta : 363,17$
60	0,12%	2,56%
120	1,43%	10,05%
180	5,82%	21,41%
240	15,22%	35,06%
300	30,40%	49,28%
360	49,79%	62,56%
420	69,46%	73,89%
480	85,02%	82,80%
540	94,36%	89,30%
600	98,45%	93,72%




Figura 5.7: CDF para a falha de entupimento TQ1-TQ3 e Agarramento FCV1

Tabela 5.3: Classificação de Falhas em Tanques e Transformadores utilizando NFC

SISTEMA	TESTE	AMOSTRAS	AMOS- TRAS PARA TREINA- MENTO	ACERTO TREINA- MENTO	ACERTO VA- LIDAÇÃO
TRAFO	3 Tipos de Estado:(DESCARGAS, TÉRMICAS e ESTADO NORMAL)	142	7%0	85,86%	86,04%
TANQUES	3 Tipos de Estado: (AGARRAMENTO FCV1, AGARRAMENTO FCV2 e ESTADO NORMAL)	150	70%	90,48%	88,88%
TANQUES	3 Tipos de Estado: (AGARRAMENTO FCV1, ENTUPIAMENTO TQ1 e ESTADO NORMAL)	150	70%	85,71%	88,88%
TANQUES	4 Tipos de Estado: (AGARRAMENTO FCV1, AGARRAMENTO FCV2, ENTUPIAMENTO TQ1 e NORMAL)	200	70%	67,14%	70%

- Níveis de Tensão de 50/10kV
- Níveis de Tensão de 50/6 kV

Com o objetivo de adequar o histórico de falhas ao classificador anteriormente apresentado, analisou-se a atualização de probabilidade de falha apenas para o curto-circuito dos enrolamentos. Desta forma, o histórico de falhas foi composto pelas seguintes falhas: falha 1=26,5 anos, falha 2=33,3 anos, falha 3=39,5 anos, falha 4=43,5 anos e falha 5=45,5 anos. Com isso chegou-se aos gráficos de PDF, CDF e Função de Weibull ajustada apresentados nas figuras 5.9, 5.10 e 5.11. Os parâmetros obtidos após a análise de Weibull são $\beta = 6,8$ - $\eta = 40,49$, como $\beta > 1$ as características que predominam no tipo de manutenção a ser realizada é preventiva/preditiva.




Figura 5.8: Gráfico de Probabilidade de weibull - falha Entupimento e Agarramento FCV1




Figura 5.9: PDF para a falha no Enrolamento do Transformador




Figura 5.10: CDF para a falha no Enrolamento do Transformador




Figura 5.11: Gráfico de Probabilidade de Weibull para falha no enrolamento do Trafo.

Considerações Finais

6.1 Conclusões

Neste trabalho foi proposta uma metodologia para atualizar um modelo de confiabilidade utilizando um algoritmo de detecção de falhas proposto recentemente na literatura. Este tipo de metodologia mostra-se interessante, conforme apresentado em [24], para prever alternativas de manutenção bem como o planejamento de investimento em processos que demandem um longo tempo de funcionamento. Um outro problema bastante curioso que gera diversas discussões na indústria é a coleta de dados de falha, com a classificação de falhas correta. Desta forma, o classificador se torna uma ferramenta de suporte e de otimização de tempo quando se fala em coleta de dados de falhas. Modelos com distribuições de probabilidades diferentes podem ser atualizados a partir de dados coletados utilizando o algoritmo de detecção e classificados utilizando os classificadores de falha. Assim, a idéia de se misturar falhas diferentes e indentificá-las é um processo que trás bastante robustez ao sistema dando mais força ao sistema com coleta de dados de falha de maneira automatizada.

6.2 Trabalhos Futuros

Uma ideia para trabalhos futuros consiste em adicionar dados censurados. Os dados censurados são aqueles que a manutenção é realizada antes do componente falhar. Estes dados são adicionados em conjunto com os dados de falha, o que faz com que as previsões de tempo ótimo para manutenção melhorem e faz com que consiga-se atuar de maneira preventiva em componentes, equipamentos ou sistemas. Esta ação combate um problema real quando se fala em manutenção, que é a falta de dados de falha de equipamento. Assim, mesmo que o sistema não falhe, ele é ainda alimentado com informações que direcionam na composição de um tempo ótimo para manutenção do sistema.

Outro tipo de abordagem que pode ser explorada é a utilização do algoritmo apresentado em [20] para atualização, de maneira on-line, da probabilidade de falhas em sistemas que utilizam a manutenção baseada na condição como sua estratégia de

manutenção. Um sistema que poderia facilmente ter esta técnica aplicada é um sistema de distribuição de energia que conta como principal elemento os transformadores elevadores e abaixadores. Caso sejam transformadores extremamente críticos para o processo, eles podem ser monitorados em tempo real a partir dos gases de isolamento e resfriamento que estão imersos em sua câmara de lubrificantes.

Referências Bibliográficas

- [1] ABNT. *NBR 5462 -Confiabilidade e Manutenibilidade*. Associação Brasileira de Normas Técnicas - ABNT, 2004.
- [2] A.Venkatasami, Dr.P.Latha, and K.Kasirajan. Diagnosis of transformer faults based on adaptive neuro-fuzzy inference system. *International Journal of Scientific Engineering Research*, 3(2):1–4, 2012.
- [3] A. Basu, C. Watters, and M. Shepherd. Support vector machines for text categorization. *International Conference on System Sciences - IEEE*, 2002.
- [4] Anísio Rogério Braga. *Implementação de Estratégias de Controle Multimalha e Multi-variável*. Master thesis, Universidade Federal de Minas Gerais, Brasil, 1994.
- [5] Carolina Leite Barbosa Cajazeira. *Estudo dos Fatores RAM na Fase de Operação e Manutenção de Aerogeradores*. Phd thesis, Universidade do Moinho, Portugal, 2012.
- [6] Walmir Matos Caminhas. *Estratégias de Detecção e Diagnóstico de Falhas em Sistemas Dinâmicos*. Phd thesis, Universidade Estadual de Campinas - UNICAMP 1997, Brasil, 1997.
- [7] Bayram Cetisli. Development of an adaptive reuro-fuzzy classifier using linguistic hedges: Part 1. *Expert Systems with Applications*, (37):6093–6101, 2010.
- [8] Bayram Cetisli. The effect of linguistic hedges on feature selection: Part 2. *Expert Systems with Applications*, (37):6102–6108, 2010.
- [9] Bayram Cetisli and Atalay Barkana. Speeding up the scaled conjugate gradient algorithm and its application in neuro-fuzzy classifier training. *Soft Comput*, (14):365–378, March 2010.
- [10] Marcos F. S. V. D’Angelo. *Iterative tanks system by fault simulation*. www.dcc.unimontes.br/~dangelo/benchmark.rar, 2011.
- [11] Marcos F. S. V. D’Angelo, Reinaldo M. Palhares, Walmir M. Caminhas, Ricardo H. C. Takahashi, Renato D. Maia, André P. Lemos, and Maurílio J. Inácio. Detecção

- de falhas: uma revisão com aplicações. *Anais do Congresso Brasileiro de Automação 2010*, mar 2010. Tutoriais do CBA. Bonito, MS.
- [12] Marcos F. S. V. D'Angelo, Reinaldo M. Palhares, Ricardo H.C. Takahashi, and Rosângela H. Loschi. Fuzzy/Baysian change point detection approach to incipient fault detection. *IET - Control Theory & Applications*, 5(4):539–551, 2011.
- [13] Marcos F. S. V. D'Angelo, Douglas H. Fonseca Silva, Reinaldo M. Palhares, Walmir M. Caminhas, Fabiano S. Moreira, and André P. Lemos. Detecção de falhas em tanques interativos utilizando uma abordagem neural/fuzzy/Bayesiana para detecção de ponto de mudança. *Anais do Congresso Brasileiro de Inteligência Computacional 2011*, Novembro 2011. X Congresso Brasileiro de Inteligência Computacional. Fortaleza, CE.
- [14] Michel Duval and Alfonso dePablo. Interpretation of gas-in-oil analysis using new iec publication 60599 and iec tc 10 databases. *IEEE Electrical Insulation Magazine*, 17(2):31–41, 2001.
- [15] Andrew K.S. Jardine and Albert H. C. Tsang. *Maintenance, Replacement and Reliability*. Taylor & Francis Group, 2006.
- [16] Rogier Jongen, E. Gulski, P. Morshuis, J. Smit, and A. Janssen. Statistical analysis of power transformer component life time data. In *Power Engineering Conference, 2007. IPEC 2007. International*, pages 1273–1277, 2007.
- [17] Allan Kardec and Julio Nascif. *MANUTENÇÃO - FUNÇÃO ESTRATEGICA. QUALITYMARK*, 1999.
- [18] Lawrence M. Leemis. *Probabilistic Models and Statistical Methods*. Prentice Hall, Inc., Englewood Cliffs, New Jersey, 1995.
- [19] D.M. Lout, R. Pascual, and A.K.S. Jardine. A practical procedure for the selection of time-to-failure models based on the assessment of trends in maintenance data. *Reliability Engineering and System Safety*, (94):1618–1628, 2009.
- [20] Fabiano S. Moreira. *Detecção de Pontos de Mudança em Séries Temporais Utilizando Uma Formulação Neural/Fuzzy/Bayesiana: Aplicação na Detecção de Falhas*. Phd thesis, Universidade Federal de Minas Gerais, Brasil, 2011.
- [21] Glenford J. Myers, Tom Badgett, Todd M. Thomas, and Corey Sandler. *The art of software testing*. John Wiley Sons, 2004.
- [22] Robson Quinello and Jose Roberto Nicoletti. Inteligência competitiva nos departamentos de manutenção industrial no brasil. *Journal of Information System and Technology Management*, 2(1):21–37, 2005.

- [23] Renan N. O. Souza, Alexandre S. Brandão, Matheus N. Faria, André G. Torres, and Tarcisio A. Pizziolo. Acionamento de cargas via comando de voz utilizando técnicas de redes neurais artificiais. *Anais do Congresso Induscon 2006*, 2006. Conferência Internacional de Aplicações Industriais, 2006, Recife - PE. IEEE - VII INDUSCON.
- [24] Renan N. O. Souza, Reinaldo M. Palhares, Marcos F. S. V. D'Angelo, and Walmir M. Caminhas. Atualização de distribuições de probabilidade e taxas de confiabilidade utilizando técnicas de detecção de falhas. *Anais do Congresso Brasileiro de Automação 2012*, Setembro 2012. XIX Congresso Brasileiro de Automática. Campina Grande, Paraíba.
- [25] Chuen-Tsai Sun and Jyh-Shing Jang. A neuro-fuzzy classifier and its applications. *Proceedings of IEEE International Conference on fuzzy systems*, pages 94–98, 1993. San Francisco.
- [26] Lofti A. Zadeh. Fuzzy logic, neural networks and soft computing. *IEEE Transactions on Systems, Man, and Cybernetic*, (3):77–84, March 1994.