



UNIVERSIDADE FEDERAL DO AMAZONAS
FACULDADE DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

DETECÇÃO E DIAGNÓSTICO REMOTO DE FALHAS BASEADO EM
APRENDIZADO DE MÁQUINA PARA EQUIPAMENTOS DE USO DOMÉSTICO

JORGE DA COSTA SEABRA

Manaus-AM

2017



UNIVERSIDADE FEDERAL DO AMAZONAS
FACULDADE DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

JORGE DA COSTA SEABRA

DETECÇÃO E DIAGNÓSTICO REMOTO DE FALHAS BASEADO EM
APRENDIZADO DE MÁQUINA PARA EQUIPAMENTOS DE USO DOMÉSTICO

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Amazonas como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica, área de concentração Controle e Automação de Sistemas.

Orientador. Prof. Dr.–Ing. Vicente Ferreira de Lucena Júnior

Manaus-AM

2017

Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

S438d Seabra, Jorge da Costa
Detecção e Diagnóstico Remoto de Falhas Baseado em
Aprendizado de Máquina para Equipamentos de Uso Doméstico /
Jorge da Costa Seabra. 2017
81 f.: il.; 31 cm.

Orientadora: Vicente Ferreira de Lucena Júnior
Dissertação (Mestrado em Engenharia Elétrica) - Universidade
Federal do Amazonas.

1. Detecção e diagnóstico de falha (DDF). 2. Aprendizado de
máquina. 3. algoritmo. 4. monitoramento tempo real. I. Lucena
Júnior, Vicente Ferreira de II. Universidade Federal do Amazonas
III. Título

JORGE DA COSTA SEABRA

DETECÇÃO E DIAGNÓSTICO REMOTO DE FALHAS BASEADO
EM APRENDIZADO DE MÁQUINA PARA EQUIPAMENTOS DE USO
DOMÉSTICO

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Amazonas como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica, área de concentração Controle e Automação de Sistemas.

BANCA EXAMINADORA

Aprovado em, 28 de abril 2017

Prof. Dr.–Ing. Vicente Ferreira de Lucena Júnior, Presidente
Universidade Federal do Amazonas

Prof. Dr. José Luís de Souza Pio, Membro
Universidade Federal do Amazonas

Prof. Dr. João Edgar Chaves Filho, Membro
Universidade Federal do Amazonas

Dedico este trabalho à minha família, em especial minha esposa Marciléa Matias Seabra, pela compreensão e apoio e minha mãe Maria Tereza da Costa Seabra minha eterna incentivadora.

AGRADECIMENTOS

Primeiramente agradeço a Deus, por tudo que tenho em vida.

À minha família, em especial à minha mãe, pelo apoio imensurável em todos os momentos que dela necessitei. Aos meus filhos, Jorge, Vanessa, Leandro, André.

Em memória ao meu pai Hipio de Freitas Seabra e da minha querida sogra, Maria Soledade Gentil de Souza.

A todos os professores e a coordenação técnica do Programa de Mestrado em Engenharia Elétrica da UFAM por contribuírem direta e indiretamente para minha formação acadêmica.

Ao orientador, professor Vicente Ferreira de Lucena Junior, por todo suporte durante o Mestrado.

Aos meus colegas do laboratório de TV Digital, Vandermi Silva, Mario Jr., Yuri Mota, Elton Pinheiro, Paulo Mouzinho pelo apoio e incentivo a minha pesquisa.

À CAPES, UFAM e CETELI, pelo apoio financeiro através de bolsa de estudo e laboratórios para o desenvolvimento da pesquisa.

RESUMO

Os equipamentos domésticos convencionais que utilizamos no dia a dia, praticamente, não são monitorados para verificação de falhas e defeitos em tempo real. Neste trabalho, será apresentada uma abordagem da aplicação do aprendizado de máquina com a utilização de dados selecionados dos equipamentos quando em funcionamento, e de dados referências extraídos das fichas técnicas.

Para analisar, comparar e avaliar as diferenças nos conjuntos de dados, foi desenvolvido o dispositivo de detecção e diagnóstico de falha para classificar os sintomas que podem representar defeitos nos equipamentos em tempo real. As ocorrências das falhas destes equipamentos, tradicionalmente são identificadas pelos próprios usuários quando o desempenho esperado não acontece. Com a utilização de uma placa micro processada conectada aos sensores eletrônicos instalados em pontos estratégicos no equipamento, inicia-se a etapa da comparação de dados, os dados coletados são transmitidos ao servidor que através do algoritmo de Aprendizado de Máquina executa as tarefas para identificação das falhas detectadas. O monitoramento em tempo real do comportamento das grandezas elétricas e físicas dos equipamentos de usos domésticos convencionais tem como objetivo, monitorar o comportamento funcional e informar ao usuário, eventuais falhas, utilizando os recursos da rede local ou da internet.

Palavras-chave: Detecção e Diagnóstico de Falha, Grandezas Elétricas e Físicas, Aprendizado de Máquina, Sensores, Algoritmos, Internet.

ABSTRACT

The conventional household equipment we use on a day-to-day basis is practically not monitored for real-time faults and defects. In this work, an approach will be presented to the application of machine learning with the use of selected data of the equipment when in operation, and of data references extracted from the datasheets.

In order to analyze, compare and evaluate differences in data sets, the fault detection and diagnosis device was developed to classify the symptoms that may represent defects in the equipment in real time. The occurrences of these equipment failures are traditionally identified by the users themselves when the expected performance does not occur. With the use of a microprocessed board connected to the electronic sensors installed at strategic points in the equipment, the data comparison step is started, the data collected are transmitted to the server, which through the Machine Learning algorithm performs the tasks for identification of the Detected failures. Real-time monitoring of the behavior of electrical and physical magnitudes of conventional household equipment is aimed at monitoring functional behavior and informing the user of any faults using local or Internet resources.

Keywords: Detection and Diagnosis of Failure, Electrical and Physical Quantities, Machine Learning, Sensors, Algorithms, Internet.

LISTA DE SIGLAS

AM	-----	aprendizado de máquina.
DDF	-----	detecção e diagnóstico de falha.
WEB	-----	rede de computadores de alcance mundial.
KDD	-----	knowledge discovery in database.
IA	-----	inteligência artificial.
WEKA	-----	Waikato environment for knowledge analysis.
ARRF	-----	attribute relation file format.
BTU	-----	british thermal unit.
CETELI	-----	centro de pesquisa tecnologia eletrônica e da informação.
UFAM	-----	universidade federal do Amazonas.
HTTP	-----	protocolo de transferência de hipertexto.
ETHERNET	-----	rede de área local (LAN)
RJ	-----	registered jack
ASHRAE	-----	sociedade americana de engenheiros de aquecimento, refrigeração e ar condicionado.
WIFI	-----	fidelidade sem fio em português.
BLUETOOTH	-----	rede sem fio de âmbito pessoal.
VAC	-----	tensão alternada
VDC	-----	tensão contínua

LISTA DE FIGURAS

Figura 1 - Eletrodomésticos convencionais.	16
Figura 2 - Grandeza Avaliada e Regimes operação.....	19
Figura 3 - Detecção de falha na grandeza monitorada em regime permanente.	20
Figura 4 - Diagrama do funcionamento do detector de falhas.....	22
Figura 5 - Etapas de processo de descoberta de conhecimento em bases de dados.	25
Figura 6 - Hierarquia de aprendizado.	32
Figura 7 - Aprendizado Indutivo.	32
Figura 8 - Formato do arquivo arff para software Weka.	34
Figura 9 - Exemplo de conjunto de dados Instâncias, Atributos, Classe.....	34
Figura 10- Árvore de decisão construída a partir da Tabela 1.....	36
Figura 11- Algoritmo Naive Bayes e a relação entre os atributos e a Classe.	39
Figura 12 - Rede Bayesiana e a relação entre os atributos e a Classe.	40
Figura 13 - Fluxo de funcionamento do equipamento.	42
Figura 14 - Arquitetura do DDF proposto.	42
Figura 15 - Módulo de aquisição de dados.	43
Figura 16 - Servidor DDF.....	44
Figura 17 - Pré-processamento de dados.	45
Figura 18 - Exemplo de ficha técnica ar condicionado.	45
Figura 19 - Etapas de Aprendizado e Produção.....	46
Figura 20 - Módulo usuário.	47
Figura 21 - Ar condicionado convencional modelo Silentia.	50
Figura 22 - Sensor eletrônico de tensão.....	51
Figura 23 - Sensor eletrônico de corrente.....	51
Figura 24 - Sensor eletrônico de temperatura.	52
Figura 25 - Sensor eletrônico de vibração.	52
Figura 26 - Sensor eletrônico de presença.	53
Figura 27 - Sensor magnético de abertura.	53
Figura 28 - Atuador para interrupção do ar condicionado.....	54
Figura 29 - Shield WiFi de comunicação sem fio.	54
Figura 30 - Placa de aquisição de dados Intel Galileo.....	55
Figura 31 - Princípio básico de funcionamento - Ciclo frio do ar condicionado.....	56
Figura 32 - Sensores, módulo de aquisição.de dados e ar condicionado.....	57

Figura 33 - Arquivo arff contendo exemplo do ar condicionado.	59
Figura 34 - Protótipo instalado na Sala de Convivência / CETELI (UFAM).....	63
Figura 35 - Tela inicial do monitoramento remoto ar condicionado.	64
Figura 36 - Monitoramento ar condicionado acesso remoto.	64
Figura 37 - Ar condicionado com filtro de ar obstruído.	65
Figura 38 - Diagnóstico filtro de ar.	65
Figura 39 - Entrada de ar externo obstruídas.	66
Figura 40 - Diagnóstico compressor.	66
Figura 41 - Tela do monitoramento DDF ar condicionado diagnóstico vibração.	67
Figura 42 – Diagnóstico ausência.	67
Figura 43 - Diagnóstico ausência.	68
Figura 44 – Módulo de aquisição, servidor DDF, internet e usuário.	68

LISTA DE TABELAS

Tabela 1 - Aparelhos convencionais: sintomas, causas e diagnósticos.....	24
Tabela 2 - Dados de treinamento.....	35
Tabela 3 - Referências de tensão para o ar condicionado.....	50
Tabela 4 - Referências da variável corrente elétrica.	51
Tabela 5 - Referências da variável temperatura.....	52
Tabela 6 - Referências dos sensores eletrônicos e placa Intel Galileo.....	55
Tabela 7 - Base de dados instâncias x atributos do ar condicionado.	58
Tabela 8 -Taxas dos acertos dos algoritmos.	60
Tabela 9 - Resultados das experiências das falhas e diagnósticos.	69

SUMÁRIO

1 Introdução	14
1.1 Motivação.....	15
1.2 Definição do Problema.....	16
1.3 Objetivos	17
1.3.1 Geral	17
1.3.2 Específicos	17
2. Fundamentos e Trabalhos Relacionados	18
2.1 Fundamentos Teóricos	18
2.1.1 Conceitos de Detecção e Diagnóstico de Falha	18
2.1.2 Modelos de Classificação de Falha	22
2.1.3 Mineração de Dados	24
2.2 Trabalhos Relacionados	28
2.3 Conclusão.....	30
3. Aprendizado Automático – Estado da Arte	31
3.1 Aprendizado de Máquina	31
3.1.1 Software para Aprendizado de Máquina	33
3.1.2 Algoritmos de Aprendizado de Máquina	35
3.2 Conclusão.....	40
4. Proposta DDF - Equipamentos Domésticos Convencionais	41
4.1 Arquitetura do Sistema DDF Proposto	41
4.1.1 Módulo de Aquisição de Dados	42
4.1.2 Módulo Servidor DDF	44
4.1.3 Módulo Usuários	47
4.2 Conclusão.....	48
5. Implementação do projeto DDF	49
5.1 Equipamento Ar Condicionado Convencional	49
5.1.1 Extração de Dados On Line - Variáveis	50
5.1.2 Princípio Básico do Ar Condicionado	55
5.1.3 Classificador e Algoritmo	57
5.2 Conclusão.....	61

6. Avaliação do Sistema DDF Proposto	62
6.1 Estudo de Caso.....	62
6.1.1 Experimentos e Diagnósticos	63
6.2 Avaliação de Desempenho.....	68
6.3 Conclusão.....	70
7. Considerações Finais	71
7.1 Trabalhos Futuros	72
Referências Bibliográficas.....	73
Apêndice A – Publicações	77
Apêndice B – Conjuntos dataset *arff. Base -1 e Base -2.....	78
Apêndice C – Códigos: Banco de dados, sensores e comunicações PHP	79

1. Introdução

Os equipamentos de uso doméstico, entre eles os aparelhos de ar-condicionado convencionais, ar-condicionado *split* e geladeira, praticamente são desprovidos do monitoramento em tempo real quando o assunto é falha de funcionamento.

Através do monitoramento em tempo real e a utilização da internet é possível detectar e diagnosticar as falhas mais comuns que comprometem os níveis de desempenho, confiabilidade e segurança na utilização dos equipamentos de usos domésticos. Os defeitos apresentados por estes equipamentos são geralmente solucionados por técnicos especialistas em manutenção corretiva. Para isso, o técnico utiliza conhecimento adquirido durante sua formação e experiência proveniente do exercício da profissão. Inserido neste contexto, este trabalho apresenta um protótipo desenvolvido com o uso de hardware e software com aplicações das técnicas do Aprendizado de Máquinas (AM), para detectar e diagnosticar remotamente falhas mais comuns nos equipamentos de usos domésticos convencionais.

Com a utilização de sensores específicos instalados em um equipamento doméstico, será possível coletar dados em regime de funcionamento e compará-los com os dados que os fabricantes recomendam como aceitáveis para o bom desempenho, dados estes, já contidos em um banco de dados do Detector de Diagnóstico de Falha (DDF).

O trabalho desenvolvido nesta dissertação utilizou as técnicas de AM para monitorar as principais grandezas elétricas e físicas durante o funcionamento do equipamento. Os sensores conectados em pontos específicos irão executar as leituras em tempo real, construindo o conjunto de dados *on-line*, estes dados são comparados com dados das especificações técnicas, denominados no projeto como conjunto de dados *off-line*, a comparação desses dados forma a base para o classificador das falhas. O monitoramento do funcionamento do equipamento com ênfase nas leituras das grandezas elétricas e físicas possibilita a identificação de dados relevantes para a identificação dos desvios ou resíduos para análises das falhas.

O tratamento para os dados residuais será realizado por um algoritmo de Aprendizado de Máquina, capaz de aprender a induzir uma função ou hipótese com o objetivo de interpretar falha a partir de dados residuais que representam instâncias do problema a ser tratado no equipamento submetido ao DDF.

A utilização da tarefa de classificação supervisionada na técnica de AM será fundamental para a identificação de falha na etapa do desenvolvimento do DDF com o qual é possível comparar dados e validar resultados.

O resultado final da pesquisa irá apresentar a técnica da coleta de dados *on-line* e a utilização do DDF em tempo real, acessível remotamente via internet e que, principalmente, possibilite mais segurança e usabilidade.

1.1 Motivação

Uma das principais aplicações onde a detecção e diagnósticos de falhas têm sido empregadas está relacionada aos equipamentos que demandam controle em sistemas de navegação em aviões, motores elétricos, geradores elétricos, turbinas de geração elétrica, entre outros equipamentos industriais.

Para estudar a relação entre as variáveis para obtenção de resultados que identificam sintomas de falhas, existem inúmeras estratégias com o mesmo objetivo, revelar dados que possam expressar possíveis sintomas de falhas.

A rede mundial de computadores *web* é um dos principais meios de comunicação entre os indivíduos nos últimos anos, a inclusão dos dispositivos móveis no dia a dia possibilita o surgimento da ação da assistência na experiência usuário-ambiente, no qual um agente autônomo se torna a interface com o usuário principal.

Detectar falhas em eletrodomésticos mais antigos que agem discretamente em suas funcionalidades isentos de comunicação é um grande desafio (Cook, 2003). Inserir recurso tecnológico que seja capaz de identificar e atuar em casos de defeito em tempo real via internet, adiciona vida útil e segurança na utilização dos eletrodomésticos.



Figura 1 - Eletrodomésticos convencionais

Fonte: Eletrodomésticos: Zoom (2017)

1.2 Definição do Problema

Para os equipamentos tidos como antigos ou convencionais, detectar e diagnosticar falha faz com que de fato a função do monitoramento seja executada pelo próprio usuário, visto que a maioria dos defeitos não é tão fácil identificar, ou seja, no momento que é necessário a utilização do equipamento e este não funciona em condições satisfatórias, o usuário conduz o equipamento até a assistência técnica ou aciona um técnico especialista para resolver o problema no local onde está instalado o equipamento com falha.

Desta forma, projetos em soluções para detecção e diagnóstico de falha remotamente com o uso de sistemas embarcados para eletrodomésticos são cada vez mais pesquisados. Na maioria dos casos, apesar de perceptível, a falha não implica na interrupção do funcionamento, nestes casos o equipamento continua em operação com baixo desempenho até o momento em que o usuário solicite o reparo, isso quando o problema é identificado. Geralmente, esses problemas poderiam ser evitados através das manutenções periódicas, porém estas intervenções impactam em custos não desejados.

A pesquisa deste trabalho utilizará o Aprendizado de Máquinas (AM) para solucionar problemas com diagnósticos de falhas que estão associadas às características técnicas específicas dos equipamentos, reduzindo assim a necessidade e dependência de especialistas. Um estudo de caso será apresentado para comprovar a eficiência do DDF para equipamentos de usos domésticos.

1.3 Objetivos

Para que o objetivo deste trabalho seja alcançado, serão abordados os principais conceitos e definições em DDF, bem como o conhecimento das técnicas em Aprendizado de Máquina com os recursos dos algoritmos no tratamento de variáveis críticas que compõem os conjuntos de dados de treinamentos e testes.

1.3.1 Geral

O objetivo deste trabalho é desenvolver um método automático em monitorar em tempo real as funcionalidades de equipamentos domésticos convencionais através da detecção e diagnóstico de falha.

1.3.2 Específicos

- Identificar as principais falhas nos equipamentos de uso doméstico mais usuais e suas características técnicas e funcionais.
- Desenvolver um classificador para prover diagnósticos de falhas.
- Extrair sinais elétricos e físicos utilizando sensores eletrônicos não invasivos para o conjunto de dados *on-line*.
- Avaliar o desempenho do algoritmo proposto através de um estudo de caso.

2. Fundamentos e Trabalhos Relacionados

Neste capítulo serão apresentadas a fundamentação teórica e as tecnologias que contribuíram ou foram utilizadas nesta dissertação.

Os conceitos em detecção e diagnóstico de falha, o comportamento das grandezas elétricas e físicas em regimes de operação, modelos de classificação de falha, abordagem em mineração de dados em facilitar o entendimento da origem dos dados, pré-processamento de dados e pós-processamento de dados.

Através dos trabalhos relacionados é possível compreender melhor o problema que envolve a detecção e diagnóstico de falha de forma automática em equipamentos domésticos convencionais.

2.1 Fundamentos Teóricos

Para o melhor entendimento da solução proposta nesta dissertação são apresentados os conceitos que envolvem a detecção e diagnóstico de falha, modelos de classificação, mineração de dados, origem de dados, pré-processamento e pós-processamento de dados.

2.1.1 Conceitos de Detecção e Diagnóstico de Falha

A crescente demanda por desempenho e qualidade associada ao ganho por maior eficiência econômica e ambiental têm tornado o uso do DDF cada vez mais importante para os equipamentos sejam indústrias ou em uso doméstico (Cook *et al*, 2003), sistema DDF em equipamentos de usos domésticos é pouco pesquisado, enquanto em diversas áreas da engenharia de equipamentos, como a de produção e controle de processos automotivos, a literatura é abrangente. Ao mesmo tempo, o desenvolvimento de sensores e hardware mais sofisticados aliados à redução dos custos, viabilizam a utilização do DDF para sistemas de equipamentos domésticos.

A importância em classificar as etapas ou fases do estado da falha são as situações que descrevem a causa que podem culminar em um evento que conduz a um estado de falha, e este conjunto de situações pode ser detectado e diagnosticado por meios de sintomas, neste sentido a falha pode ser interpretada como o elemento central. A característica da redução ou perda da capacidade em desempenhar uma função requerida sob condições especificadas

proporcionam indícios que o equipamento caminha para uma condição de falha ou para um evento de mau funcionamento. Assim, o defeito é geralmente resultado de uma condição de falha.

Como resultado desta condição, surge a fase do sintoma, onde as falhas se revelam, ou seja, os sintomas são as observações ou sinais que são relacionados ou associados às falhas e que podem ser utilizados na sua detecção e no seu diagnóstico. Para Lafraia (2014), os sintomas também possuem forte relação com o erro ou desvio entre um valor medido ou uma condição observada, que poderá corresponder ao valor verdadeiro, especificado ou teoricamente correto. Conceitos defendidos em Isermann (2006) definem como perturbação uma entrada atuando sobre um sistema, resultando em um desvio temporário em relação ao estado em curso denominado de distúrbio, uma entrada desconhecida não controlada atuando sobre um sistema.

Estes dois conceitos podem ser resumidos em um único, de uma forma mais contundente ao que é amplamente utilizado na área de controle de processos, a perturbação ou distúrbio em uma variável atuando sobre um sistema resulta em um desvio em relação ao estado em curso.

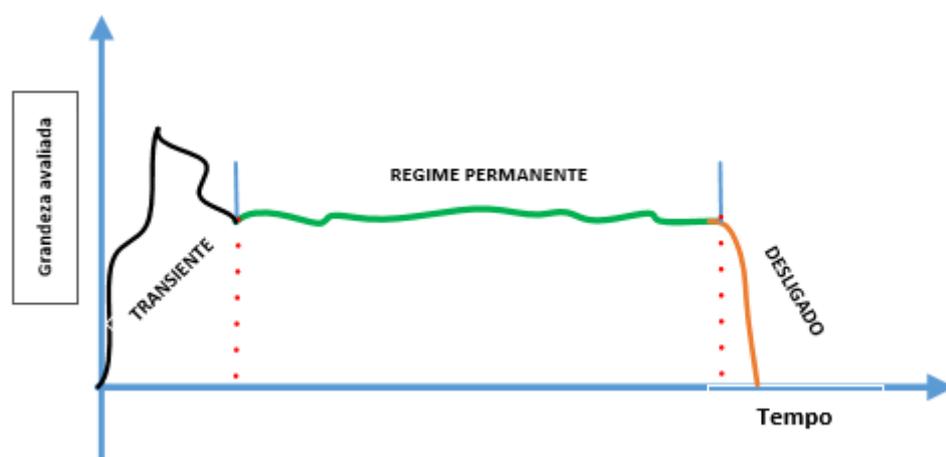


Figura 2 - Grandeza monitorada em regime de operação

Fonte: adaptado de Lafraia (2014)

Para ocorrência de anormalidade em um sistema, as fases em que as falhas podem ocorrer dependem da cadeia de eventos em função de algumas situações, o regime permanente na operação de um equipamento fornece dados com características do comportamento das variáveis, existindo certa relação de causa e efeito entre elas. A detecção

de falhas é a determinação da presença de uma falha no sistema e do tempo de detecção Venkatasubramanian (2003). No regime permanente de operação após certo tempo, algo está errado com o sistema, o sintoma de falha inicia um comportamento indesejável ou inaceitável. A detecção de falha é realizada por meios de registros de informações, do reconhecimento e da indicação de anormalidades no comportamento do equipamento em um tempo determinado. Essa operação pode ser feita por meio de diversas formas, desde o simples acompanhamento de alguma variável do equipamento até as análises das diferenças chamada de resíduo entre o valor medido de uma variável e o seu respectivo valor estimado por um modelo projetado.

O diagnóstico de falha é a determinação das características das falhas detectadas, essas características variam de acordo com o objetivo de cada sistema, sendo que a localização e a causa são as mais pesquisadas em artigos científicos. Os diagnósticos de falhas podem ser divididos nas etapas de isolamento e análises das falhas. Na etapa de isolamento ou classificação, o objetivo é determinar a falha existente, por meio da determinação do tipo, da localização e do tempo de sua ocorrência. Existem divergências entre alguns autores que consideram que a definição do tipo de falha faz parte da etapa seguinte (Frank *et al*, 2014).

A tarefa de análise ou identificação de falha é definida como todo detalhamento posterior da falha, definição do tamanho, da causa, do comportamento com o tempo, dentre outros, assim abordam Gertler (2013); Isermann (2006); e Frank *et al* (2014).

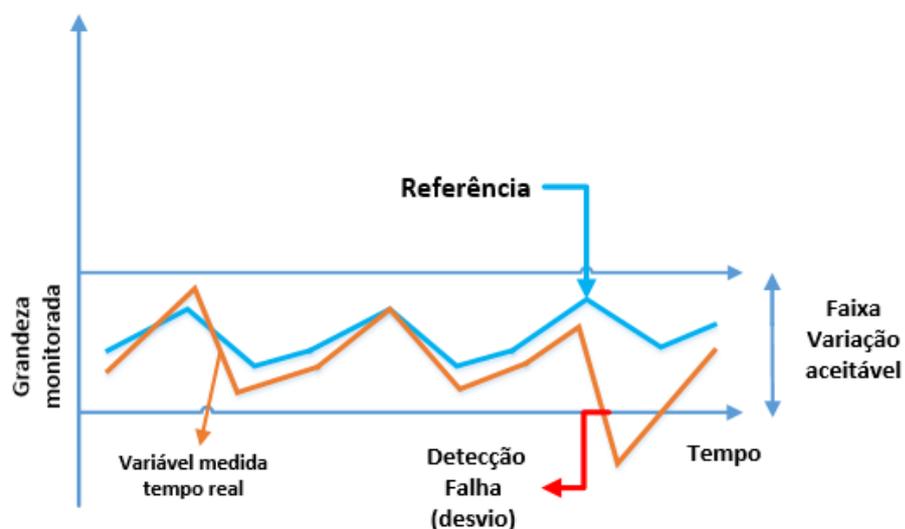


Figura 3 - Detecção de falha na grandeza monitorada em regime permanente

Fonte: Fonte: adaptado de Lafraia (2014)

As variáveis mais relevantes são observadas nas tarefas que requerem atenção especial de subsistemas no diagnóstico de falha (Chiang *et al*, 2004), esta tarefa é fundamental no diagnóstico de falha e utiliza o termo identificação de falha para se referirem ao procedimento de determinação das variáveis observadas mais relevantes. Este procedimento não é a única maneira utilizada para facilitar o diagnóstico de falha, existem outras formas para o tratamento das análises das variáveis, não é necessário focar exclusivamente como uma etapa separada. Portanto, o diagnóstico de falha pode ser definido como a junção das etapas de isolamento.

As falhas propriamente ditas são isoladas e analisadas, os diagnósticos fornecem, então, assistência para a tomada de ações de correções. Um sistema DDF deverá possuir recursos que, ao identificar falhas, possam minimizar os danos ou perdas nos equipamentos. Isso é possível por meio da supervisão contínua e em tempo real, a principal análise consiste em observar em primeiro momento o sistema físico para detectar condições anormais de funcionamento, quando uma condição anormal é detectada, um diagnóstico de falha é utilizado para determinar a causa. Ao avaliar a importância da anormalidade, medidas corretivas são aplicadas ou até mesmo nenhuma ação é feita.

A detecção de falha depende da leitura feita por sensores, estes leem dados correspondentes às características do funcionamento do sistema real, os dados, depois de tratados, são comparados aos valores esperados em um sistema ideal, e as diferenças dos valores encontrados são chamados de resíduos.

A Figura 4 ilustra o diagrama básico para o detector de falha, os resíduos gerados têm certo limite, ou seja, se o valor real obtido ultrapassar uma margem permitida, um sinal ou alarme pode ser utilizado para alertar ao usuário que o equipamento está fora de suas condições aceitáveis de funcionamento. O limite dado ao valor do resíduo determina a sensibilidade do DDF, este limite deve ser estabelecido cuidadosamente devido à possibilidade de alarme falso.

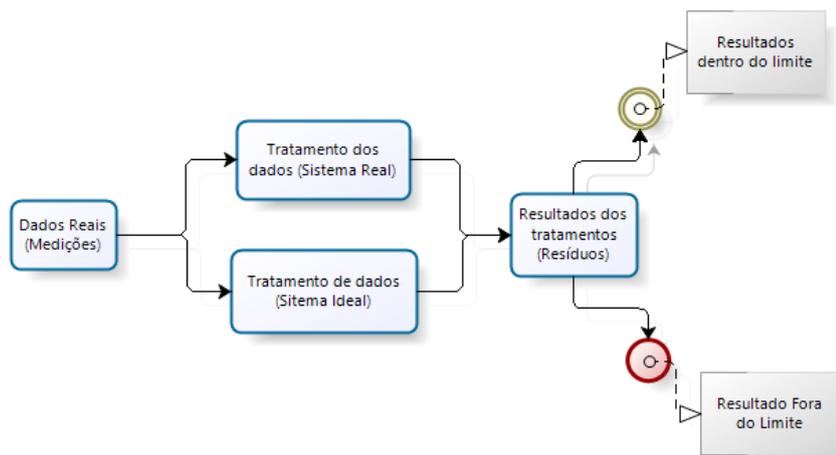


Figura 4 - Diagrama do funcionamento do detector de falhas

Fonte: Adaptado de Gertler (2013)

O modelo DDF busca determinar o tipo, o tamanho, a localização e o tempo de detecção de falha de acordo com os sintomas observados. Por vezes o diagnóstico pode não localizar imediatamente a principal causa da falha, mas pode envolver uma série de etapas que eventualmente podem convergir para a causa em algum ponto posterior no diagnóstico.

Pode-se chegar à condição ideal de operação, por exemplo, a partir do modelamento que utilize balanços das grandezas elétricas e físicas, ou seja, relações entre as variáveis envolvidas. Técnicas de simulação computacional podem ser utilizadas para investigar o desempenho do modelo dentro de limites pré-definidos.

Os sistemas de supervisão em tempo real existentes para residências, em sua maioria, avalia o consumo de energia elétrica por equipamento ou através do conjunto de cargas instaladas. Os equipamentos de uso doméstico convencionais não possuem nenhum sistema de supervisão que seja utilizado por empresas de manutenção com o objetivo de monitorar os equipamentos em condições preestabelecidas de acordo com as fichas técnicas dos fabricantes.

2.1.2 Modelos de Classificação de Falha

Nesta seção são abordados alguns modelos para classificação de falhas em sistemas DDF, os modelos paramétrico, o físico, o empírico e o semiempírico (Ramachandran, 2008) descritos a seguir:

Modelo Paramétrico: Os modelos paramétricos baseiam-se na estimativa de parâmetros a partir de informações. Um modelo paramétrico fornece uma descrição entre as entradas e saídas do sistema, mas os parâmetros não têm significado físico.

Modelo Físico: Um modelo físico é um conjunto de ideias e conceitos dos quais a interpretação provém de observações e resultados experimentais. Em sua forma mais completa, um modelo físico é construído a partir de um conjunto de leis naturais. É possível criar uma representação matemática através dos resultados experimentais. Os modelos físicos são baseados nos princípios físicos que envolvem o sistema real a ser investigado. Geometria, propriedade dos materiais e dos fluídos geralmente também são incluídas.

Modelo Empírico ou Modelo Caixa Preta: Modelos empíricos são basicamente modelos paramétricos em que os dados utilizados provêm de experimentos. A aquisição feita de um sistema real fornece uma tendência que é contabilizada e utilizada como referência. São boas opções para descrição de comportamentos não lineares, enquanto sua desvantagem é a grande quantidade de dados necessários muito superior comparada ao modelo físico.

Modelo Semi-Empírico ou Modelo Caixa Cinza: Estes são modelos que mesclam leis e princípios físicos com dados experimentais para montar a base de dados para o DDF. Por fazer uma conexão entre os modelos físico e o caixa preta, são denominados de modelos caixa cinza.

Os modelos para diagnósticos de falhas podem ser classificados com base no conhecimento a priori ou no histórico do processo, sendo em ambos os casos divididos em métodos quantitativo e qualitativo. Diversas técnicas de detecção e diagnóstico de falhas são amplamente debatidas no âmbito científico, destacando-se as técnicas de base estatísticas e o uso crescente da inteligência artificial (Ozyurt e Kendel , 2010).

A Tabela 1 ilustra as falhas mais frequentes em equipamentos convencionais.

Equipamentos	Sintomas:	Possíveis causas	Diagnósticos
Ar-condicionado	Compressor trava	Alta pressão condensador	Má troca de calor no condensador Compressor
	Compressor não liga	Tensão elétrica baixa	Rede elétrica anormal, baixa voltagem
	Ambiente não esfria	Portas / janelas abertas, excesso de carga térmica	Ambiente anormal
	Vibração ou barulho excessivo	Motor do ventilador com defeito	Trocar o motor, verificar hélices do ventilador
Máquina de lavar roupa	Não entra água no tanque	Falta de água na rede hidráulica	Ausência de água na entrada
	Máquina não liga	Falta de energia/ Plug desligado	Rede elétrica anormal
	Vibração excessiva	Máquina desnivelada	Ajuste de nível anormal
Ar-condicionado SPLIT	Não liga pelo controle, nem pelo botão da unidade interna	Falta de energia/ Plug desligado	Rede elétrica anormal
	O compressor e o ventilador da unidade externa não funcionam	Tensão da rede abaixo do normal (127V ou 220V)	Rede elétrica anormal
	Desempenho não é satisfatório	Unidade condensadora exposta diretamente ao sol	Alta pressão da unidade condensadora

Tabela 1 - Aparelhos convencionais: sintomas, causas e diagnósticos

Fonte: ASHRAE -Handbook CD (2015)

2.1.3 Mineração de Dados

A ferramenta mineração de dados é a etapa mais importante do processo na extração do conhecimento implícito no auxílio à tomada de decisão em problemas em que as variáveis envolvidas são utilizadas na forma original como aparecem nas bases de dados em Ganyun *et al* (2005).

Historicamente, mineração de dados pode ser considerada como parte de Descoberta de Conhecimento em Banco de dados (KDD – Knowledge Discovery in Databases).

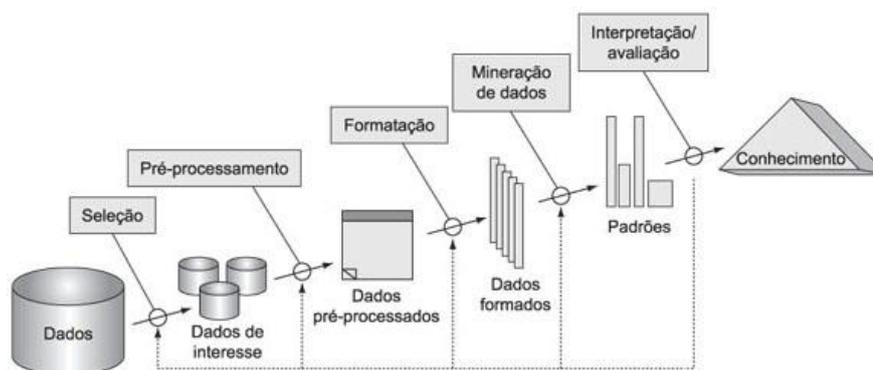


Figura 5 - Etapas de processo de descoberta de conhecimento em bases de dados

Fonte: Fayyad.*et al* (1996)

Segundo Ganyun *et al* (2005), o termo KDD é bastante utilizado para representar o processo de tornar dados de baixo nível em conhecimento de alto nível, enquanto mineração de dados pode ser definida como a extração de padrões ou modelos de dados observados.

A mineração de dados combina métodos e ferramentas das seguintes áreas: aprendizagem de máquina, banco de dados, sistemas especialistas e visualização de dados. Inúmeros são os conceitos publicados por autores atribuídos a mineração de dados, a principal contribuição observada nas pesquisas convergem para as questões em que consiste em relacionar dados que forneçam subsídios para que possam serem feitas previsões de tendências futuras baseada no passado.

A mineração de dados é a exploração e a análise, por meio automático ou semiautomático, de grandes quantidades de dados, a fim de descobrir padrões e regras significativos (Berry e Linoff, 1997).

O resultado obtido com a mineração de dados pode ser usado no gerenciamento de informação, processamento de pedidos de informação, tomada de decisão, controle de processo e muitas outras aplicações.

A mineração de dados pode ser aplicada de duas formas: como um processo de verificação e como um processo de descoberta (Goldschmidt *et al*, 2012). No processo de verificação, o usuário sugere uma hipótese acerca da relação entre os dados e tenta prová-la aplicando técnicas como análises estatísticas e multidimensional sobre um banco de dados contendo informações passadas. Já no processo de descoberta não é feita nenhuma suposição antecipada. Esse processo usa técnicas, tais como descoberta de regras de associação, árvore de decisão, algoritmos genéticos, redes neurais e redes bayesiana.

- **A Origem dos Dados**

A importância em conhecer a origem dos dados quanto à disponibilidade, à relevância dos dados e a existência de um especialista no domínio da aplicação para a construção dos conjuntos de dados ou data set são fundamentais na etapa inicial.

Segundo Han (2012), as técnicas de mineração de dados podem ser aplicadas sobre banco de dados operacionais nos quais geralmente resultam em melhor qualidade na informação, pois os dados normalmente são preparados antes de serem armazenados.

A importância das etapas da seleção dos dados para um tipo de investigação requer bastante avaliação e forte demanda de tempo para que o resultado apresente organização, gerenciamento e integração de banco de dados. Para que as etapas posteriores não sejam comprometidas, a seleção e limpeza dos dados exercem bastante importância na formação dos conjuntos de dados na representação no comportamento das variáveis que se deseja investigar.

- **Pré-processamento de Dados**

As técnicas de pré-processamento de dados são frequentemente utilizadas para melhorar a qualidade dos dados. Essa melhora pode facilitar o uso de técnicas de aprendizado de máquina. Com a melhora na qualidade dos dados, podemos construir modelos mais fiéis à distribuição real dos dados, reduzindo sua complexidade computacional, tornar mais fáceis e rápidos os ajustes de parâmetros do modelo e seu posterior uso.

A etapa do pré-processamento de dados é útil não apenas porque podem eliminar problemas existentes em um conjunto de dados, mas também porque podem tornar os dados mais adequados para sua utilização por um determinado algoritmo de Aprendizado de Máquina.

Para a integração dos dados em Aprendizado de Máquina onde os dados estão distribuídos em diferentes conjuntos de dados, os conjuntos devem ser integrados antes do início do uso da técnica de Aprendizado de Máquina (Wang *et al*, 2008). Nesse caso, é possível que cada conjunto de dados represente diferentes atributos de um mesmo grupo de objetos. Assim, na integração é necessário identificar quais são os objetos que estão presentes nos diferentes conjuntos a serem combinados. Essa identificação é realizada por meio da busca por atributos comuns nos conjuntos a serem combinados. Como exemplo, um conjunto de dados médicos que podem ter um atributo que identifica o paciente. Assim, os objetos dos

diferentes conjuntos que possuem o mesmo valor para o atributo que identifica o paciente são combinados em um único objeto do conjunto integrado.

Através das evidências extraídas dos valores dos atributos, alguns aspectos dificultam a integração. Por exemplo, atributos correspondentes podem ter nomes diferentes em diferentes bases de dados. Além disso, os dados a serem integrados podem ter sido atualizados em momentos diferentes, para tentar eliminar estes problemas é comum o uso de metadados em base de dados. Os metadados são dados que, ao descrever as principais características dos dados, podem ser utilizados para evitar erros no processo de integração (Tan *et al*, 2013).

Então, com ou sem integração é cada vez mais frequente o uso das técnicas de Aprendizado de Máquina em grandes conjuntos de dados, que em alguns casos crescem com o tempo. Embora um conjunto de dados seja considerado grande, se tem um número elevado de objetos, conjuntos que não possuem muitos objetos, visto que cada objeto possui um grande número de atributos, também podem ser considerados grandes.

Em Cheng *et al* (2013), a existência de um conjunto de dados grande, tanto em termos de números de objetos como de atributos, não implica que o algoritmo de Aprendizado de Máquina deva utilizar todo ele. Muitas vezes é mais eficiente usar parte do conjunto original. Quanto aos números de atributos, um número elevado pode comprometer o desempenho do algoritmo de Aprendizado de Máquina por causa de um problema conhecido como maldição da dimensionalidade (Castillo, 2010).

- **Pós-processamento de Dados**

O pós-processamento tem como principal objetivo apoiar na verificação dos resultados obtidos para os padrões e que efetivamente contribuem na solução de um problema.

A etapa de pós-processamento corresponde ao processo de tratamento do conhecimento propriamente adquirido por meio da mineração de dados, proporcionando facilidade na interpretação e avaliação do conhecimento descoberto. A simplificação de gráficos, diagramas e outros tipos de relatórios demonstrativos nesta etapa, oferece ao usuário maior poder de decisão na interpretação do conhecimento extraído (Goldschmidt *et al*, 2005).

Após a etapa de pós-processamento, todo o conhecimento é extraído depois de avaliado e também validado e consolidado na fase de utilização do conhecimento, sendo

incorporado a um sistema inteligente, que é utilizado pelo usuário final para o apoio a algum processo de tomada de decisão.

Na prática, o usuário deseja visualizar e interpretar de maneira fácil e rápida os resultados do processo de mineração de dados.

2.2 Trabalhos Relacionados

Os trabalhos apresentados nesta seção foram selecionados por tratarem da utilização de tecnologias aplicadas com o tema desta dissertação utilizando diferentes técnicas em Aprendizado de Máquina.

Em Basílio *et al* (2010), utilizaram as metodologias desenvolvidas para o diagnóstico de falhas, que podem ser aplicadas não apenas para sistemas onde o modelo de eventos discretos é o mais adequado como redes de comunicação, sistemas computacionais e sistemas de produção, mas também em muitos sistemas dinâmicos de variáveis contínuas, considerando um nível maior de abstração.

No trabalho de Cheng *et al* (2013), a tarefa do diagnóstico requer procedimentos mais relevantes para determinação das variáveis em função da etapa em que ocorrem as anormalidades. Segundo estes autores, o objetivo deste procedimento é focalizar a atenção dos operadores e engenheiros nos subsistemas mais pertinentes para a determinação das falhas.

O trabalho de Venkatasubramanian *et al* (2003) destaca os métodos para diagnósticos de falhas com base no conhecimento a priori utilizado. Assim, a abordagem utilizada pode envolver métodos baseados em modelos ou no histórico do processo, sendo em ambos os casos divididos em métodos quantitativo e qualitativo.

Segundo Ganyun *et al* (2005), a busca do conhecimento através das bases de dados é bastante utilizada para representar o processo em tornar dados de baixo nível em conhecimento de alto nível, enquanto mineração de dados pode ser definida como a extração de padrões ou modelos de dados observados. Esta análise permeia as alternativas em desenvolver sistemas em diagnóstico de falha bem mais atrativas utilizando estas ferramentas.

Em Han (2012), as técnicas de mineração de dados podem ser aplicadas em banco de dados operacionais, nos quais geralmente resulta uma informação melhor, pois os dados normalmente são preparados antes de serem armazenados. Podem ser aplicadas, também,

sobre data set, definido como um banco de dados específico para um tipo de investigação a ser realizada.

Em Brameier (2001), descreve a comparação entre a programação genética linear e a técnica utilizando redes neurais, utilizando o algoritmo de retropropagação resiliente para aprendizado, em mineração de dados médicos. O desempenho dos dois métodos foi compatível, observando a propagação genética linear considerada satisfatória na classificação e generalização de dados.

A proposta de Lemos (2003) aborda uma análise em diagnosticar falha em cadastro de crédito bancário com o uso de mineração de dados, com a utilização das técnicas de redes neurais e árvore de decisão. Em árvores de decisão foi aplicado o algoritmo J48. O objetivo do trabalho era auxiliar na tomada de decisão sobre conceder ou não crédito para clientes de micro e pequenas empresas, os resultados foram considerados satisfatórios.

No trabalho de Braun (2009) foram utilizadas as regras de diagnósticos para avaliação de itens considerados chaves em sistemas de ar-condicionado, vazamento de gás refrigerante, vazamento na válvula do compressor, restrição na linha do líquido do gás refrigerante, sujeira no condensador. Para diagnósticos de temperaturas, as análises das temperaturas de evaporação, grau de superaquecimento, condensação, sub-resfriamento, variação da temperatura do ar através do evaporador. Para o autor, com a combinação das diversas medidas ao longo do sistema real foi possível chegar a um diagnóstico previsto.

Para Grimmeliuss (2015), o diagnóstico utilizando a técnica de reconhecimento de padrão aplicada aos resíduos reais e uma matriz de resíduos esperados associando as diferenças encontradas às falhas, também, resultam em uma boa técnica para análises de falhas correspondentes às diferenças entre os valores desejados.

Em Afegan (2014), o diagnóstico de falha foi obtido através do Aprendizado de Máquinas com a metodologia da árvore de decisão. O sistema seguiu uma abordagem em pergunta-resposta que associa perguntas apropriadas às respostas correspondentes no caminho mais curto entre um sintoma inicial e um diagnóstico final.

A técnica avaliada no trabalho de Kitts (2006) consiste em simular o comportamento de um sistema sobre o desempenho de cada componente em tempo real em detectar falhas, o principal desafio dessa técnica é a explosão combinatória para aplicação de vários componentes na tentativa de criar um modelo capaz de atender um número considerável de dispositivos em detectar falhas em um sistema.

Outra técnica que se baseia na descrição do comportamento do sistema é visto no trabalho de Sama *et al* (2008), que lida com objetos ao contexto através de um conjunto de

regras. A técnica consiste em transformar o conjunto de regras em um modelo formal de estado finito. Algoritmos são então propostos para analisar o estado finito. Para detectar defeitos de adaptação. A abordagem compara o estado do conjunto já estabelecido de padrões de falhas de adaptação, a proposta mostra-se bastante interessante se aplicada dinamicamente nas falhas comparando o mundo real em tempo de execução.

O trabalho de Shell (2010) abordou a técnica para resolver o problema de diagnóstico usando redes de sensores. A técnica consiste em detectar falhas dentro de uma rede de sensores através da aplicação de uma abordagem de fusão de dados de lógica Fuzzy usando um controle estatístico de processos e uma covariância em cluster. O modelo busca solução em tempo de execução para tirar conclusões dinâmicas sobre o bom funcionamento do sistema em tempo real.

Em Luger (2014), o trabalho aborda a técnica de inteligência artificial, a técnica utiliza as informações de entrada em tempo real oriundos de diversos sensores conectados ao sistema com o objetivo em detectar possíveis anomalias no comportamento normal esperado. A detecção de anomalias permite um diagnóstico prévio e possibilita o planejamento de ações junto ao sistema, o resultado destas ações auxiliam no planejamento das tarefas de manutenções preditivas.

2.3 Conclusão

Neste capítulo foram apresentados os fundamentos teóricos na detecção e diagnóstico de falha, os modelos de classificação de falha mais utilizados em sistemas de DDF, a ferramenta mineração de dados nas etapas da origem de dados, pré-processamento e pós-processamento de dados.

Foi verificado nas pesquisas em publicações de artigos, livros e dissertações, trabalhos relacionados que contribuíram na solução do problema desta dissertação. Nos trabalhos relacionados é notório a busca por ferramentas que possam gerar análises inteligente e automática de padrões para extração de conhecimento. É sem dúvida o grande desafio da comunidade científica apresentar soluções de aprendizagem automática em tempo real.

No próximo capítulo será descrito os conceitos em aprendizagem de máquina, os softwares utilizados nas etapas de aprendizado, os algoritmos e suas características.

3. Aprendizado Automático – Estado da Arte

Neste capítulo são apresentadas as técnicas mais utilizadas no aprendizado automático no âmbito desta dissertação, neste sentido, foi feito o levantamento do estado da arte para explicar as técnicas no estágio do conhecimento atual.

As principais tarefas em Aprendizado de Máquina, a hierarquia do aprendizado, a construção dos arquivos para os softwares open source, os algoritmos e exemplos de aplicação são fundamentais para a construção do sistema DDF.

As pesquisas em periódicos relacionados auxiliaram na busca em compreender melhor a solução do problema em detecção e diagnóstico de falhas em diversas áreas tecnológicas. Ao final deste capítulo é descrito a técnica e o algoritmo que será utilizado na construção do sistema de detecção e diagnóstico proposto nesta dissertação.

3.1 Aprendizado de Máquina

Técnicas em Aprendizado de Máquina (AM) é uma área de Inteligência Artificial (IA) cujo objetivo é o desenvolvimento de técnicas computacionais sobre o aprendizado bem como a construção de sistemas capazes de adquirir conhecimento de forma automática (Carvalho, 2011). Um sistema de aprendizado neste contexto é um programa de computador, que executa decisões baseado em experiências acumuladas através da solução bem-sucedida de problemas anteriores.

Um sistema de aprendizado supervisionado possui características na experiência contida em exemplos solucionados com sucesso (Coppin, 2010). Aprender implica em alterações no sistema que são adaptativas, no sentido que elas capacitam o sistema a realizar a mesma tarefa, ou tarefas provenientes da mesma população, de forma mais eficiente e eficaz na próxima vez (Simon, 1983).

Em Mark *et al* (2014), apresenta uma hierarquia de aprendizado de acordo com a Figura 6 com os tipos de tarefas de aprendizado. No topo aparece o aprendizado indutivo, processo pelo qual são realizadas as generalizações a partir dos dados. Tem-se em seguida os tipos de aprendizado supervisionado preditivo e o tipo não supervisionado descritivo. As tarefas supervisionadas se distinguem pelo tipo dos rótulos dos dados, o discreto, no caso de classificação e contínuo, no caso de regressão. As tarefas descritivas são genericamente divididas em agrupamentos em que os dados são agrupados de acordo com sua similaridade;

sumarização, cujo objetivo é encontrar uma descrição simples e compacta para um conjunto de dados; e associação, que consiste em encontrar padrões frequentes de associações entre os atributos de um conjunto de dados.

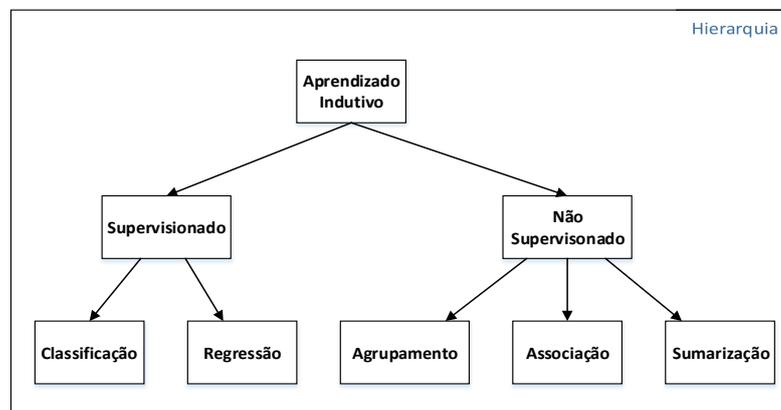


Figura 6 - Hierarquia de aprendizado

Fonte: Mark H, Eibe F (2014)

O aprendizado indutivo gera uma hipótese ou classificador, o objetivo de um indutor consiste em extrair um bom classificador a partir de um conjunto de exemplos rotulados. A saída do indutor, o classificador, pode então ser usada para classificar exemplos novos que ainda não foram rotulados com a meta de prever corretamente o rótulo de cada exemplo, após esta etapa, o classificador pode ser avaliado considerando sua precisão, compreensibilidade ou grau de interesse, velocidade de aprendizado, requisitos de armazenamento, grau de compactação ou qualquer outra propriedade desejável que determine quão bom e apropriado o classificador é para a tarefa em questão.

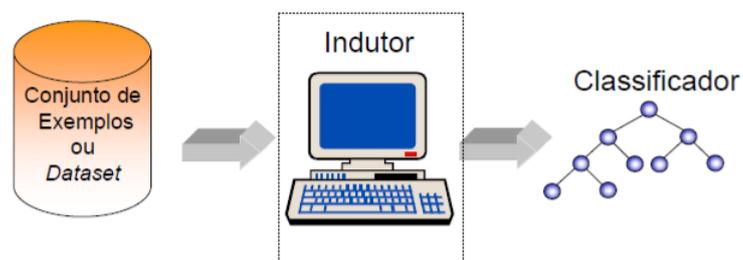


Figura 7 - Aprendizado Indutivo

Fonte: Mark H, Eibe F (2014)

3.1.1 Software para Aprendizado de Máquina

Segundo Melo (2010), o software livre Waikato Environment for Knowledge Analysis (*Weka*), formado por um conjunto de implementações de algoritmos de diversas técnicas de mineração de dados e que está implementado na linguagem Java, tem como principal característica sua portabilidade, desta forma é possível utilizá-lo em diferentes sistemas operacionais, além de aproveitar os principais benefícios da orientação a objetos.

O software Weka oferece recursos para a execução de tarefas relacionadas ao pré-processamento de dados como, por exemplo, a seleção e a transformação de atributos. As facilidades em utilizar os recursos neste software através dos tutoriais e apostilas sobre a ferramenta disponibilizados na internet mostram como minerar bases de dados estruturadas nos formatos ARFF ou CSV.

Arquivo ARFF (Attribute-Relation File Format) é o formato utilizado pelo software Weka. Este arquivo precisa conter informações a respeito de domínio dos atributos, valores que os atributos podem representar e o atributo classe. O arquivo é dividido, primeiramente, por uma lista de todos os atributos de seu estudo, em que se deve escolher o tipo do atributo e/ou valores desejados.

Os valores escolhidos precisam estar entre chaves e separados por vírgulas. A segunda parte é formada por instâncias que estão presentes nos dados escolhidos. Os atributos precisam estar separados por vírgula. No exemplo da Figura 8 têm-se as informações da base de dados em questão e a sua formatação no arquivo *ARFF*.

```

@relation breast-cancer % Nome do arquivo

% Atributos
@attribute age {'10-19','20-29','30-39','40-49','50-59','60-69','70-79','80-89','90-99'}
@attribute menopause {'lt40','ge40','premeno'}
@attribute tumor-size {'0-4','5-9','10-14','15-19','20-24','25-29','30-34','35-39','40-44','45-49','50-54','55-59'}
@attribute inv-nodes {'0-2','3-5','6-8','9-11','12-14','15-17','18-20','21-23','24-26','27-29','30-32','33-35','36-39'}
@attribute node-caps {'yes','no'}
@attribute deg-malig {'1','2','3'}
@attribute breast {'left','right'}
@attribute breast-quad {'left_up','left_low','right_up','right_low','central'}
@attribute 'irradiat' {'yes','no'}
@attribute 'Class' {'no-recurrence-events','recurrence-events'}

@data % Início dos registros
'40-49','premeno','15-19','0-2','yes','3','right','left_up','no','recurrence-events'
'50-59','ge40','15-19','0-2','no','1','right','central','no','no-recurrence-events'
'50-59','ge40','35-39','0-2','no','2','left','left_low','no','recurrence-events'
'40-49','premeno','35-39','0-2','yes','3','right','left_low','yes','no-recurrence-events'

```

Figura 8 - Formato do arquivo arff para software Weka

Fonte: Goldschmidt (2005)

Com dados dos registros históricos classificados por um especialista é possível relacionar os eventos e interpretar como o resultado é esperado ou previsto para uma solução de um determinado problema.

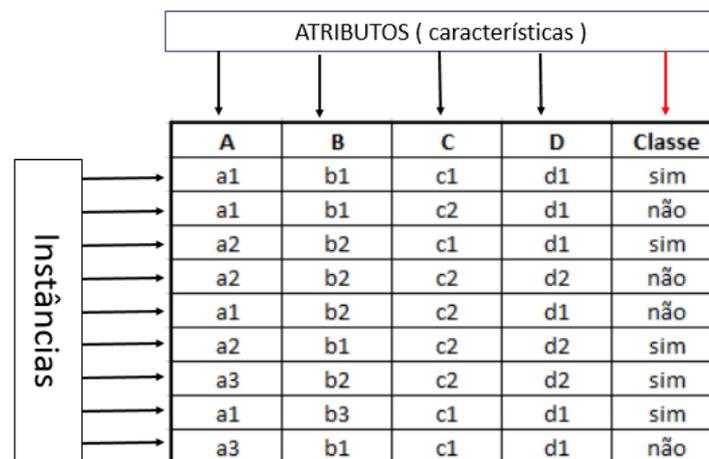


Figura 9 - Exemplo de conjunto de dados Instâncias, Atributos, Classe

Fonte: Katti Faceli (2011)

3.1.2 Algoritmos de Aprendizado de Máquina

As árvores de decisão são modelos bastante utilizados para inferência indutiva. Estas árvores são treinadas de acordo com um conjunto de treino e, posteriormente, outros exemplos são classificados de acordo com essa mesma árvore. A Figura 10 ilustra o método através de um exemplo. Um classificador ou modelo de classificação é utilizado para identificar a classe à qual pertence uma determinada observação de uma base de dados, a partir de suas características, conforme Berry e Linoff (1997).

A mineração dos modelos de classificação em bases de dados é um processo composto por duas fases, aprendizado e teste, de acordo com Han e Kamber (2006). Na fase de aprendizado, um algoritmo classificador é aplicado sobre um conjunto de dados de treinamento. Como resultado, obtém-se a construção do classificador propriamente dito. Tipicamente, o conjunto de treinamento corresponde a um subconjunto de observações selecionadas de maneira aleatória, a partir da base de dados que se deseja analisar. Cada observação do conjunto de treinamento é caracterizada por dois tipos de atributos: o atributo classe, que indica a classe à qual a observação pertence; e os atributos preditivos, cujos valores serão analisados para que seja descoberto o modo como eles se relacionam com o atributo classe.

Para exemplificar estes conceitos, a Tabela 2 mostra um conjunto de dados de treinamento. Neste exemplo, o conjunto de dados é composto por observações selecionadas a partir de uma base hipotética de informações. Na identificação que cada observação contém os dados de uma pessoa entrevistada. O atributo “Rico”, utilizado para indicar se uma pessoa possui renda anual igual ou superior a R\$ 50.000,00, representa o atributo classe, enquanto os atributos “escolaridade” e “idade” são preditivos.

NOME	ESCOLARIDADE	IDADE	RICO (Atributo classe)
Joana	Mestrado	>30	Sim
Tereza	Doutorado	<=30	Sim
Lúcia	Mestrado	<=30	Não
João	Doutorado	>30	Sim
Rosália	Graduação	<=30	Não
Rafael	Graduação	>30	Não
Antônia	Mestrado	>30	Sim
Fernando	Mestrado	<=30	Não

Tabela 2 - Dados de treinamento.

Fonte: Adaptado de Berry e Linoff (1997).

Após o classificador ser construído, inicia-se a etapa de teste, que visa avaliar a sua acurácia através do emprego de um conjunto de dados de teste. O conjunto de teste contém observações que também são selecionadas aleatoriamente, a partir da base de dados. No entanto, estas observações devem ser diferentes das que foram selecionadas para compor o conjunto de treinamento. A acurácia do classificador representa a porcentagem de observações do conjunto de teste que são corretamente classificadas por ele. Caso a acurácia seja alta, o modelo de classificação é considerado eficiente e pode ser utilizado para classificar novos casos. Diversas técnicas podem ser utilizadas para a construção de classificadores, tais como redes neurais, métodos bayesianos e árvores de decisão, entre outros. As árvores de decisão, Figura 10, têm sido bastante utilizadas pelos softwares de mineração de dados. Isto é justificado pelo fato delas possuírem uma representação gráfica, que torna o modelo de classificação fácil de ser interpretado.

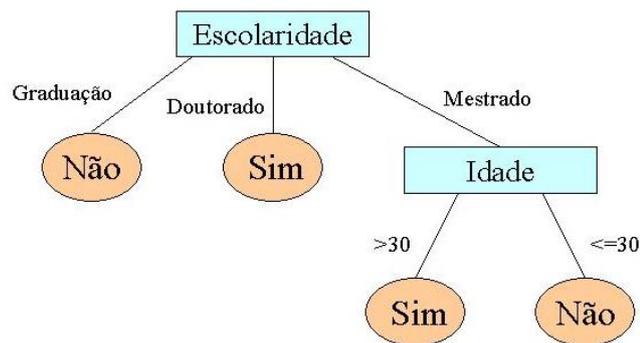


Figura 10- Árvore de decisão construída a partir da Tabela 1.

Fonte: próprio autor.

Um exemplo de aplicação do classificador árvore de decisão pode ser em identificar se um cliente será um bom pagador em função de suas características e descrição em fornecer informações interessantes a respeito das relações entre os atributos preditivos e o atributo classe numa base de dados.

Os algoritmos classificadores possuem como meta a construção de árvores que possuam o menor tamanho e a maior acurácia possível. Uma questão chave para a construção de uma árvore de decisão consiste na estratégia para a escolha dos atributos que estarão mais próximos da raiz da árvore, ou seja, os atributos que são inicialmente avaliados para determinar a classe à qual uma observação pertence. O atributo “Escolaridade”, na Figura 11, encontra-se na raiz da árvore, pois foi considerado pelo algoritmo classificador como o

atributo mais importante para determinar se uma pessoa é rica ou não, geralmente são utilizadas medidas baseadas na entropia para tratar este problema.

A entropia é importante no cálculo necessário para obtenção do ganho da informação baseado em uma medida bastante utilizada na teoria da informação. Os dados contêm impurezas que necessitam ser tratadas com o objetivo de elevar o grau de homogeneidade dos dados de entrada em relação a sua classificação.

Por exemplo, a entropia é máxima igual a 1 quando o conjunto de dados é heterogêneo, Mitchell (1997).

Para um dado conjunto de entrada (S) que pode ter classes distintas, a entropia de S será dada através da Equação 1.

$$Entropia (S) = - (P_+ \log_2 P_+ + P_- \log_2 P_- + \dots + P_n \log_2 P_n) \quad (1)$$

Onde:

S é a totalidade de amostras do conjunto

P₊ é a proporção de amostras positivas

P₋ é a proporção de amostras negativas

De forma geral a Equação 2 da entropia é dada por:

$$H = - \sum p(x) \log p(x) \text{Equação 1} \quad (2)$$

A entropia fornece a quantidade necessária de informação para identificar a classe de um determinado caso a ser analisado.

Para Mitchell (1997), o ganho de informação mede a efetividade de um atributo em classificar um conjunto de treinamento.

O ganho de informação de um atributo A visto na Equação 3:

$$GI(S, A) = E(S) - \sum \left(\frac{S_v}{S} \right) E(S_v) \quad (3)$$

O segundo termo desta equação mede a entropia particionando o conjunto de treinamento de acordo com o atributo A.

Logo, o ganho de informação mede a redução na entropia, ou na incerteza, ao selecionar o atributo A.

Medidas de ganhos de informação e a redução esperada na entropia, pode-se definir agora a medida da efetividade de um atributo para classificar os dados de treinamento.

O valor de Ganho (S, A) é o número de bits economizados quando codifica-se o valor-objetivo de um membro arbitrário de S, sabendo-se o valor do atributo deste conjunto de teste.

No paradigma utilizando modelos probabilísticos supervisionados, destacam-se os classificadores bayesiano com o Naive Bayes e Redes Bayesianas.

O classificador Naive Bayes possui mais restrições que um classificador Rede Bayesiana qualquer, a diferença consiste em assumir que todas as variáveis dos conjuntos de dados são condicionalmente independentes entre si dada a variável classe com o objetivo de obter um esforço computacional reduzido. Esse recurso em assumir a interdependência entre as variáveis produz um cálculo mais simples, tornando os resultados com características lineares e não exponenciais se fôssemos adotar dependências entre as variáveis. A rede Bayesiana não assume as independências absolutas entre as variáveis, exploram as probabilidades destas variáveis que influenciam diretamente na classe.

Os classificadores Bayesianos são oriundos do Teorema de Bayes descrito através da Equação 4.

$$P(A \setminus B) = P(B \setminus A) \cdot P(A) / P(B) \quad (4)$$

Segundo o Teorema de Bayes:

Buscamos classificar o novo exemplo segundo sua classe mais provável, dado seu conjunto de atributos: $\langle a_1, a_2, \dots, a_n \rangle$ na Equação.5.

$$vMAP = \underset{vj \in V}{\operatorname{argmax}} \frac{P(a_1, a_2, \dots, a_n \setminus vj) P(vj)}{P(a_1, a_2, \dots, a_n)} \quad (5)$$

A probabilidade $P(vj)$ é relativamente simples de ser estimada, assumindo que o conjunto de treinamento possui tamanho limitado. Torna-se difícil estimar, pois existem possivelmente poucas, ou nenhuma, ocorrências idênticas no conjunto de treinamento, então esta probabilidade poderia ser estimada, somente se o conjunto de treinamento fosse muito grande.

O Classificador Naive Bayes faz uma simplificação:

- Assume que os valores de atributos são independentes

- Em outras palavras, a probabilidade de observar a_1, a_2, \dots, a_n é, justamente, o produto das probabilidades de cada atributo individual, através da Equação 6.

$$P(a_1, a_2, \dots, a_n | v_j) = \prod P(a_i | v_j) \quad (6)$$

Assim, o Classificador Naive Bayes é uma simplificação, a qual é dada pela Equação.7.

$$v_{NB} = \underset{v_j \in V}{\operatorname{argmax}} P(v_j) \prod P(a_i | v_j) \quad (7)$$

Através desta simplificação, o Naive Bayes não executa a busca explícita por uma hipótese. A hipótese é formada simplesmente pela contagem de frequências.

A Figura 11 mostra como a classe relaciona-se com os atributos de acordo as características do Naive Bayes.

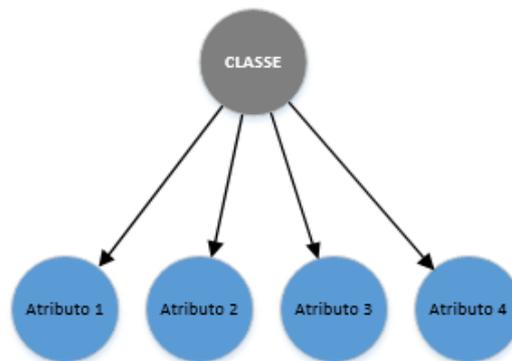


Figura 11- Algoritmo Naive Bayes e a relação entre os atributos e a Classe.

Fonte: próprio autor.

Através da simplificação da Equação 6, é possível entender como o algoritmo naive bayes é bastante interessante para os casos em que a relação condicional entre as independências entre os atributos pode executar a busca explícita por uma hipótese.

Em uma rede bayesiana, a inferência nas variáveis é possível e alteram a relação com a classe, os resultados que cada atributo poderá apresentar de acordo com a dinâmica dos resultados possíveis. A ferramenta de interface gráfica GeNIe da University of Pittsburgh (2017) oferece licença desta ferramenta. A Figura 12 ilustra a diferença na estrutura do grau de relação dos atributos e a classe no Naive Bayes e a Rede Bayesiana.

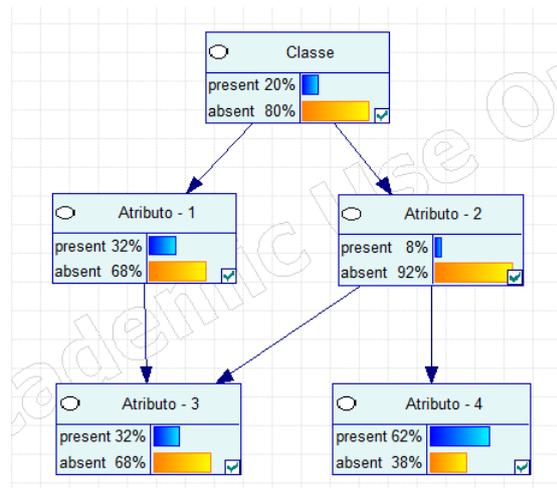


Figura 12 - Rede Bayesiana e a relação entre os atributos e a Classe.

Fonte: University Pittsburgh (2017).

3.2 Conclusão

Foi verificado, neste capítulo, que a descoberta de conhecimento em base de dados é um processo complexo, composto por diversas etapas. O critério para a realização de cada etapa pode ou não levar em consideração a necessidade da participação de um especialista no domínio da base de dados.

É importante observar que os trabalhos em detecção e diagnóstico de falha estão predominantes inseridos no cenário de equipamentos industriais. Além disso, cabe frisar que as tecnologias em aprendizado de máquina voltada para equipamentos convencionais de usos domésticos é praticamente inexistente. Através das pesquisas do estado da arte, a opção em selecionar o aprendizado de máquina, com a tarefa supervisionada, seguida da árvore de decisão são as técnicas escolhidas para a solução do problema desta dissertação.

No próximo capítulo, será apresentado o desenvolvimento do modelo DDF para equipamentos de uso domésticos convencionais utilizando o Aprendizado de Máquinas supervisionado.

4. Proposta DDF - Equipamentos Domésticos Convencionais.

Neste capítulo, é apresentada a construção do protótipo do projeto DDF. A arquitetura contendo os módulos de aquisição de dados *on-line*, o servidor DDF e o módulo de usuários. Os sensores eletrônicos não invasivos, o atuador eletrônico, a placa microprocessada que gerencia a comunicação de dados de entrada e saída com o servidor DDF, o classificador com o algoritmo com o melhor desempenho na etapa dos treinamentos e testes serão descritos neste capítulo.

Na seção 4.1 é apresentado as nuances da arquitetura e a descrição dos módulos, aquisição de dados, servidor DDF e usuários. Na etapa de produção e aprendizado, são abordados os percentuais dos conjuntos de dados separados para os testes com os algoritmos.

No final deste capítulo, é apresentada a visão geral da arquitetura.

4.1 Arquitetura do Sistema DDF Proposto

Para fornecer uma base que permitirá compreender a estrutura e a organização do sistema, uma visão do fluxo do DDF é apresentada ressaltando as características importantes de cada módulo.

A construção da arquitetura ilustra as etapas que o sistema DDF necessita para monitorar equipamentos domésticos convencionais. O modelo proposto será capaz de atuar em um sistema real com o reconhecimento de falha utilizando técnica de Aprendizado de Máquina.

No aprendizado supervisionado como visto na seção 2.3.1, todo exemplo possui um atributo especial, o rótulo ou classe, que descreve o fenômeno de interesse, isto é, a meta que se deseja aprender e poder fazer previsões a respeito.

Para o DDF proposto, a construção do conjunto de dados que envolvem as grandezas elétricas e físicas, implica em coletar dados na fase do regime de funcionamento do equipamento, nesta fase, as variáveis medidas são analisadas na etapa de pré-processamento para obtenção de dados mais precisos.

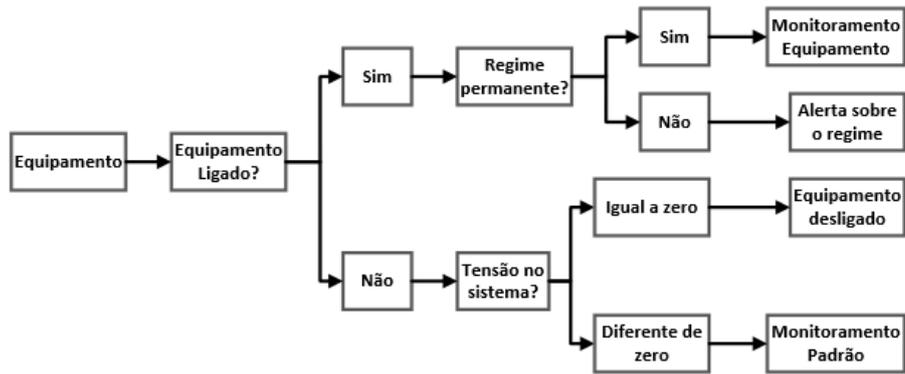


Figura 13 - Fluxo de funcionamento do equipamento.

Fonte: próprio autor.

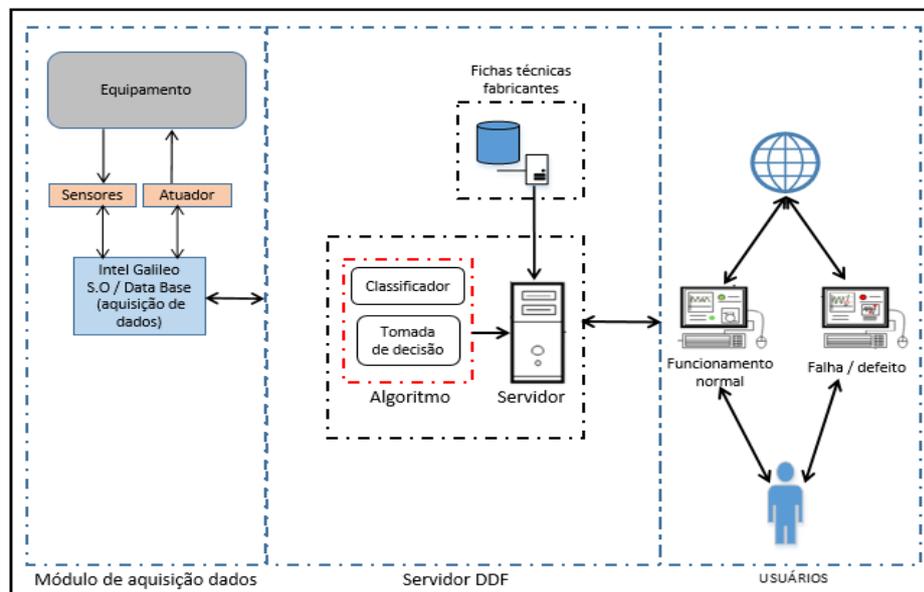


Figura 14 - Arquitetura do DDF proposto.

Fonte: próprio autor.

4.1.1 Módulo de Aquisição de Dados

O Módulo de aquisição de dados é composto pelos sensores eletrônicos instalados no equipamento monitorado, o relé atuador para eventos de interrupções, a placa microprocessada Intel Galileo que gerencia todos os eventos oriundos dos sensores e fornece pacotes de dados no formato estruturado com o *software Json* através do *HTTP* ao servidor.

Os sensores eletrônicos são específicos de acordo com as características das grandezas selecionadas, as leituras são armazenadas e formam o conjunto de dados *on-line* que será

analisado posteriormente. A coleta de dados deverá ocorrer somente na fase em que o equipamento esteja em funcionamento gerando dados fundamentais para a determinação da eficiência computacional e acurácia (taxa de predições corretas) do algoritmo. Quanto mais dados são utilizados, maior tende a ser a acurácia do modelo e consequentemente menor a eficiência computacional do processo indutivo, pois um número muito grande de objetos pode tornar o tempo de processamento muito longo. Para balancear eficiência e acurácia, utilizaremos amostras de dados com intervalos estabelecidos de leituras para formação do subconjunto dos dados *on-line*.

Além disso, o módulo de aquisição possui também um atuador para ações em ligar e desligar o equipamento remotamente. Para os casos em que o DDF identifique anormalidade grave, o atuador também poderá ser acionado.

A comunicação entre o módulo de aquisição e o servidor DDF é realizada através da internet ou conexão local direta com a placa Intel Galileo.

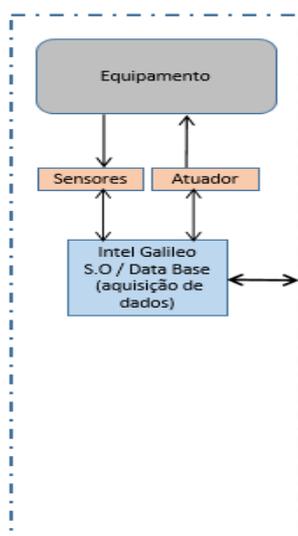


Figura 15 - Módulo de aquisição de dados.

Fonte: próprio autor.

4.1.2 Módulo Servidor DDF

Neste módulo está o servidor, nele são inseridos o banco de dados *on-line* e *off-line*, o código do classificador com o algoritmo selecionado e a comunicação entre o servidor e o usuário.

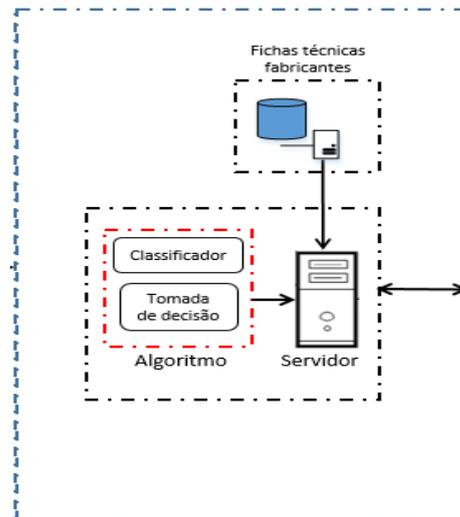


Figura 16 - Servidor DDF.

Fonte: próprio autor.

O algoritmo de aprendizado supervisionado possui um atributo especial, o rótulo ou classe, que descreve o fenômeno de interesse, isto é, a meta que se deseja aprender e poder fazer previsões através do algoritmo instalado no servidor. O aprendizado tem como objetivo relacionar os valores dos atributos de entrada de um equipamento com o seu conjunto de instâncias oriundas de dados gerados em tempo real recebidos do módulo de aquisição.

Os parâmetros de operação de cada fabricante são distintos e são disponibilizados através das fichas técnicas no banco de dados *off-line*. De fato, estes dados possuem particularidades para cada fabricante, resultando em um tratamento diferenciado para as variáveis de referência e para o diagnóstico de falha. Na etapa de pré processamento, ocorre a junção de dados *on-line* e *off-line* submetidos ao filtro do classificador para seleção de dados que são relevantes no Aprendizado de Máquina que analisam o comportamento das variáveis envolvidas.

Ressaltamos que a análise da variável selecionada deverá apresentar no decorrer do tempo características para a identificação do estado de operação do equipamento, faz-se necessário a observação do comportamento das grandezas supervisionadas com medidas mais

precisas em função do regime de funcionamento para cada equipamento. Para os casos das ocorrências de falhas diagnosticadas e que representem riscos na operação, o equipamento será desligado automaticamente na ação direta do servidor.

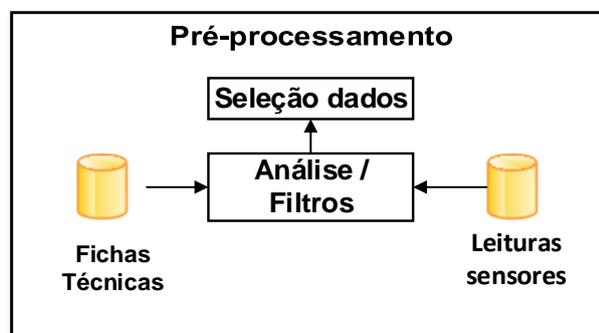


Figura 17 - Pré-processamento de dados.

Fonte: próprio autor.

A ficha técnica dos equipamentos possui informações que são fundamentais na etapa do diagnóstico, nela os limites pré-definidos pelo fabricante devem ser obedecidos criteriosamente, as falhas em funcionamento estão intimamente relacionadas com as variáveis fornecidas nesta ficha técnica. O exemplo de ficha técnica de equipamento doméstico convencional é visto na Figura 18.

MODELO	CCB07DBA	CCB07DBB	CCS07DBB	CCN07DBA	CCN07DBB	CCO07DBB	CCB10DBA	CCB10DBB	CCS10DBB	CCN10DBA	CCN10DBB	CCO10DBB
Capacidade (kW)	2,2	2,2	2,2	2,2	2,2	2,2	2,93	2,93	2,93	2,93	2,93	2,93
(BTU/h)	7500	7500	7500	7500	7500	7500	10000	10000	10000	10000	10000	10000
Ciclo	Frio	Frio	Reverso									
Tensão (V)	127	220	220	127	220	220	127	220	220	127	220	220
Frequência (Hz)	60	60	60	60	60	60	60	60	60	60	60	60
Potência (W)	748	748	748	748	748	748	964	964	964	964	964	964
Corrente (A)	6,1	3,5	3,5	6,1	3,5	3,5	7,8	4,5	4,5	7,8	4,5	4,5
Vazão de ar (m³/h)	420	420	420	420	420	420	530	530	530	530	530	530
Peso sem embalagem (kg)	23	23	23,5	23	23	23,5	27	27	28	27	27	28
Peso com embalagem (kg)	24	24	24,5	24	24	24,5	28	28	29	28	28	29
Compressor	Rotativo											
Eficiência energética (W/W)	2,94	2,94	2,94	2,94	2,94	2,94	3,04	3,04	3,04	3,04	3,04	3,04
Disjuntor (A)	10	10	10	10	10	10	15	15	15	15	15	15

Figura 18 - Exemplo de ficha técnica ar condicionado.

Fonte: Ar-condicionado – Springer (2017).

Na etapa de treinamento, os dados serão separados para gerar subsídios necessários para os algoritmos que avaliam o modelo DDF proposto. A Figura 19 ilustra os blocos dos processos de aprendizado e produção.

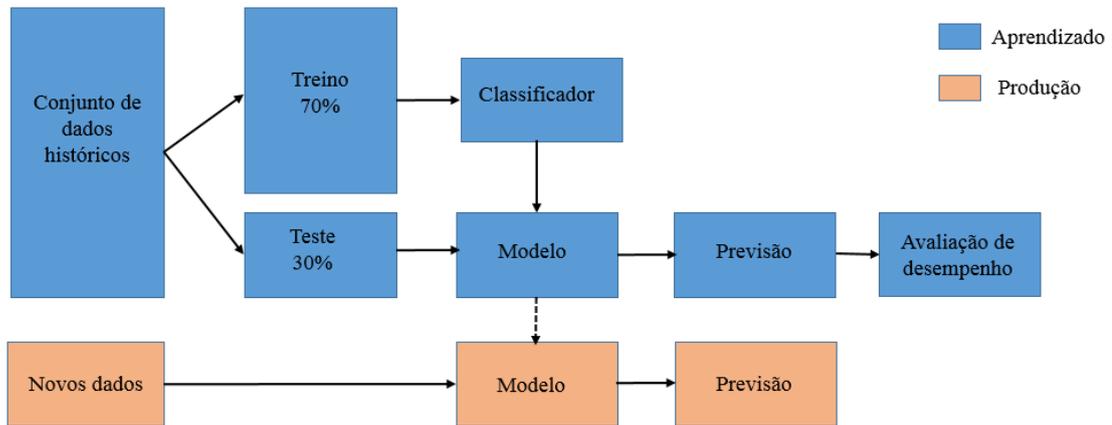


Figura 19 - Etapas de Aprendizado e Produção.

Fonte: adaptado de Katti Faceli (2011).

No trabalho de Katti Facelli (2011), o conjunto de dados são separados na etapa de aprendizado e produção.

Os blocos na cor azul representam a etapa de aprendizado, onde os dados são separados para verificação do desempenho do algoritmo. É comum a utilização de 70% dos dados para treinamento e 30% dos dados para teste, ou seja, após o classificador treinar o conjunto de treinamento, deve-se aplicar o resultado treinado com os dados de teste que não foram utilizados no treinamento para gerar uma previsão do grau de precisão. Após os resultados é possível avaliar o desempenho do modelo. Nos blocos de cor laranja na etapa de produção, novos dados podem ser inseridos ao modelo e gerar nova previsão.

4.1.3 Módulo usuários

O módulo usuários, o monitoramento ocorre em tempo real, o usuário poderá interagir com o sistema, seja na tomada de decisão de forma manual ou em monitorar o equipamento através dos dispositivos que interajam com os recursos da internet. Novos eventos podem ser cadastrados desde que sejam relevantes para enriquecer a base de dados existente em otimizar o DDF em ações de falhas não previstas anteriormente. O acesso para inserção deverá ser apenas para usuários com perfil de administrador do sistema DDF.

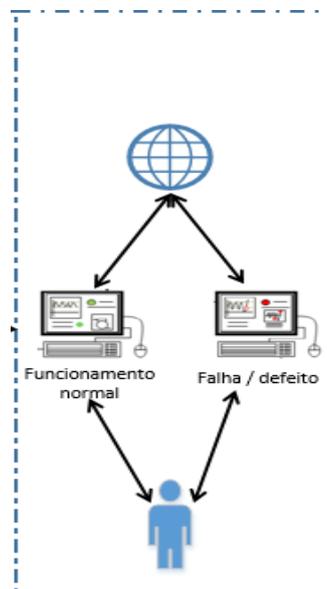


Figura 20 - Módulo usuário.

Fonte: próprio autor.

4.2 Conclusão

Neste capítulo, foi apresentada a arquitetura proposta com detalhes de cada um dos módulos, exemplo de ficha técnica para extração de dados *off-line*, as etapas de aprendizado e produção de dados que representam o processo da extração de conhecimento das bases de dados.

A ilustração da arquitetura é importante para a verificação das etapas que envolvem o sistema DDF. O aprendizado e a produção vistos na Figura 19, reforçam a importância do tratamento dos conjuntos de dados, seja tanto na etapa de treino quanto na etapa de teste.

Para validar a arquitetura proposta nesta dissertação, no próximo capítulo será apresentado a implementação de um protótipo, instalado em um equipamento de uso doméstico convencional, que contém as características necessárias para os testes e experimentações necessárias para avaliação dos resultados identificados pelo algoritmo do DDF.

5. Implementação do projeto DDF

Neste capítulo, são mostradas as etapas construtivas do protótipo; a escolha do equipamento doméstico convencional para teste do modelo DDF proposto, as variáveis relevantes de acordo com a ficha técnica, os sensores eletrônicos que serão utilizados em coletar dados das variáveis selecionadas; a construção do conjunto de dados para etapa de treinamento e teste com o algoritmo de classificação.

A seleção do equipamento doméstico convencional descreve o comportamento funcional do equipamento, assim como, suas características técnicas com as principais grandezas que atuam no funcionamento em condições normais livre de falhas de acordo com a ficha técnica do fabricante. As informações contidas na ficha técnica auxiliam na construção do banco de dados que em conjunto com os dados gerados em tempo real captados pelos sensores eletrônicos, formam a base necessária para o algoritmo aprender o funcionamento e os sintomas que conseqüentemente podem produzir falhas.

No final do capítulo, é apresentado o rendimento do algoritmo selecionado de acordo com as etapas de treinamentos e testes das bases de dados submetidos nas experimentações.

5.1 Equipamento Ar-Condicionado Convencional

Entre os equipamentos domésticos convencionais, o ar-condicionado compacto é sinônimo de conforto e bem-estar, este equipamento representa um legado do engenheiro mecânico norte-americano Willis Carrier que inventou, em 1902, em Web ar-condicionado (2017). A máquina foi a primeira a conseguir condicionar mecanicamente o ar, controlando a temperatura e a umidade do ambiente. Mesmo passados tantos anos, milhões de pessoas continuam utilizando este equipamento que, de fato, sofreu melhorias principalmente em relação ao consumo de energia.

Não são tão silenciosos quanto a linha de ar condicionado split, porém utilizam o evaporador e o condensador dentro do mesmo gabinete, pode ser instalado na parede ou na janela de ambientes residenciais, comércio e em indústrias em áreas que necessitem de controle de temperatura.

O ar-condicionado convencional possui dispositivos de controles mecânicos e totalmente isento de comunicação com o usuário. A partir do modelo do aparelho de ar-condicionado convencional escolhido, é possível extrair referências das variáveis e faixa de

tolerância contida na ficha técnica, as recomendações de uso, análises de falhas, limites das grandezas elétricas tensão e corrente e temperaturas. Estas informações são inseridas no banco de dados *off-line* de acordo com o modelo do fabricante Springer. As variáveis que serão selecionadas do ar-condicionado compacto para implementação são o modelo FCA078BB Springer Silentia.



Figura 21 - Ar condicionado convencional modelo Silentia.

Fonte: Ar condicionado, Springer (2017).

5.1.1 Extração de Dados On-Line - Variáveis

As variáveis elétricas e físicas com maior relevância no processo do diagnóstico de falha do ar-condicionado, foram selecionadas após minuciosa análise da ficha técnica do modelo escolhido. De acordo com as características para o funcionamento do ar-condicionado em um ambiente com dimensões favoráveis para sua utilização, a Tabela 3 ilustra a variável tensão elétrica e suas faixas de tolerância.

Limites de tensão para o ar-condicionado funcionar adequadamente.

Tensão nominal (V)	Mínimo (V)	Máximo (V)
127	105	135

Tabela 3 - Referências de tensão para o ar condicionado.

Fonte: próprio autor.

A variável tensão elétrica é coletada através do sensor eletrônico que mede a variação da tensão da rede elétrica que alimenta o ar-condicionado. A variação da tensão possui relação direta com sintomas que podem avançar para o defeito. O sensor eletrônico de tensão não está

incorporado no ar-condicionado, mas é um dispositivo capaz de fornecer dados na etapa da coleta de dados *on-line* no processo da construção do sistema DDF.



Figura 22 - Sensor eletrônico de tensão.

Fonte: Eletrônicos, felipeflop (2017).

A outra variável selecionada é a corrente elétrica do conjunto. A corrente é presente somente no regime de funcionamento do ar-condicionado através do consumo da corrente do motor do ventilador no estágio da ventilação e refrigeração, adicionado também com o consumo da corrente do compressor. Da mesma forma que a tensão elétrica, a variável corrente possui referência nominal para partida do compressor e corrente nominal em regime de funcionamento. A Tabela 4 ilustra a variável corrente elétrica e suas faixas de referências.

Limites de corrente elétrica para o ar-condicionado funcionar adequadamente.

Corrente nominal (A)	Mínimo (A)	Máximo (A)
6.0	4.8	7.2

Tabela 4 - Referências da variável corrente elétrica.

Fonte: próprio autor.

A variável corrente elétrica é coletada através do sensor eletrônico não invasivo que mede a variação da corrente de consumo total do ar condicionado. A variação da corrente estabelece relação direta com sintomas que podem avançar para o defeito. O sensor eletrônico de corrente também não está incorporado no ar condicionado, mas é um dispositivo capaz de fornecer dados na etapa da coleta de dados *on-line* no processo da construção do sistema DDF.



Figura 23 - Sensor eletrônico de corrente.

Fonte: Eletrônicos, felipeflop (2017).

A variável física temperatura é a variável que apresentam propriedades físicas que variam de acordo com: ambiente interno, ambiente externo, temperatura de insulflamento e temperatura de retorno estas últimas temperaturas procedentes do ar condicionado.

Temperatura ambiente interno (bulbo seco) °C	26.7
Temperatura ambiente interno (bulbo úmido) °C	19.4
Temperatura ambiente externo (bulbo seco) °C	35.0
Temperatura ambiente externo (bulbo úmido) °C	24.0
Diferencial de temperatura (saída e entrada) °C	8 a 12

Tabela 5 - Referências da variável temperatura.

Fonte: próprio autor.

A leitura da variável física de temperatura para os ambientes interno e externo, é coletado através dos sensores eletrônico de temperatura que também serão utilizados na leitura das temperaturas de insulflamento e temperatura de retorno. O ar condicionado não possui sensores de temperatura que possam gerar dados, portanto estes sensores são inseridos para a construção dos sistema DDF.



Figura 24 - Sensor eletrônico de temperatura.

Fonte: Eletrônicos, felipeflop (2017).

A variável física vibração é coletada através do sensor de vibração eletrônico que detecta dados de vibração e determina o diagnóstico se existe ou não presença de vibração excessiva no ar-condicionado. A vibração possui relação direta com defeito denominado ruído excessivo. O sensor eletrônico de vibração não está incorporado no condicionado, mas é um dispositivo capaz de fornecer dados na etapa da coleta de dados *on-line* no processo da construção do sistema DDF.



Figura 25 - Sensor eletrônico de vibração.

Fonte: Eletrônicos, felipeflop (2017).

A variável física presença é coletada através do sensor de presença eletrônico que detecta através dados de movimento e determina a presença ou não de pessoas no ambiente. A presença produz efeito na ação do monitoramento, para os casos em que não há presença por um período determinado, o funcionamento do ar-condicionado pode ser considerado operação em regime ocioso. O sensor eletrônico de presença também não está incorporado no ar-condicionado, mas é um dispositivo capaz de fornecer dados na etapa da coleta de dados *on-line* no processo da construção do sistema DDF.



Figura 26 - Sensor eletrônico de presença.

Fonte: Eletrônicos, felipeflop (2017).

A variável física que monitora a condição se a porta ou janela no ambiente está aberta ou fechada é feita através do sensor magnético de abertura que funciona como interruptor (liga/desliga), acionados por campo magnético produzido por ímãs quando aproximados. Este sensor é instalado na porta do ambiente e em janelas. A efetiva comprovação em existir perda de carga térmica no ambiente em função da porta/janelas em estado aberto/fechado, possui relação com o rendimento do ar condicionado.

A possibilidade da perda térmica ocorrer devido ao estado da porta/janela estar aberta, fornece subsídio para que o usuário possa tomar decisão através do monitoramento remoto, visto que, porta/janela aberta seguido da ausência de pessoas no ambiente por um período determinado for comprovada, o funcionamento do ar-condicionado é ocioso. O sensor de abertura magnético não está incorporado no ar-condicionado, mas é um dispositivo contido na etapa da coleta de dados *on-line*.



Figura 27 - Sensor magnético de abertura.

Fonte: Eletrônicos, felipeflop (2017).

O atuador contido na arquitetura do DDF terá a função de interromper o funcionamento do ar-condicionado para os casos em que o sistema DDF identificar anormalidades que possam danificar o equipamento ou através da ação do usuário em interromper o funcionamento por livre opção.

O contactor funciona com tensão de 127V e pode acionar ou desligar carga de até 250VAC ou 30 VDC e suporta passagem de corrente até 20^a. Com essas características, o contactor possui boa margem de referência para a inserção no projeto DDF.



Figura 28 - Atuador para interrupção do ar condicionado.

Fonte: Eletrônicos, felipeflop (2017).

O *shield Wifi* compatível com a placa Intel Galileo possui recursos para comunicação sem fio que facilita a integração e minimiza o tempo de desenvolvimento na etapa da transferência dos pacotes de dados ao servidor DDF. Esta opção de comunicação é muito útil na ausência da rede internet no ambiente da instalação dos sensores e configuração da placa microprocessada Intel.



Figura 29 - Shield WiFi de comunicação sem fio.

Fonte: Eletrônicos, felipeflop (2017).

A placa Intel Galileo é responsável em coletar os dados e eventos dos sensores conectados no ar-condicionado e no ambiente. A escolha da placa Intel Galileo para o projeto do DDF é devido a compatibilidade do micro controlador em poder embarcar os *shields* dos sensores escolhidos na coleta de dados *on-line* das variáveis selecionadas e a comunicação para conexões *Ethernet* RJ-45 para rede com cabos, *WiFi*, *Bluetooth*, fundamentais na implementação do projeto.



Figura 30 - Placa de aquisição de dados Intel Galileo.

Fonte: Eletrônicos, felipeflop (2017).

A Tabela 6 ilustra as referências dos sensores, atuador, e da placa microprocessada que compõe a fase da coleta de dados *on-line* do protótipo.

Dispositivos	Referências
Sensor de Corrente não invasivo	SCT-013
Sensor de tensão	P-08
Sensor de temperatura	DHT II
Sensor de vibração	SW-420
Sensor de movimento	DYP-ME003
Contactora de interrupção	23V30A
Sensor de abertura	MAG-01
Shield WIFI	ESP8266 ESP13
Placa Intel	Galileo

Tabela 6 - Referências dos sensores eletrônicos e placa Intel Galileo.

Fonte: próprio autor.

5.1.2 Princípio Básico do Ar-Condicionado

O ar-condicionado executa a tarefa de proporcionar aos ambientes por ele atendidos, temperaturas agradáveis criando sensação de conforto térmico, ou até mesmo se fazer úteis em determinados ambientes em que o seu uso é indispensável.

Para selecionar um ar condicionado é necessário algumas considerações: a dimensão do ambiente, o material de isolamento térmico do ambiente, a sua exposição em relação ao sol ou sombra, a quantidade de ocupantes que frequentarão o ambiente.

O princípio de funcionamento do ar-condicionado convencional modelo mecânico é descrito de acordo com a Figura 31.

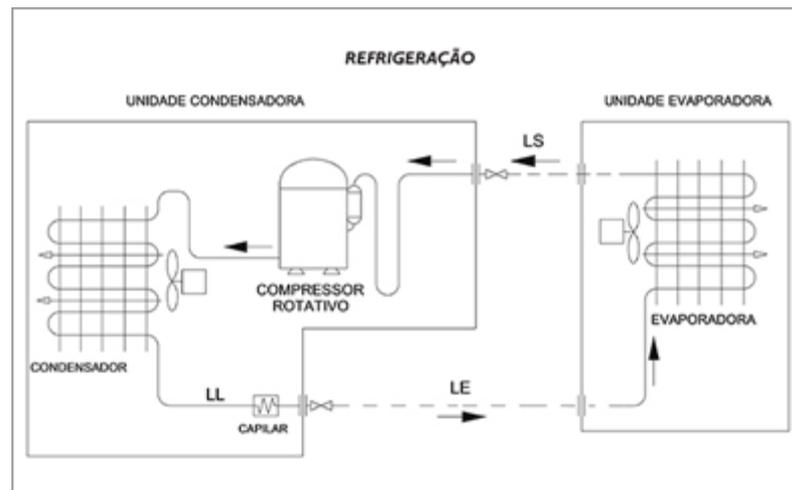


Figura 31 - Princípio básico de funcionamento - Ciclo frio do ar-condicionado.

Fonte: Ar condicionado, Springer (2017).

O ciclo inicia com a sucção do ar do ambiente através do ventilador do evaporador, neste momento o ar do ambiente atravessa o conjunto de serpentinas preenchidas com o gás refrigerante, este gás evapora a 7°C . Ao absorver o calor do ar que vem do ambiente interno, o gás refrigerante muda de fase deixa seu estado líquido se transformando em um gás. Em seguida, passa por um compressor, sofrendo um aumento de pressão e aquecendo até uma temperatura aproximada de 52°C .

O gás em estado gasoso e aquecido é enviado para um condensador na parte externa do aparelho, passando por um processo de troca de calor com o ambiente externo e tornando-se líquido novamente. Daí, a substância refrigerante entra em uma válvula que a faz perder pressão e retorna ao seu estado líquido inicial, reiniciando todo o seu ciclo.

Destaca-se a importância do compressor para o ciclo frio do ar condicionado, que ao executar esta tarefa, necessita da grandeza corrente elétrica

O monitoramento da corrente elétrica já está selecionado na construção do conjunto de dados *on-line*. O diagnóstico de falha do compressor em função da corrente elétrica, torna-se bastante interessante, o DDF proposto é capaz de identificar esta falha através da técnica de Aprendizado de Máquina.

5.1.3 Classificador e Algoritmo

O sistema DDF possui características com aprendizado automático, logo, o algoritmo do classificador deve ser capaz de aprender com os conjuntos de treinamentos e testes e com dados novos não apresentados. Para solucionar o problema com diagnóstico de falha automaticamente, a escolha pela tarefa de classificação é a mais apropriada. A maneira como a falha deverá ser diagnosticada e avaliada, converge para os algoritmos da tarefa de classificação que aprendem com exemplos e observações de dados.

Para aplicação da tarefa de classificação e o algoritmo, na construção do DDF, utilizaremos o software livre *Weka* (Waikato Environment for Knowledge Analysis) que possui ferramenta em pré processamento, testes e simulações dos conjuntos de dados.

Antes do uso deste software, é necessário converter os dados para o padrão no formato *. *arff* (Attribute Relation File Format).

Os dados extraídos do ar-condicionado em regime de funcionamento são agrupados e rotulados de acordo com seus respectivos atributos. A classe representa o alvo do diagnóstico da falha a ser detectada pelo algoritmo do classificador que a ferramenta *Weka* fornecerá após a execução do *dataset* gerado pelos dados do arquivo *ddf-ar-condicionado.arff*. O arquivo contém o conjunto de treinamento no formato *arff* de acordo com os atributos e as classes.

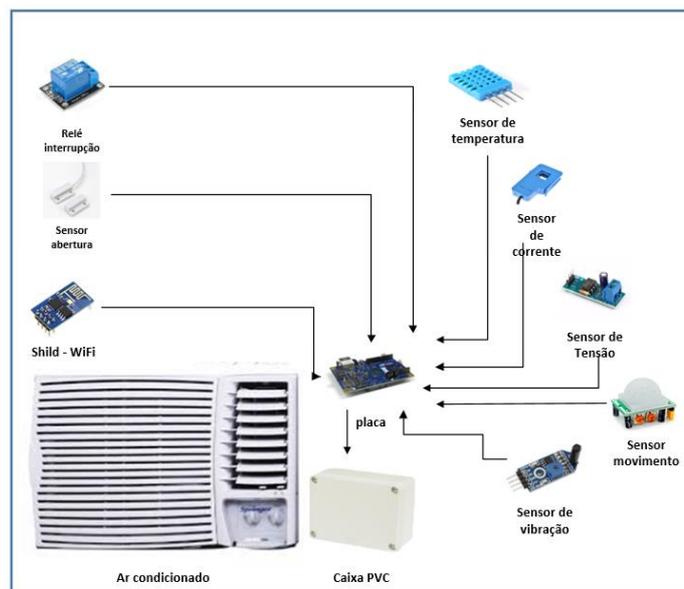


Figura 32 - Sensores, módulo de aquisição de dados e ar-condicionado.

Fonte: próprio autor.

O módulo de aquisição de dados é composto por sensores não invasivos capazes de medir corrente elétrica, tensão, temperatura, presença, porta aberta e vibração. Os sensores devem captar os sinais e transmiti-los para placa Intel Galileo.

Para simulação do algoritmo J4.8, foi utilizado o software *Weka*, este software é formado por um conjunto de algoritmos de diversas técnicas para resolver problemas concretos de Aprendizado de Máquina. O software está implementado em linguagem *Java*. O *Weka* foi escolhido tendo em vista sua praticidade de utilização, bem como o fato de ser um software de domínio público.

• **Árvore de Decisão**

O paradigma simbólico árvore de decisão no Aprendizado de Máquina é um diagrama que permite representar e avaliar problemas que envolvem decisões sequenciais de um conjunto de variáveis. Foi utilizado o *software Weka / preprocess / classify / trees / algoritmo J48*.

Para execução do algoritmo J4.8, foi necessário alocar cada base de dados contendo instâncias e atributos. A representação da base de dados está representada na Tabela 7.

Tensão (V)	Corrente nominal (A)	Temperatura Interna ° C	Temperatura Externa ° C	Temperatura (saída) ° C	Porta aberta	Presença	Vibração
127.5	6,35	21.55	29.55	8.79	1	1	0
127.5	6.39	21.16	29.55	8.79	0	1	0
127.5	6.10	21.16	29.60	9.28	1	1	0
127.5	6.80	21.18	29.70	10.26	1	1	0
128.4	6.40	21.16	29.95	11.73	1	0	0
127.9	6,50	21.16	30.15	13.19	1	1	0
127.9	6.35	21.18	30.25	14.66	1	1	0
126.9	6.85	21.25	30.30	16.12	1	1	0

Tabela 7 - Base de dados instâncias x atributos do ar condicionado.

Fonte: próprio autor.

Na experiência com o algoritmo J48 foi utilizado o padrão *arff* para os arquivos de entrada. Este padrão é utilizado para representar uma série de dados dos exemplos independentes.

```

@RELATION ddfarcondicionado
@ATTRIBUTE Tensão NUMERIC
@ATTRIBUTE Corrente NUMERIC
@ATTRIBUTE Temp-externa NUMERIC
@ATTRIBUTE Temp-sala NUMERIC
@ATTRIBUTE Temp-insuflamento NUMERIC
@ATTRIBUTE Porta-aberta NUMERIC
@ATTRIBUTE Presença NUMERIC
@ATTRIBUTE Vibração NUMERIC
@ATTRIBUTE Diagnóstico {normal,filtro,sobretensão,subtensão,compressor,vibração,ausência}

@DATA
126,7,32,24,16,1,1,0,normal
127,7,30,23,23,1,1,0,filtro
124,7,32,23,14,1,1,0,normal
126,7,32,24,16,1,1,0,normal
126,7,32,24,15,1,1,0,normal

```

Figura 33 - Arquivo arff contendo exemplo do ar condicionado.

Fonte: próprio autor.

As características dos arquivos *arff* devem ser obedecidas para o reconhecimento da ferramenta *Weka*.

O símbolo % significa que a linha é um comentário, não tendo validade junto ao processamento pelo algoritmo. A primeira linha válida indica o nome da relação a encontrar (@relation nome_da_relação), as linhas seguintes devem listar todos os atributos, onde deve-se definir o tipo dos atributos e os valores que eles podem representar. Neste último caso os valores devem estar entre “{}” e separados por vírgula. No próximo bloco de informações, após uma linha de indicação (@data), vêm as instâncias, ou seja, os registros a serem aprendidos com os valores dos atributos para cada instância separado por vírgula, a ausência de um item em um registro deve ser atribuída pelo símbolo “?” Para a simulação no algoritmo J48 foi utilizado o padrão *arff* para os arquivos de entrada. Este padrão é utilizado para representar um série de dados que consistem em exemplos independentes.

- **Rede Bayesiana**

A técnica das redes bayesianas constitui um modelo gráfico probabilístico que representa de forma simples as relações de causalidades das variáveis de um sistema. Para analisar a base de dados da Tabela 7 e utilizar o algoritmo naive bayes, utilizamos o *software Weka / preprocess / classify / bayes/ naive bayes*.

Para o experimento do algoritmo, naive bayes foi utilizado o mesmo conjunto de dados do arquivo ilustrado da Figura 33.

A escolha do melhor algoritmo é uma tarefa que necessita de treinamento, já que o algoritmo pode ter melhor desempenho em determinada situação e outro pode ser mais eficiente em outros tipos de situações.

Os experimentos com os algoritmos através dos conjuntos de dados foram agrupados da seguinte forma; cada base de dados é organizada em dois conjuntos, sendo um de treinamento e o outro de validação. Os dados de treinamento foram feitos com 70% e as validações com 30% restantes dos conjuntos de treinamentos.

Foram utilizadas duas bases de dados contendo características do funcionamento do ar- condicionado com experimentos para os diagnósticos de defeitos.

- Base 1: composta de 50 instâncias para os diagnósticos determinados através de medições específicas e visuais no ar-condicionado, feitas por especialista, com resultados; 15 instâncias da classe normal, 10 instâncias da classe ausência, 10 instâncias filtro obstruído, 02 instâncias da classe defeito compressor, 10 instâncias classe porta aberta, 03 instâncias vibração.
- Base 2: composta de 100 instâncias determinadas através de medições específicas e observadas por especialista, os diagnósticos apresentaram resultados; 65 instâncias da classe normal, 15 instâncias da classe ausência, 05 instâncias da classe filtro obstruído, 05 instâncias da classe defeito compressor, 05 instâncias da classe porta aberta e 05 instâncias da classe vibração.

Para a escolha do algoritmo, foram utilizados 70% dos dados para treinamentos e 30% para testes tanto para Base de teste 1 e 2 respectivamente.

Classificadores	Algoritmos	Opções de teste WEKA	Taxa de Acertos (%) Base - 1	Taxa de Acertos (%) Base - 2
Árvore de decisão	J48	Split 70.0% train, remainder test	94,00	98,33
Rede Bayesiana	Naive Bayes	Split 70.0% train, remainder test	86,86	92,23

Tabela 8 -Taxas dos acertos dos algoritmos.

Fonte: próprio autor.

Comparando os resultados, pode-se considerar que os algoritmos utilizados nesta avaliação apresentaram resultados bastante equivalentes de acordo com a base de dados submetida para os treinamentos e testes. O algoritmo da árvore de decisão J48 apresentou taxa de acerto com maior percentual, 98,33%. A Base 1 possui a metade das instâncias que a Base 2, entretanto é percebido o ganho em acertos com o acréscimo das instâncias de treinamentos para os algoritmos avaliados.

5.2 Conclusão

Neste capítulo, foi apresentado o ar-condicionado compacto, equipamento de uso doméstico convencional selecionado para extração das grandezas elétricas e físicas em regime de funcionamento, a extração de dados *on-line* através dos sensores eletrônicos específicos em cada etapa de leitura, a definição da tarefa de classificação, árvore de decisão com a escolha do algoritmo J48, a construção das bases dos conjuntos de dados *off-line* para simulações com seus respectivos diagnósticos com auxílio de especialista em ar-condicionado convencional.

O capítulo também descreveu a ferramenta *Weka* como a construção do arquivo com o formato padrão *arff* para a execução dos conjuntos de dados para treinamentos e testes.

No próximo capítulo, serão apresentados os resultados das avaliações do sistema DDF através do estudo de caso com o cenário utilizando o ar-condicionado convencional, as etapas das experimentações e resultados, a visualização dos diagnósticos nas telas do monitoramento em tempo real detectados pelo sistema DDF proposto.

6. Avaliação do Sistema DDF Proposto

Neste capítulo, será apresentada a avaliação do sistema DDF a partir de um cenário real com experimentos e os respectivos resultados.

Primeiramente, descreve-se o cenário para em seguida serem abordados os dispositivos utilizados na avaliação assim como os experimentos das funcionalidades executadas no cenário proposto. A sala de Convivência no prédio do Ceteli/Ufam, possuem dimensões e a disponibilidade de um aparelho de ar-condicionado convencional. O acesso até este ambiente é somente através da porta única, as janelas são basculantes e a população que ocupa o ambiente é adequada à prática dos experimentos.

A sala possui recurso de rede internet, conexão cabeada, e tomada elétrica já existente na alimentação do ar-condicionado. As conexões dos sensores foram instaladas no lado externo da sala e no interior da sala, assim como na periferia do gabinete do ar-condicionado.

No final deste capítulo, é apresentado um resumo dos diagnósticos realizados com o sistema DDF proposto.

6.1 Estudo de Caso

Para o estudo de caso, foi instalado na sala de convivência do prédio do CETELI da Universidade Federal do Amazonas - Ufam, o módulo de aquisição do sistema DDF em destaque através do círculo de cor vermelha, na Figura 34.

As leituras das grandezas elétricas e físicas selecionadas são extraídas através dos sensores eletrônicos em tempo real. Foram selecionadas as grandezas, tensão elétrica, corrente elétrica, temperatura interna da sala, temperatura externa, temperatura de saída do ar condicionado, o estado em que a porta de entrada do ambiente, fechada ou aberta, presença de pessoas na sala e a existência de vibração no conjunto do gabinete do ar-condicionado.

O servidor onde o DDF realizará as análises dos dados enviados pelo módulo de aquisição, encontra-se no Laboratório de TV Digital no prédio do Ceteli. Ao acessarmos este servidor, iremos acompanhar em tempo real todos os eventos relacionados à operação do DDF, assim como o monitoramento e a avaliação do comportamento do ar-condicionado. A plataforma de serviços em tempo real poderá ser configurada com novos dados referentes a novas características pré-estabelecidas para um novo ambiente e de acordo com cada equipamento.

O cenário escolhido possui características que possibilitam a coleta de dados em tempo real para o servidor que estará remotamente armazenando dados e avaliando a melhor decisão de acordo com cada particularidade do ambiente no qual o ar-condicionado está submetido.



Figura 34 - Protótipo instalado na Sala de Convivência / CETELI (UFAM).

Fonte: próprio autor.

6.1.1 Experimentos e Diagnósticos

Para o monitoramento do ar-condicionado com acesso remoto, foi criada a página na internet no endereço ufam-automation.net, através do sistema chamado Detecção e Diagnóstico de Falha em Ar-Condicionado. Utilizando *login* e senha, é possível acessar a tela do DDF desenvolvido nesta dissertação. No sistema também é possível acompanhar as etapas dos experimentos e suas respectivas falhas com os diagnósticos correspondentes às experiências realizadas.

SalaConvivencia1Ceteli	
Histórico	Ligado ● Funcionamento normal
ID	1
Aparelho	SalaConvivencia1Ceteli
Modelo	FCA078BB
Capacidade	7500
Tensao Nominal	127
Tensao Minima	105
Tensao Maxima	135
Frequencia	60
Corrente Nominal	6.5
Corrente Partida	15
Potencia Nominal	750
Temperatura Interna Bulbo Seco	26.7
Temperatura Interna Bulbo Umido	19.4
Temperatura Externa Bulbo Seco	35
Temperatura Externa Bulbo Umido	24
Temperatura Diferencial	8

Figura 35 - Tela inicial do monitoramento remoto ar condicionado.

Fonte: próprio autor.

As etapas dos experimentos que resultaram nas falhas com o ar-condicionado em operação no ambiente proposto, foram realizadas na sala de Convivência do CETELI. Percebe-se que as medições são realizadas com dados produzidos em circunstâncias premeditadas e em pontos estratégicos do ar-condicionado.

Para o acompanhamento dos resultados dos experimentos, foi necessário o acesso do monitoramento remoto através do servidor DDF. As telas apresentam as variáveis com as respectivas leituras em tempo real.

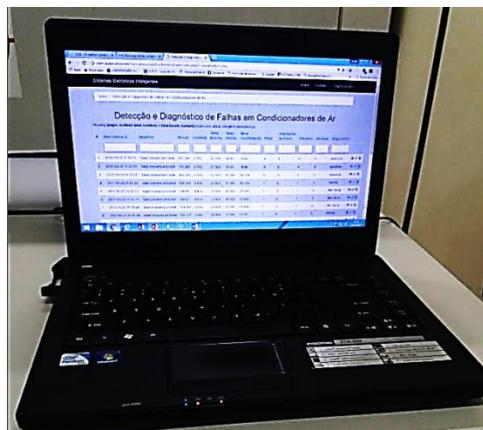


Figura 36 - Monitoramento ar condicionado acesso remoto.

Fonte: próprio autor.

Na entrada de ar do retorno do ambiente na tela do filtro demarcada com o círculo na cor vermelha, foi introduzido uma folha de papel para obstrução da passagem de ar do retorno do ambiente. Este experimento induz a hipótese de sujeira excessiva no filtro de ar ou obstrução total. A relação deste experimento produz alteração nas temperaturas de insuflamento e retorno do ambiente, tornando assim praticamente iguais. Os dados coletados pelos sensores de corrente e temperaturas instalados fornecem em tempo real dados para o módulo de aquisição, mais precisamente para a placa Intel Galileo que automaticamente alimenta o banco de dados do servidor DDF.




Figura 37 - Ar condicionado com filtro de ar obstruído.

Fonte: próprio autor.

A detecção desta falha é percebida no DDF e disponibilizada na tela do sistema de monitoramento remoto, conforme ilustrado na Figura 38.

Detecção e Diagnóstico de Falhas em Condicionadores de Ar												
Showing {begin, number}-{end, number} of {totalCount, number} {totalCount, plural, one{item} other{items}}.												
#	Data Leitura ↕	Aparelho	Tensao	Corrente	Temp Externa	Temp Interna	Temp Insuflamento	Porta	Interrupcao de Falha	Presenca	Vibracao	Diagnostico
6	2017-03-23 11:32:13	SalaConvivencia1Ceteli	128.57	4.819	21.505	16.129	21.505	1	0	1	0	filtro de ar
7	2017-03-23 11:30:48	SalaConvivencia1Ceteli	129.167	5.642	21.994	17.106	21.994	1	0	1	0	filtro de ar

Figura 38 - Diagnóstico filtro de ar.

Fonte: próprio autor.

Outra experiência no aparelho de ar-condicionado foi a vedação da passagem de ar. O gabinete do ar-condicionado possui entradas de ar externo na parte superior e lateral para o sistema de condensação. Na parte superior do gabinete do ar-condicionado indicado pela seta na Figura 39, indica que a entrada de ar externo foi forçadamente obstruída com o uso de folhas de papel. Na entrada de ar na parte lateral, também foi vedada. O resultado desta experiência tem relação direta com o desempenho do ar-condicionado, o fluxo de ar externo interrompe a troca de calor produzida pelo sistema do compressor.

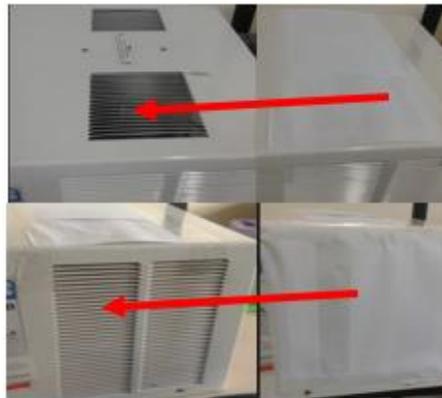


Figura 39 - Entrada de ar externo obstruídas.

Fonte: próprio autor.

O resultado logo é percebido pelo sensor de temperatura externa e diretamente há o crescimento do valor da corrente do compressor percebido através do sensor responsável em detectar esta anormalidade, o sensor de corrente não invasivo identifica falha grave, sinalizada na tela do monitoramento em tempo real.

Detecção e Diagnóstico de Falhas em Condicionadores de Ar												
Showing {begin, number}-{end, number} of {totalCount, number} {totalCount, plural, one{item} other{items}}.												
#	Data Leitura ↓	Aparelho	Tensao	Corrente	Temp Externa	Temp Interna	Temp Insulfiamento	Porta	Interrupcao de Falha	Presenca	Vibracao	Diagnostico
10	2017-03-23 11:30:12	SalaConvivencia1Ceteli	129.167	8.608	21.505	18.84	14.173	1	1	0	0	compressor
11	2017-03-23 11:30:00	SalaConvivencia1Ceteli	129.167	8.428	21.505	19.55	16.129	1	1	0	0	compressor

Figura 40 - Diagnóstico compressor.

Fonte: próprio autor.

Outra experiência consistiu na hipótese da ocorrência de forte vibração no ar-condicionado. As causas que podem ocorrer para produzir vibração e conseqüentemente ruídos, são percebidas através do sensor de vibração fixado no gabinete do ar condicionado.

Para que sejam emitidos dados referentes à vibração, a relação com esta variável é associada às hipóteses de danos nas hélices dos ventiladores, evaporador ou do ventilador do sistema de condensação, ambas são movimentadas por um único motor elétrico.

Detecção e Diagnóstico de Falhas em Condicionadores de Ar													
Showing {begin, number}-{end, number} of {totalCount, number} {totalCount, plural_one(item) other(items)}.													
#	Data Leitura ↓	Aparelho	Tensao	Corrente	Temp Externa	Temp Interna	Temp Insuflamento	Porta	Interrupcao de Falha	Presenca	Vibracao	Diagnostico	
13	2017-03-23 11:29:09	SalaConvivencia1Ceteli	130.363	0.728	21.505	19.55	18.84	1	1	0	1	vibracao	👁️🗑️
14	2017-03-23 11:29:09	SalaConvivencia1Ceteli	130.363	0.728	21.505	19.55	18.84	1	1	0	1	vibracao	👁️🗑️

Figura 41 - Tela do monitoramento DDF ar condicionado diagnóstico vibração.

Fonte: próprio autor.

A hipótese de que ocorram ausências de pessoas no ambiente seguido de porta aberta é visto de acordo com a Figura 42. A experiência foi realizada utilizando os sensores de presença e o sensor de abertura de porta. Nas ações do sistema DDF, desligar o ar condicionado após o tempo estimado de 30 minutos sem presença de pessoas seguido de porta aberta, considera-se que o ar-condicionado está funcionando para um ambiente sem ocupação humana, portanto, desperdício de energia elétrica.



Figura 42 – Diagnóstico ausência.

Fonte: próprio autor.

Detecção e Diagnóstico de Falhas em Condicionadores de Ar												
Showing (begin, number)-(end, number) of (totalCount, number) (totalCount, plural, one(item) other(items)).												
#	Data Leitura	Aparelho	Tensao	Corrente	Temp Externa	Temp Interna	Temp Insulfimento	Porta	Interrupcao de Falha	Presenca	Vibracao	Diagnostico
1	2017-03-23 11:33:13	SalaConvivencia1Ceteli	130.363	0.732	21.505	19.55	18.84	0	0	0	0	ausencia
2	2017-03-23 11:33:13	SalaConvivencia1Ceteli	130.363	0.732	21.505	19.55	18.84	0	0	0	0	ausencia

Figura 43 - Diagnóstico ausência.

Fonte: próprio autor.

6.2 Avaliação de Desempenho

Os dados utilizados nos experimentos foram dados reais transferidos automaticamente do módulo de aquisição para o servidor DDF. A ideia por trás da aprendizagem de máquina é que as percepções práticas devem ser usadas não apenas para agir, mas também para melhorar a habilidade do algoritmo J48 em identificar falhas com mudanças adaptáveis no sistema.

Os diagnósticos apresentados corresponderam às experiências das falhas em que o aparelho de ar-condicionado foi submetido.

É importante esclarecer que o ambiente proposto é compatível com a carga térmica do ar-condicionado e o volume de dados gerados foi estabelecidos de acordo com os padrões normais de funcionamento.

As falhas que produziram os diagnósticos identificados nas telas do monitoramento, somente foram possíveis após ações das experiências nas etapas dos testes práticos.



Figura 44 – Módulo de aquisição, servidor DDF, internet e usuário.

Fonte: próprio autor.

O esquema da Figura 44 descreve a conexão prática do monitoramento do ar condicionado, através do sistema desenvolvido para detecção e diagnóstico de falha avaliado no estudo de caso. Os usuários que antes não tinham acesso ao monitoramento podem, a partir

deste trabalho, identificar falhas com os respectivos diagnósticos, assim como também atuar no equipamento remotamente.

A Tabela 9 apresenta os resultados das experiências realizadas que possibilitaram a validação da seleção das grandezas elétricas e físicas que diretamente participam no monitoramento do ar-condicionado.

Leitura dos sensores	Sintomas de falhas	Diagnósticos	Possíveis correções
Corrente do compressor ler acréscimo > que 20% acima da corrente nominal.	Condensador com baixa troca de calor, temperatura externa >45°C	Compressor anormal	Verificar sujeira na serpentina do condensador, entrada de ar do gabinete obstruídas.
	Corrente do compressor acima do valor nominal e aumentando		
	Corrente do compressor acima do valor nominal e aumentando		
Tensão da rede elétrica <105 V.	Corrente do compressor acima do valor nominal e aumentando	Sub tensão Compressor anormal	Efetuar medidas elétricas no compressor, trocar compressor
	Compressor não liga.		
	Não esfria o ambiente		
Temperatura de insuflamento (saída de ar) praticamente igual a temperatura de retorno do ambiente.	Não esfria o ambiente	Filtro de ar/serpentina do evaporador anormal	Verificar possíveis alterações no ambiente atendido pelo ar condicionado
	Corrente do compressor abaixo da corrente nominal		
	Temperatura de retorno anormal.		
Porta aberta, sem detecção de pessoas no ambiente após 30 minutos.	Sintomas ausência carga térmica	Ausência	Desligar ar condicionado
Vibração	Ruído e vibração no funcionamento	Vibração	Desligar ar condicionado

Tabela 9 - Resultados das experiências das falhas e diagnósticos.

Fonte: próprio autor.

6.3 Conclusão

Neste capítulo, foi apresentada a avaliação do sistema DDF eletrônico implementado a partir de um cenário real de teste na sala de Convivência do prédio Ceteli/Ufam. Os resultados apresentados em cada tela do ambiente de monitoramento com acesso remoto, via internet, com seus respectivos diagnósticos, tornaram-se possíveis somente após as etapas das experiências com ações premeditadas, estas ações resultaram em sintomas de falhas. Observou-se as detecções das falhas no sistema DDF através do acesso remoto desenvolvido para comunicação via internet, pois entendeu-se que as falhas ocorreriam de acordo com as sequências dos testes.

O uso dos sensores eletrônicos não invasivos torna prático a coleta de dados, o envio das leituras das grandezas elétricas e físicas até a placa Intel Galileo. Os resultados obtidos comprovam que a ideia em organizar conjuntos de dados pode apoiar tomadas de decisões de forma contínua e automática, fazendo o uso dos registros das experiências passadas. Os recursos das ferramentas disponíveis no *software Weka* facilitam a escolha do melhor algoritmo após executar os treinamentos e testes com os conjuntos de dados.

O sistema DDF desenvolvido atuou de acordo com cada etapa estabelecida para avaliação da aprendizagem automática. O algoritmo J48 da árvore de decisão apresentou desempenho satisfatório. A visualização do monitoramento em tempo real, informando e atuando no ar-condicionado de acordo com as premissas do objetivo geral desta dissertação, comprova que o sistema DDF é capaz de analisar e otimizar dados de produção *on-line* alinhados com os dados *off-line* extraídos das fichas técnicas.

7. Considerações Finais

Os estudos detalhados dos conceitos de detecção e diagnóstico de falha foram etapas fundamentais para a consolidação do trabalho e formaram a base para todo o desenvolvimento do projeto. Verificou-se que há um grande número de publicações sobre o uso de sistema de DDF, mas poucos referem-se em aplicações para equipamentos domésticos convencionais.

O trabalho demonstrou como o dispositivo DDF pode ser aplicado em aparelhos eletrodomésticos convencionais, também demonstrou a capacidade em auxiliar nos procedimentos de manutenção através dos diagnósticos. Foi proposta uma nova abordagem para o problema através do aprendizado de máquina automático, envolvendo o paradigma árvore de decisão com o algoritmo J48. Verificou-se o bom desempenho desse algoritmo através dos acertos nas situações impostas nas etapas dos experimentos realizados no estudo de caso.

Na seção 2.2, trabalhos relacionados, verificou-se o trabalho proposto por Braun (2009), suas análises são voltadas para um sistema de detecção de falha em equipamentos de ar-condicionado de grande capacidade de refrigeração e com sensores invasivos em pontos estratégicos para verificação de vazamento de gás refrigerante e válvulas de controle. A proposta do sistema DDF com o uso de aprendizagem automática através de sensores não invasivos apresenta uma abordagem diferente, principalmente, na sua aplicação em equipamentos de usos domésticos convencionais. As análises das propostas apresentadas em trabalhos anteriores foi determinante para a implementação da aprendizagem automática, principalmente relacionadas aos parâmetros a serem adotados e o modelo DDF mais adequado à proposta da dissertação.

O sistema DDF projetado teve sua avaliação verificada através da implementação do protótipo em um ambiente com parâmetros reais. Seu desempenho é avaliado através do acesso remoto via internet, sendo possível identificar, em tempo real, as condições operacionais do ar condicionado modelo convencional, verifica-se a condição ligado ou desligado, acompanha o comportamento das variáveis durante o funcionamento do ar condicionado, possui histórico dos diagnósticos das falhas, atua automaticamente no desligamento do ar-condicionado para os casos específicos selecionados com diagnósticos que resultam em danos aos equipamentos ou até no desperdício de energia elétrica.

O sistema DDF desenvolvido e implementado atendeu aos requisitos desejados, produzindo resultados satisfatórios de acordo com a proposta desta dissertação.

7.1 Trabalhos Futuros

A partir dos sensores não invasivos utilizados e da aprendizagem automática aplicada, outros equipamentos que não possuem características de usos domésticos podem experimentar o uso deste método, assim, será possível avaliar o dispositivo DDF com outros parâmetros e principalmente com experimentações de falhas em tempo real, sempre observando as tolerâncias fornecidas através das fichas técnicas dos fabricantes.

Para ambientes com maior capacidade de refrigeração que utilizam ar-condicionado não convencionais, a carga térmica residente e flutuante no ambiente é sempre um desafio para os ajustes de temperatura de acordo com a população presente no ambiente. Homens e mulheres possuem diferentes taxas metabólicas que resultam nas diferenças das temperaturas, estas diferenças são fundamentais na definição do conforto térmico do ambiente. A participação não invasiva de uma câmera com lente grande angular para visualização de toda área abrangente em busca da presença de homens e mulheres pode resultar em estudos mais avançados em determinar a temperatura média ideal de acordo com a predominância da ocupação do ambiente, resultando em ajustes automáticos de temperatura em função da variação de ocupação e conseqüentemente carga térmica gerada.

Algoritmos relacionados com visão computacional podem participar destas melhorias associadas com técnicas de identificação de imagens. É importante lembrar que, nos escritórios onde surgem a maior parte dos debates, os homens são geralmente obrigados a usarem roupas mais fechadas, como os ternos, por exemplo, enquanto as mulheres podem usar saias e vestidos tranquilamente. E isto faz toda a diferença quando o assunto é sentir calor ou frio.

Referências Bibliográficas

AFGAN, NH.; RADANOVIC, L.M.; TIKHONOV, A. I. SRMES: an expert system for performance analysis of small refrigerating machines. *Int. J. Refere.* Vol. 17, 2014.

BREMEIER, M.; BANZHAF, W. A comparison of Linear Genetic Programming and Neural Networks in medical data Mining, 2001. *Evolutionary Computation, IEEE Transations* 5 (1):17-26.

BRAUN, J.E.; COMSTOCK, M.C. Literature review for application of fault Detection and diagnostic methods to vapor Compression cooling equipment. ASHRAE Deliverable for Research Project 1043-RP. Fault Detection an Diagnostic (FDD) requirements and Evolution Tools for Chillers. HL 99-19 Report#4036-2.2009.

BERRY, Michael J. A., LINOFF, Gordon. *Mineração de dados techniques: for marketing, sales and customer support.* USA: Wiley Computer Publishing, 1997.

BASÍLIO, J. C.,Carvalho, L. K. E Moreira, M. V. Diagnose de falhas em sistemas a eventos discretos modelados por automatos finitos, *Revista Controle & Automação (Impresso)*, v. 21, p. 510-533, 2010.

CARVALHO, André. *Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina.* 1 Ed. São Paulo: LTC, 2011.

COPPIN, Ben. *Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina.* 1 Ed. São Paulo: LTC, 2010.

CHENG, C. W.; YAO, H. Q.; WU, T. C. (2013); Applying data mining techniques to analyze the causes of major occupational accidents in the petrochemical industry. *Journal of Loss Prevention in the Process Industries*, v. 26, p. 1269-1278.

CHIANG, L. H.; KOTANCHEK, M. E.; KORDON, A. K. Fault diagnosis based on Fisher discriminant analysis and support vector machines. *Computers & Chemical Engineering*, v. 28, p. 1389-1401, 2004.

D. J. Cook,; M. Young blood, E. O. Heierman, K. Gopalratnam, S. Rao, A. Litvin and F. Khawaja, "MavHome: An Agent-Based Smart Home PERCOM '03", *Proceedings of the First IEEE International Conference on Pervasive Computing and Communications*, (2003), pp. 521-524.

FRANK, P. M.; GARCIA, E. A.; Kopper-Seliger, B. Modelling for fault detection and isolation versus modelling for control. *Mathematics and Computers in Simulation*, v. 53, p. 259-271, 2014.

FAYYAD, U; PIATETSKY-Shapiro, G; Smyth, P. From Data Mining to Knowledge Discovery in Databases. American Association for Artificial Intelligence, 1996.

FACELI, Katti. Inteligência Artificial: Uma abordagem de aprendizagem de Máquina, Rio de Janeiro: LTC, 2011.

GERTLER, J. J. Survey of model-based failure detection and isolation in complex plants. IEEE Control Systems Magazine, v. 8, p. 3-11, 198, 2013.

GOLDSCHMIDT, R.; Passos, E. Data mining: um guia prático, conceitos, técnicas, ferramentas, orientações e aplicações. 1. ed. Rio de Janeiro, RJ: Elsevier, 2005.

GANYUN, L. V.; Cheng, H. Z.; Zhai, H. B.; Dong, L. X Fault diagnosis of power transformer based on multilayer SVM classifier. Electric Power Systems Research, v. 74, p. 1-7, 2005.

GRIMMELIUS, H. T.; WOUND, J. K.; BEEN, G. On-line Failure Diagnostic for Compression Refrigeration Plants, International Journal of Refrigeration, Vol. 18, No. 1, pp. 31-41, 2015.

HAN, J.; KAMBER, M; Data Mining: Concepts and Techniques, ed. 1, Nova York: Morgan Kaufmann 2012.

HAN, J. e KAMBER, M. (2006), Data Mining: Concepts and Techniques, Morgan Kaufmann Publishers, 2nd edition.

ISERMANN, R. Fault-diagnosis systems, introduction from fault detection to fault tolerance. Springer, Berlin, Germany, 2006.

J. Mark. H; EIBE, F. Geoffrey H. Pfahringer B, Reutemann P, Witten IH. The weka data mining software: update. ACM SIGKDD.2014.

J. Castillo and T. Edgar, "Model Based Fault Detection and Diagnosis." TWCCC – Texas – Wisconsin – California Control Consortium, Texas, 2010, pp 1-10.

KITTS, C., "Managing Space System Anomalies Using First Principles Reasoning". IEEE Robotics and Automation Magazine, Special Issue on Automation Science, v 13, n 4, pp. 39-50. 2006.

LUGER, George. Inteligência artificial. 6 Ed. São Paulo: Pearson, 2014.

LEMOS, E.P., Análise de Crédito Bancário com uso de Data Mining: Redes Neurais e Árvores de decisão, Curitiba, 2003. Tese (Mestrado em Ciências) – Departamento de Matemática, Universidade Federal do Paraná.

LAFRAIA, J. R. B. Manual de confiabilidade, manutenibilidade e disponibilidade. 2a Edição. Rio de Janeiro: Qualitymark, 2014.

M. Sama, D. S.; ROSENBLUM, Z. M.; WANG, and S. Elbaum, “Modelbased fault detection in context-aware adaptive applications,” in Proceedings of 16th ACM SIGSOFT International Symposium on the Foundations of Software Engineering, pp. 261-271, 2008.

MELO, M.D. Introdução à Mineração de Dados usando o Weka. V CONNEPI-2010.

OZYURT, B.; KANDEL, A. A hybrid hierarchical neural network-fuzzy expert system approach to chemical process fault diagnosis. Fuzzy sets and systems. v. 83, n. 1, p. 11-25, 2010.

PORTAL AR CONDICIONADO, Web Ar condicionado. Disponível:
<http://www.webarcondicionado.com.br/a-historia-do-ar-condicionado>.
Acesso em 03 Abril 2017.

PORTAL ELETRODOMÉSTICOS, Zoom. Disponível em:
<<https://www.zoom.com.br/ar-condicionado/convencional>> .Acesso em 3 abril.2017.

PORTAL AR CONDICIONADO, Springer. Disponível em:
<<http://www.springer.com.br/pt/modelo/descricao/16>>. Acesso em 03 abril.2017.

PORTAL ELETRÔNICOS, FelipeFlop. Disponível em:
<<http://www.filipeflop.com/>>. Acesso em abril.2017.

PORTAL ELETRODOMÉSTICOS, Zoom. Disponível em:
<<https://www.zoom.com.br/microondas/convencional>> .Acesso em 3 abril.2017.

PORTAL EDUCAÇÃO. University Pittsburgh. Disponível em:
<http://www.pitt.edu/genie>. Acesso em 06 abril 2017.

PORTAL AR CONDICIONADO. ASHARE. Disponível em:
<https://elearning.ashrae.org>. Acesso em 27 março 2017.

RAMACHANDRAN, K. I. Fault diagnostics of roller bearing using kernel based neighborhood score multi-class support vector machine. Expert Systems with Applications, v. 34, p. 3090-3098, 2008.

SIMON, H. E. Search and reasoning in problem solving. Artificial Intelligence 21, 7-29. 1983.

SHELL, J., Coupland, S., and Goodyer, E. N. (2010). “Fuzzy data fusion for fault detection in wireless sensor networks”. Computer. IEEE.

T.M. Mitchell. Machine Learning. McGraw – Hill Science/ Engineering / Math, 432 páginas ISBN 0070428077, 1997.

TAN, P.; STEINBACH, M., Kumar, V. 2009. Introdução ao Data Mining – Mineração de Dados. Rio de Janeiro: Editora Ciência Moderna Ltda.

UNIVERSITY OF WAIKATO. Weka 3 – Machine Learning Software in Java. Disponível no site da University of Waikato (2010). URL: <http://www.cs.waikato.ac.nz/ml/weka>>. Acesso em março.2017.

VENKATASUBRAMANIAN, V.; Rengaswamy, R.;Kavuri, S. N.; Yin, K. W. A review of process faultdetection and diagnosis Part III: Process history based methods. Computers and Chemical Engineering, v. 27,p. 327-326, 2003.

WANG, Y. J; XIN, Q; COENEN, F. Mining efficiently significant classification association rules. In: STUDIES IN COMPUTATIONAL INTELLIGENCE, p. 443U” 467.Springer-Verlag, 2008.

Apêndice A – Publicações

SEABRA, Jorge da Costa; JUNIOR, Mário Costa; FERREIRA, Mateus Lucena. “IoT based Intelligent System for Fault Detection and Diagnosis in Domestic Appliances”, aceito no ICCE Berlim V30 - Conferência Internacional de Consumidores Eletrônicos – 6ª IEEE (4 – 7 Setembro 2016).

SEABRA, Jorge da Costa; JUNIOR, Mário Costa; FERREIRA, Mateus Lucena. “Sistema Inteligente baseado em IoT para Detecção e Diagnóstico de Falha em Equipamentos de uso Doméstico”, publicado nos anais no SBRC - Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos (SBRC), A 34ª edição do Simpósio realizada de 30 de maio a 3 de junho em Salvador, Bahia.

Apêndice B – Conjuntos dataset *arff. Base -1 e Base -2

```

@RELATION ddfarcondicionado
@ATTRIBUTE Tensão NUMERIC
@ATTRIBUTE Corrente NUMERIC
@ATTRIBUTE Temp-externa NUMERIC
@ATTRIBUTE Temp-sala NUMERIC
@ATTRIBUTE Temp-insuflamento NUMERIC
@ATTRIBUTE Porta NUMERIC
@ATTRIBUTE Presença NUMERIC
@ATTRIBUTE Vibração NUMERIC
@ATTRIBUTE Diagnóstico {normal,anormal,sobretensão,subtensão,sobrecorrente,vibração,interrupção}

@DATA

% Observações:
% Relacionamos os dados das variáveis para os atributos da Classe
% "Diagnóstico da performance do aparelho ar condicionado".

% Dados referências do fabricante Ar condicionado CARRIER - MODELO FCA0788B
% A tensão da rede em faixa nominal é de 127V, os limites são 135V máximo e 105V mínimo
% A corrente nominal do aparelho de ar condicionado em funcionamento é de 6,5A a 7,5A em condições normais.
% A temperatura externa variando entre 30 graus Celsius a 45 graus Celsius para cidade de Manaus/AM.
% A temperatura da sala varia entre 25 graus Celsius a 38 graus Celsius sem ar condicionado.
% 0 atributo porta aberta consideramos 1 = porta fechada, 0 = porta aberta.
% 0 atributo presença consideramos 1 = presença de pessoas na sala, 0 = ausência de pessoas.
% 0 atributo vibração consideramos 1 = vibração, 0 = sem vibração.

126,7.152,32.746,29.325,28.347,1,1,0,normal
127,7.13,30.303,23.46,18.84,1,1,0,normal
120,7.123,31.769,29.325,27.37,1,0,0,normal
123,6.993,30.791,23.46,17.595,0,1,0,normal
122,6.978,27.37,23.46,18.84,0,1,0,normal
125,6.973,30.791,23.949,18.572,0,0,0,anormal
118,6.968,28.836,23.46,17.595,1,1,1,vibração
96,6.968,28.836,23.46,17.595,1,1,0,subtensão
138,6.978,27.37,23.46,18.84,0,0,0,sobretensão
126,26.152,32.746,29.325,28.347,1,1,0,sobrecorrente
126,26.152,32.746,29.325,28.347,1,1,1,interrupção
138,6.978,27.37,23.46,18.84,0,0,1,interrupção

|
@RELATION ddfarcondicionado
@ATTRIBUTE Tensão NUMERIC
@ATTRIBUTE Corrente NUMERIC
@ATTRIBUTE Temp-externa NUMERIC
@ATTRIBUTE Temp-sala NUMERIC
@ATTRIBUTE Temp-insuflamento NUMERIC
@ATTRIBUTE Porta-aberta NUMERIC
@ATTRIBUTE Presença NUMERIC
@ATTRIBUTE Vibração NUMERIC
@ATTRIBUTE Diagnóstico {normal,filtro,sobretensão,subtensão,compressor,vibração,ausência}

@DATA

% Observações:
% Relacionamos os dados das variáveis para os atributos da Classe
% "Diagnóstico da performance do aparelho ar condicionado".
% Dados referências do fabricante Ar condicionado CARRIER - MODELO FCA0788B
% A tensão da rede em faixa nominal:127V ; limites: 135V máximo e 105V mínimo
% A corrente nominal do aparelho de ar condicionado em funcionamento:6,A a 7,5A.
% A temperatura externa variando entre 30 graus Celsius a 45 graus Celsius.
% A temperatura da sala varia entre 25 graus Celsius a 38 graus Celsius sem ar condicionado.
% 0 atributo porta aberta: 1 = porta fechada, 0 = porta aberta.
% 0 atributo presença: 1 = presença de pessoas na sala, 0 = ausência de pessoas.
% 0 atributo vibração 1 = vibração, 0 = sem vibração.

126,7,32,24,16,1,1,0,normal
127,7,30,23,23,1,1,0,filtro
124,7,32,23,14,1,1,0,normal
126,7,32,24,16,1,1,0,normal
126,7,32,24,15,1,1,0,normal
100,7,31,29,27,1,0,0,subtensão
124,7,32,23,14,1,1,0,normal
126,7,32,24,16,1,1,0,normal
126,7,32,24,15,1,1,0,normal
140,6,30,23,17,0,1,0,sobretensão
124,7,32,23,14,1,1,0,normal
126,7,32,24,16,1,1,0,normal
126,7,32,24,15,1,1,0,normal
122,16,27,23,18,0,1,0,compressor
124,7,32,23,14,1,1,0,normal
126,7,32,24,16,1,1,0,normal
126,7,32,24,15,1,1,0,normal
125,6,30,23,18,0,0,1,vibração
124,7,32,23,14,1,1,0,normal
126,7,32,24,16,1,1,0,normal
126,7,32,24,15,1,1,0,normal
118,6,28,23,17,0,0,1,ausência
125,7,32,22,16,1,1,0,normal
124,7,32,23,14,1,1,0,normal
127,7,32,24,16,1,1,0,normal
126,7,32,24,15,1,1,0,normal
123,16,27,23,18,0,1,0,compressor
125,7,32,23,14,1,1,0,normal

```

Apêndice C – Códigos: Banco de dados, sensores e comunicações PHP

```

#include <stdio.h>
#include <stdlib.h>
#include <sqlite3.h>

static int callback(void *data, int argc, char **argv, char **azColName){
    int i;
    fprintf(stderr, "%s: ", (const char*)data);
    for(i=0; i<argc; i++){
        printf("%s = %s\n", azColName[i], argv[i] ? argv[i] : "NULL");
    }
    printf("\n");
    return 0;
}

int main(int argc, char* argv[])
{
    sqlite3 *db;
    char *zErrMsg = 0;
    int rc;
    char *sql;
    const char* data = "Callback function called";

    /* Open database */
    rc = sqlite3_open("/DataBaseJSeabra/jSeabraDB.db", &db);
    if( rc ){
        fprintf(stderr, "Can't open database: %s\n", sqlite3_errmsg(db));
        exit(0);
    }else{
        fprintf(stderr, "Opened database successfully\n");
    }

    /* Create SQL statement */
    sql = "SELECT * from jseabra";

    /* Execute SQL statement */
    rc = sqlite3_exec(db, sql, callback, (void*)data, &zErrMsg);
    if( rc != SQLITE_OK ){
        fprintf(stderr, "SQL error: %s\n", zErrMsg);
        sqlite3_free(zErrMsg);
    }else{
        fprintf(stdout, "Operation done successfully\n");
    }
    sqlite3_close(db);
    return 0;
}

```

```

#include <stdio.h>
#include <string.h>
#include <stdlib.h>
#include <sqlite3.h>

static int callback(void *data, int argc, char **argv, char **azColName){
    int i;
    fprintf(stderr, "%s: ", (const char*)data);
    for(i=0; i<argc; i++){
        printf("%s = %s\n", azColName[i], argv[i] ? argv[i] : "NULL");
    }
    printf("\n");
    return 0;
}

int main(int argc, char* argv[])
{
    if( argc!=11 ){
        fprintf(stderr, "Usage: %s Tensao Corrente TempInterna TempExterna TempInsulflamento Porta Rele\n", argv[0]);
        return(1);
    }

    sqlite3 *db;
    char *zErrMsg = 0;
    int rc;
    char sql[500] = "";
    const char* data = "Callback function called";

    /* Open database */
    rc = sqlite3_open("/DataBaseJSeabra/jSeabraDB.db", &db);
    if( rc ){
        fprintf(stderr, "Can't open database: %s\n", sqlite3_errmsg(db));
        exit(0);
    }else{
        fprintf(stderr, "Opened database successfully\n");
    }
}

```

.OP point found by inspection.

Date: Thu Jan 07 06:14:59 2016
Total elapsed time: 0.073 seconds.

```

tnom = 27
temp = 27
method = modified trap
totiter = 2139
traniter = 2139
tranpoints = 1049
accept = 1048
rejected = 1
matrix size = 7
fillins = 1
solver = Normal
Matrix Compiler1: 304 bytes object code size 0.4/0.4/[0.4]
Matrix Compiler2: 475 bytes object code size 0.3/0.4/[0.3]

```