



ESCOLA NAVAL



ta sãntõr õ bñ-faire

Daniel Santos Baptista

Avaliação de Falha em Sistemas de Refrigeração *Uso do método de Dempster-Shafer*

Dissertação para obtenção do Grau de Mestre em
Ciências Militares Navais, na especialidade de Engenharia
Naval - Ramo de Mecânica




Alfeite
2022



ESCOLA NAVAL

talant de bi-faire



Daniel Santos Baptista

*Avaliação de Falha em Sistemas de Refrigeração
Uso do método de Dempster-Shafer*

Dissertação para obtenção do Grau de Mestre em
Ciências Militares Navais, na especialidade de Engenharia Naval - Ramo
de Mecânica

Orientação de: Prof. Doutor Miguel Cavique Santos

O Aluno Mestrando,

O Orientador,

ASPOF Daniel Santos Baptista

Prof. Doutor Miguel Cavique Santos

Alfeite

2022

"Plans are nothing. Planning is everything."

Dwight D. Eisenhower

Aos que querem passar *além* do Bojador

Agradecimentos

Agradeço a todos que me acompanharam durante a Escola Naval. A dissertação de mestrado é o culminar dos cinco anos de aprendizagem e experiência, mas não é o produto de todos os momentos partilhados.

Agradeço, profundamente, ao meu orientador Professor Doutor Miguel Cavique pela disponibilidade, acompanhamento, motivação e apoio ao longo da realização desta dissertação, e por todos os ensinamentos e experiências ao longo do curso.

Agradeço ao corpo docente do Departamento de Ciências e Tecnologias por todo o conhecimento transmitido ao longo dos cinco anos.

Agradeço aos meus camaradas da Escola Naval pela amizade, pela camaradagem e pela união como Classe, como Curso e como Corpo de Alunos.

Agradeço à minha família por todo o apoio, força, inspiração e paciência.

Agradeço ao meu pai, por tudo.

Resumo

Uma das primeiras aplicações da Teoria de Dempster-Shafer - *Dempster-Shafer Theory* (DST) como método de abdução de sintomas aplicado a falhas em sistemas de refrigeração é apresentada nesta dissertação. A metodologia proporciona uma estrutura de desenvolvimento de novos métodos de Detecção e Diagnóstico de Falhas - *Fault Detection and Diagnosis* (FDD) apoiados pela DST.

O estudo de um sistema de refrigeração, como sistema complexo, permite a aplicação de um algoritmo de FDD. A detecção antecipada de condições de falha é usada em manutenção preventiva. A Análise de Modos de Falha e Efeitos - *Failure Mode and Effects Analysis* (FMEA) permite discriminar e priorizar possíveis modos de falha de modo a selecionar falhas adequadas à FDD. Os Conjuntos Difusos - *Fuzzy Sets* (FS) definem funções de pertinência que melhor caracterizam o estado de um parâmetro face a uma avaliação em detrimento da definição de um limiar de valores discretos. A quantificação do desvio de um parâmetro analisado é resultado do sistema de inferência construído. A Inteligência Artificial - *Artificial Intelligence* (AI) é uma ferramenta que permite ajustar modelos de sistemas complexos, suportados por conhecimento especialista conforme novas entradas de dados.

A DST é uma teoria para o tratamento de incerteza em ambientes de informação incompleta ou ambígua que considera dois limites para a possibilidade dos acontecimentos: a crença e a plausibilidade. O programa materializa um raciocínio de abdução em vez de dedução. Às causas associam-se sintomas. A aquisição de dados pode evidenciar sintomas. As causas são determinadas com base em valores probabilísticos para cada condição de falha possível.

A regra de combinação de evidências da DST permite considerar e combinar duas ou mais fontes de informação. A compilação de pequenos indícios que não dão alarmes ou pré-alarmes podem ser combinados para identificar situações anormais.

Palavras-chave: Sistemas de Refrigeração, Detecção e Diagnóstico de Falhas, Teoria de Dempster-Shafer, Conjuntos Difusos

Abstract

One of the first applications of the DST as a symptom abduction method applied to failures in refrigeration systems is presented in this dissertation. The methodology provides a framework for developing new FDD methods supported by the DST.

The study of a refrigeration system, as a complex system, allows the application of a FDD algorithm. Early detection of fault conditions is used in preventive maintenance. The Failure Mode and Effects Analysis (FMEA) allows the discrimination and prioritization of possible failure modes in order to select faults suitable for FDD. Fuzzy Sets (FS) define membership functions that better characterize the state of a parameter in the face of an evaluation, rather than defining a threshold of discrete values. The quantification of the deviation of an analyzed parameter is a result of the built inference system. Artificial Intelligence (AI) is a tool that allows you to adjust models of complex systems, supported by expert knowledge, according to new data inputs.

The Dempster-Shafer Theory (DST) is a theory for the treatment of uncertainty in environments of incomplete or ambiguous information that considers two limits to the possibility of events: belief and plausibility. The program materializes abduction reasoning instead of deduction. The causes are associated with symptoms. Data acquisition may highlight symptoms. Causes are determined based on probabilistic values for each possible failure condition.

The DST combination rule of evidence allows the consideration and combination of two or more sources of information. The compilation of small pieces of evidences that do not trigger alarms or pre-alarms can be combined to identify unusual situations.

Keywords: Refrigeration Systems, Fault Detection and Diagnosis, Dempster-Shafer Theory, Fuzzy Sets

Índice

| | |
|--|-----------|
| Introdução | 1 |
| 1 Sistemas de Climatização | 3 |
| 1.1 Ciclos de Refrigeração | 3 |
| 1.2 Componentes de um Sistema de Refrigeração | 5 |
| 1.2.1 Compressor | 6 |
| 1.2.2 Permutadores de Calor | 6 |
| 1.2.3 Dispositivo Expansor | 9 |
| 1.3 Tipificação de Avarias | 10 |
| 1.3.1 Compilação de falhas no estudo ASHRAE | 10 |
| 1.3.2 Implementação de falhas no estudo ASHRAE | 12 |
| 1.3.3 Aplicação da Análise de Modos de Falha e Efeitos | 16 |
| 1.4 Sistemas de Refrigeração | 19 |
| 1.4.1 Navios de Patrulha Oceânicos | 19 |
| 1.4.2 Instalação de Teste | 21 |
| 2 Métodos de Detecção e de Diagnóstico de Falhas | 25 |
| 2.1 Sistemas Periciais | 25 |
| 2.2 Detecção e Diagnóstico de Falhas | 28 |
| 2.3 Teoria de Dempster-Shafer | 37 |
| 2.3.1 Teoria de Bayes | 38 |
| 2.3.2 Fundamentos da Teoria de Dempster-Shafer | 39 |
| 2.3.3 Combinação de Evidências | 41 |
| 3 Modelo | 45 |
| 3.1 Fundamentos Teóricos | 45 |
| 3.1.1 Aplicação da Teoria de Dempster-Shafer | 46 |
| 3.1.2 Aplicação dos Conjuntos Difusos | 51 |
| 3.2 Programa | 53 |
| 3.2.1 Aquisição e Estrutura de Dados | 56 |

| | | |
|------------|--|------------|
| 3.2.2 | Pré-Processamento de Dados | 57 |
| 3.2.3 | Processamento de Dados | 58 |
| 3.2.4 | Sistema de Inferência Difuso | 60 |
| 3.2.5 | Motor Dempster-Shafer | 64 |
| 3.2.6 | Gráficos de saída | 69 |
| 4 | Resultados e Discussão | 71 |
| 4.1 | Simulação de Falhas | 71 |
| 4.2 | Diagnósticos Obtidos | 72 |
| 4.3 | Avaliação de Desempenho | 77 |
| 5 | Conclusões | 81 |
| 5.1 | Trabalhos Futuros | 83 |
| | Bibliografia | 85 |
| | Apêndices | 89 |
| A | Análise de Modos de Falha e Efeitos | 89 |
| B | Lógica Difusa | 95 |
| B.1 | Conjuntos Difusos | 95 |
| B.2 | Funções de Pertença | 96 |
| C | Resultados da detecção e diagnóstico de falhas | 103 |
| D | Programa de detecção e de diagnóstico de falhas | 147 |
| | Anexos | 183 |
| I | Parâmetros recolhidos do sistema <i>AERNET</i> | 183 |
| II | Estruturas DS com base em conhecimento especialista | 187 |
| III | Estruturas DS adaptadas ao programa | 191 |
| IV | Artigo ICMECE 2022 | 195 |

Lista de Figuras

| | | |
|-----|---|----|
| 1.1 | Ciclo de Rankine, extraído de Cengel et al. (2011) | 4 |
| 1.2 | Ciclo de refrigeração real, extraído de Cengel et al. (2011) | 5 |
| 1.3 | Permutador <i>shell-and-tube</i> de expansão direta, extraído de ASHRAE (2008) | 8 |
| 1.4 | Permutador inundado <i>shell-and-tube</i> , extraído de ASHRAE (2008) | 8 |
| 1.5 | Resultados do inquérito do estudo por Comstock et al. (1999) | 12 |
| 1.6 | Circuito de refrigerante do sistema ANL H 081, extraído do manual da <i>AERMEC</i> | 23 |
| 1.7 | Circuito hidráulico do sistema ANL H 081, extraído do manual da <i>AERMEC</i> | 24 |
| 3.1 | Fluxograma do programa desenvolvido | 54 |
| 3.2 | Função polinomial para interpolação | 60 |
| 3.3 | Funções de Pertença Difusas para a avaliação dos quatro parâmetros | 61 |
| 3.4 | Funções de Pertença Difusas para a obtenção do valor de saída | 61 |
| 3.5 | Exemplo - Sistema de Inferência Difuso (1) | 62 |
| 3.6 | Exemplo - Sistema de Inferência Difuso (2) | 63 |
| 3.7 | Fluxograma da função de combinação de estruturas | 66 |
| 4.1 | Diagnóstico de falha de dia 24 de junho (3 ^o grafo) | 74 |
| 4.2 | Diagnóstico de falha de dia 27 de junho (1 ^o grafo) | 74 |
| 4.3 | Diagnóstico de falha de dia 28 de junho (1 ^o grafo) | 75 |
| 4.4 | Diagnóstico de falha de dia 29 de junho (1 ^o grafo) | 75 |
| 4.5 | Diagnóstico de falha de dia 7 de julho (1) (3 ^o grafo) | 76 |
| 4.6 | Diagnóstico de falha de dia 7 de julho (2) (3 ^o grafo) | 76 |
| 4.7 | Diagnóstico de falha de dia 7 de julho (4) (1 ^o grafo) | 77 |
| A.1 | Escala de critérios para atribuição de um valor de severidade, extraído de Mikulak et al. (2017) | 91 |
| A.2 | Escala de critérios para atribuição de um valor de probabilidade de ocorrência, extraído de Mikulak et al. (2017) | 92 |

| | | |
|------|--|-----|
| A.3 | Escala de critérios para atribuição de um valor de detetabilidade e reparação (1), extraído de Mikulak et al. (2017) | 93 |
| A.4 | Escala de critérios para atribuição de um valor de detetabilidade e reparação (2), extraído de Mikulak et al. (2017) | 94 |
| B.1 | Exemplo das quatro funções de pertença | 99 |
| B.2 | Funções de pertença de saturação | 100 |
| B.3 | Funções de pertença para valores linguísticos compostos | 101 |
| B.4 | Efeito das operações no contraste das funções de pertença | 102 |
| C.1 | Diagnóstico de falha de dia 24 de junho | 103 |
| C.2 | Diagnóstico de falha de dia 27 de junho | 104 |
| C.3 | Diagnóstico de falha de dia 28 de junho | 105 |
| C.4 | Diagnóstico de falha de dia 29 de junho | 106 |
| C.5 | Diagnóstico de falha de dia 30 de junho | 107 |
| C.6 | Diagnóstico de falha de dia 1 de julho | 108 |
| C.7 | Diagnóstico de falha de dia 4 de julho | 109 |
| C.8 | Diagnóstico de falha de dia 5 de julho (1) | 110 |
| C.9 | Diagnóstico de falha de dia 5 de julho (2) | 111 |
| C.10 | Diagnóstico de falha de dia 6 de julho (1) | 112 |
| C.11 | Diagnóstico de falha de dia 6 de julho (2) | 113 |
| C.12 | Diagnóstico de falha de dia 7 de julho (1) | 114 |
| C.13 | Diagnóstico de falha de dia 7 de julho (2) | 115 |
| C.14 | Diagnóstico de falha de dia 7 de julho (3) | 116 |
| C.15 | Diagnóstico de falha de dia 7 de julho (4) | 117 |
| C.16 | Diagnóstico de falha de dia 8 de julho (1) | 118 |
| C.17 | Diagnóstico de falha de dia 8 de julho (2) | 119 |
| C.18 | Diagnóstico de falha de dia 8 de julho (3) | 120 |
| C.19 | Diagnóstico de falha de dia 8 de julho (4) | 121 |
| C.20 | Diagnóstico de falha de dia 8 de julho (5) | 122 |
| C.21 | Diagnóstico de falha de dia 8 de julho (6) | 123 |
| C.22 | Diagnóstico de falha de dia 11 de julho (1) | 124 |
| C.23 | Diagnóstico de falha de dia 11 de julho (2) | 125 |
| C.24 | Diagnóstico de falha de dia 11 de julho (3) | 126 |
| C.25 | Diagnóstico de falha de dia 12 de julho (1) | 127 |
| C.26 | Diagnóstico de falha de dia 12 de julho (2) | 128 |
| C.27 | Diagnóstico de falha de dia 12 de julho (3) | 129 |
| C.28 | Diagnóstico de falha de dia 13 de julho (1) | 130 |

| | |
|--|-----|
| C.29 Diagnóstico de falha de dia 13 de julho (2) | 131 |
| C.30 Diagnóstico de falha de dia 13 de julho (3) | 132 |
| C.31 Diagnóstico de falha de dia 13 de julho (4) | 133 |
| C.32 Diagnóstico de falha de dia 14 de julho (1) | 134 |
| C.33 Diagnóstico de falha de dia 14 de julho (2) | 135 |
| C.34 Diagnóstico de falha de dia 14 de julho (3) | 136 |
| C.35 Diagnóstico de falha de dia 15 de julho (1) | 137 |
| C.36 Diagnóstico de falha de dia 15 de julho (2) | 138 |
| C.37 Diagnóstico de falha de dia 15 de julho (3) | 139 |
| C.38 Diagnóstico de falha de dia 18 de julho (1) | 140 |
| C.39 Diagnóstico de falha de dia 18 de julho (2) | 141 |
| C.40 Diagnóstico de falha de dia 19 de julho (1) | 142 |
| C.41 Diagnóstico de falha de dia 19 de julho (2) | 143 |
| C.42 Diagnóstico de falha de dia 20 de julho | 144 |
| C.43 Diagnóstico de falha de dia 21 de julho | 145 |
| IV.1 Carta de aceitação | 195 |

Lista de Tabelas

| | | |
|------|---|----|
| 1.1 | Condições de projeto do sistema dos NPOs | 20 |
| 1.2 | Condições limite do sistema dos NPOs | 20 |
| 1.3 | Performance do sistema ANL H 081 | 23 |
| 2.1 | Cálculo dos valores de crença e plausibilidade | 41 |
| 2.2 | Combinação do conjunto 1 e do conjunto 2 | 43 |
| 2.3 | Cálculos da Combinação dos conjuntos | 43 |
| 3.1 | Falhas associadas ao estado de cada parâmetro | 49 |
| 3.2 | Falhas e massas de probabilidade de cada parâmetro | 50 |
| 3.3 | Resultado provável da combinação de evidências | 51 |
| 3.4 | Exemplo - Dados de entrada | 57 |
| 3.5 | Dados de entrada - Parâmetros do sistema | 57 |
| 3.6 | Exemplo - Pré-Processamento de Dados | 58 |
| 3.7 | Exemplo - Processamento de Dados (1) | 59 |
| 3.8 | Exemplo - Processamento de Dados (2) | 59 |
| 3.9 | Exemplo - Processamento de Dados (3) | 60 |
| 3.10 | Identificadores de cada estado perante cada parâmetro | 63 |
| 3.11 | Exemplo - Motor Dempster-Shafer (1) | 64 |
| 3.12 | Exemplo - Motor Dempster-Shafer (2) | 65 |
| 3.13 | Exemplo - Motor Dempster-Shafer (3) | 66 |
| 3.14 | Exemplo - Motor Dempster-Shafer (4) | 67 |
| 3.15 | Exemplo - Motor Dempster-Shafer (5) | 68 |
| 4.1 | Exatidão do diagnóstico do programa | 78 |

Lista de Siglas e Acrónimos

| | |
|--------|--|
| AD | Axiomática de Projeto - <i>Axiomatic Design</i> . |
| AFD | Deteção de Falhas Automática - <i>Automatic Fault Detection</i> . |
| AHP | Processo Analítico Hierárquico - <i>Analytical Hierarchy Process</i> . |
| AI | Inteligência Artificial - <i>Artificial Intelligence</i> . |
| ASHRAE | <i>American Society of Heating, Refrigeration and Air-Conditioning Engineers</i> . |
| BEMS | Sistemas de Gestão Energética de Edifícios - <i>Building Energy Management Systems</i> . |
| BN | Rede Bayesiana - <i>Bayesian Network</i> . |
| COP | Coefficiente de Desempenho - <i>Coefficient Of Performance</i> . |
| DBN | Rede Bayesiana de Diagnóstico - <i>Diagnosis Bayesian Network</i> . |
| DS | Dempster-Shafer. |
| DST | Teoria de Dempster-Shafer - <i>Dempster-Shafer Theory</i> . |
| EER | Rácio de Eficiência Energética - <i>Energy Efficiency Ratio</i> . |
| ES | Sistemas Periciais - <i>Expert Systems</i> . |
| FDD | Deteção e Diagnóstico de Falhas - <i>Fault Detection and Diagnosis</i> . |
| FGA | Algoritmo Genético Difuso - <i>Fuzzy Genetic Algorithm</i> . |

| | |
|------|--|
| FMEA | Análise de Modos de Falha e Efeitos - <i>Failure Mode and Effects Analysis</i> . |
| FS | Conjuntos Difusos - <i>Fuzzy Sets</i> . |
| GA | Algoritmo Genético - <i>Genetic Algorithm</i> . |
| HVAC | Aquecimento, Ventilação e Ar Condicionado - <i>Heating, Ventilation and Air Conditioning</i> . |
| MCDM | Tomada de Decisão de Múltiplos Critérios - <i>Multi Criteria Decision Making</i> . |
| ML | <i>Machine Learning</i> . |
| NPOs | Navios de Patrulha Oceânicos. |
| PCA | Análise de Componentes Principais - <i>Principal Component Analysis</i> . |
| PLS | Mínimos Quadrados Parciais - <i>Partial Least Squares</i> . |
| RPN | Número de Prioridade de Risco - <i>Risk Priority Number</i> . |
| SVM | Máquina de Vetor de Suporte - <i>Support Vector Machine</i> . |

Introdução

Um sistema de refrigeração é um sistema essencial nos navios, que permite retirar calor de um espaço e libertá-lo para outro espaço a uma temperatura mais elevada, através de um ciclo de refrigeração. Refrigera o ar interior, climatizando os espaços. Requer frequente monitorização e manutenção competente visto que a falha do sistema ou de dos seus componentes pode revelar-se vital para o navio e impactante para a missão.

É fundamental que o sistema trabalhe dentro dos parâmetros nominais, o desvio destes parâmetros pode evidenciar uma futura situação de alarmes. No entanto, apenas alguns conjuntos de condições específicas de alarmes podem levar a uma avaria. A previsão de modos de falha é essencial para o diagnóstico de avarias. A diferença entre atuar em manutenção preditiva ou atuar em manutenção preventiva ou corretiva leva a um aumento do tempo de vida útil dos equipamentos e, sobretudo, mantém a operacionalidade dos sistemas.

O objetivo da dissertação é o desenvolvimento de um programa de Detecção e Diagnóstico de Falhas - *Fault Detection and Diagnosis* (FDD) ¹ que preveja condições de funcionamento que possam levar a modos de falha, através do diagnóstico de um conjunto de condições, ativadas pela deteção do desvio dos parâmetros da sua gama de funcionamento nominal. A deteção e diagnóstico de falhas é feita antes de existirem alarmes ou pré-alarmes. Pretende-se estudar um sistema de refrigeração como sistema complexo, identificando relações entre os parâmetros que descrevem o sistema e os respetivos modos de falha.

Nesta dissertação, o estudo dos sistemas de refrigeração é apoiado extensivamente por manuais e estudos da *American Society of Heating, Refrigeration and Air-Conditioning Engineers* (ASHRAE), complementado com outra bibliografia relevante. A revisão dos métodos de FDD, da sua estrutura fundamental e diversas aplicações é feita maioritariamente através de artigos científicos no âmbito no tema. Neste trabalho são utilizadas diversas teorias como a Análise de Modos de Falha e

¹É utilizada a nomenclatura em inglês ao longo da dissertação

Efeitos - *Failure Mode and Effects Analysis* (FMEA), a Teoria de Dempster-Shafer - *Dempster-Shafer Theory* (DST) e os Conjuntos Difusos - *Fuzzy Sets* (FS).

A FMEA é uma estrutura sistemática de avaliação de modos de falha num sistema, com ferramentas que permitem priorizar possíveis modos de falha. A DST é uma teoria probabilística para o tratamento de incerteza em ambientes de informação incompleta ou ambígua que considera dois limites para a possibilidade dos acontecimentos: a crença e a plausibilidade. Os FS permitem a interpretação de valores qualitativos.

As falhas aplicadas ao programa de FDD derivam de uma FMEA aplicada ao sistema de refrigeração. A DST permite construir e combinar estruturas de diagnóstico, baseadas no estado dos parâmetros do sistema, com as causas e respetivas probabilidades associadas a cada condição. Os FS permitem definir funções de pertinência que melhor caracterizem o estado de um parâmetro face a uma avaliação. Neste trabalho os FS servem como filtro de dados de entrada e como adaptadores das massas de probabilidade. Perante os modos de falha identificados pela FMEA, os FS atuam na deteção, enquanto que a DST atua no diagnóstico de falhas.

A DST é utilizada como método de abdução de evidências, frequentemente empregue em medicina, no diagnóstico de doenças perante um conjunto de sintomas, de uma ou mais fontes de informação (opiniões médicas). Esta dissertação apresenta uma das primeiras aplicações da teoria à deteção de falhas por abdução de sintomas. A revisão bibliográfica mostra que não se encontra disponível nenhuma aplicação da DST que trabalhe com conjuntos. A metodologia desenvolvida visa proporcionar uma estrutura para desenvolvimento de futuros métodos de FDD apoiados pela DST. Foi escrito um artigo, *Chiller fault evaluation using Dempster-Shafer theory*, sobre a aplicação da DST na FDD em sistemas de refrigeração para a ICMECE 2022, (Baptista & Cavique, 2022). A metodologia do artigo, apresentado no Anexo IV, é o sumário da metodologia aplicada nesta dissertação e o caso prático discutido é a reflexão dos resultados obtidos para teste e validação. A DST pode ser integrada ou ser parte de um sistema de Inteligência Artificial - *Artificial Intelligence* (AI).

Os primeiros dois capítulos servem como estado da arte, no Capítulo 1 são apresentados os principais conceitos da refrigeração, no Capítulo 2 são revistos os principais métodos de FDD assim como introduzidas as teorias utilizadas no modelo desenvolvido. No Capítulo 3 é descrita pormenorizadamente a metodologia proposta e o respetivo programa de FDD. No Capítulo 4 são apresentados e discutidos os resultados. Por último, no Capítulo 5 são tiradas as conclusões e apresentados os trabalhos futuros.

Capítulo 1

Sistemas de Climatização

1.1 Ciclos de Refrigeração

A refrigeração é o processo de transferência de calor de um corpo ou espaço frio para um espaço quente.

O ciclo de Carnot é o modelo ideal do ciclo de refrigeração, permitindo obter um limite teórico para o funcionamento do ciclo com a máxima eficiência. O ciclo de Rankine é um ciclo mais aproximado da realidade porque se assemelha a um ciclo com compressão, condensação, laminagem e evaporação.

O ciclo de refrigeração é o ciclo de um fluido refrigerante dentro de um sistema de refrigeração. O refrigerante absorve calor de um espaço frio, o espaço a refrigerar, porque se encontra a uma temperatura mais baixa do que o espaço; é comprimido, aumenta a pressão e rejeita calor para um espaço quente, porque se encontra a uma temperatura mais alta. Um sistema de refrigeração por compressão de vapor com um único andar de compressão é constituído por um compressor e um dispositivo expensor e dois permutadores de calor.

O ciclo de refrigeração de Carnot divide-se em quatro processos completamente reversíveis entre duas temperaturas fixas: a temperatura de evaporação T_E e a temperatura de condensação T_C . Quando mais próximas as duas temperaturas estiverem uma da outra, mais eficiente será o ciclo de refrigeração. A compressão e a expansão neste ciclo ideal são processos isentrópicos, a entropia mantém-se constante, e a condensação e a evaporação são processos isotérmicos, a temperatura e pressão mantém-se constantes. (ASHRAE, 2013)

O ciclo de refrigeração de Rankine de compressão de vapor, é descrito na Figura 1.1. O refrigerante absorve e liberta calor em permutadores de calor, no evaporador e no condensador, respetivamente, é comprimido no compressor e expande

na válvula de expansão. A expansão na válvula não é um processo reversível, porque envolve um processo de laminagem do refrigerante.

A diminuição na temperatura de evaporação provoca um aumento no trabalho a realizar no compressor. O aumento da temperatura de condensação provoca um ligeiro aumento no trabalho do compressor e uma diminuição do calor absorvido. Para máxima eficiência, o ciclo deve trabalhar com a temperatura de condensação mais baixa possível e com a temperatura de evaporação mais alta possível. (Cengel et al., 2011)




FIGURA 1.1: Ciclo de Rankine, extraído de Cengel et al. (2011)

O fluido refrigerante é uma combinação de refrigerante e óleo lubrificante. Todos estes desvios do ciclo teórico causam irreversibilidades no sistema, que provocam o aumento do trabalho do compressor. (ASHRAE, 2013) O diagrama de um ciclo real de refrigeração por compressão de vapor é mostrado na Figura 1.2.

Num ciclo ideal, o refrigerante sai do evaporador e entra no compressor como vapor saturado. No entanto, num ciclo real não é possível controlar com precisão o estado do refrigerante. O sistema é projetado para garantir um grau de sobreaquecimento em 8, de modo a que o refrigerante entre no compressor completamente vaporizado em 1. O sobreaquecimento é a absorção de calor por parte do refrigerante mesmo após ter evaporado para o estado gasoso. O sobreaquecimento garante que na linha de aspiração (linha entre o evaporador e o compressor) apenas flui gás, mas quanto menor for o grau de sobreaquecimento, mais eficiente é o sistema de refrigeração. Líquido no compressor pode danificar o compressor devido ao facto do líquido não ser compressível. Uma falha no evaporador, com um compressor hermético, pode originar a perda total do sistema. Na linha de admissão – linha desde a saída do evaporador até a entrada do compressor – a perda de pressão




FIGURA 1.2: Ciclo de refrigeração real, extraído de Cengel et al. (2011)

pode ser significativa, existindo perdas locais na entrada do compressor. As perdas de pressão e o sobreaquecimento resultam no aumento do trabalho do compressor.

À semelhança do processo de evaporação, também é projetado um grau de sub-arrefecimento desejado. No entanto, não controlado, no refrigerante em 5. O sub-arrefecimento é a rejeição de calor por parte do refrigerante mesmo após ter condensado para o estado líquido, o sub-arrefecimento garante que na linha de líquido – linha entre o condensador e o dispositivo expensor – apenas flui líquido. O vapor na linha de líquido pode causar uma diminuição excessiva da pressão e redução da capacidade do sistema. O sub-arrefecimento permite ao refrigerante entrar no evaporador em 6 com uma entalpia mais baixa, e por consequente, absorver mais calor. (Cengel et al., 2011)

1.2 Componentes de um Sistema de Refrigeração

Os principais componentes de um sistema de refrigeração por compressão de vapor são o compressor, os permutadores de calor - o condensador e o evaporador, e o dispositivo expensor. Todos os componentes, incluindo as linhas entre eles e os respectivos sensores estão sujeitos a avarias. Como componentes essenciais de um sistema de refrigeração, a falha de um dos componentes, afeta todos os outros, podendo por em risco a integridade do sistema.

1.2.1 Compressor

O compressor tem a função de aumentar a pressão, fazendo circular o refrigerante no sistema, criando a diferença entre as pressões de condensação e de evaporação. Existem duas categorias principais de compressores: compressores de deslocamento positivo e dinâmicos. Compressores de deslocamento positivo aumentam a pressão do vapor através da redução do volume da câmara de compressão pelo trabalho aplicado pelo compressor. Compressores dinâmicos aumentam a pressão do vapor através de uma transferência contínua de energia cinética dos elementos rotativos do compressor.

Compressores de deslocamento positivo podem ser classificados de várias formas: (1) de um ou múltiplos estágios; (2) pelo tipo de motor – elétrico, hidráulico ou mecânico; (3) pela capacidade de controlo – uma velocidade, velocidade variável (inverter) ou volume da câmara de compressão variável; (4) e pelo tipo de encapsulamento – hermético, semi-hermético ou aberto. Compressores herméticos contêm o motor e o compressor dentro de um recipiente fechado, sem acesso para manutenção ou troca de peças. O veio do compressor está integrado com o motor e em contacto com o refrigerante. Compressores semi-herméticos são de construção aparafusada, selados por juntas e gaxetas, permitindo acesso para manutenção. Compressores abertos são compressores em que o veio estende através de uma vedação no cárter para rotação externa.

1.2.2 Permutadores de Calor

Um permutador de calor tem como função a transferência de calor entre dois meios. Tanto o condensador como o evaporador são permutadores de calor. O condensador rejeita calor enquanto que o evaporador absorve calor do meio para o refrigerante. A capacidade dos permutadores de absorver ou rejeitar calor depende da diferença de temperatura entre o refrigerante e o fluido de arrefecimento, ou ar ou água.

No condensador é possível aumentar a sua capacidade através: do aumento da temperatura do refrigerante (que resulta numa diminuição da capacidade do compressor), ou do aumento do fluxo do fluido de arrefecimento. No entanto, não costuma ser possível diminuir a temperatura do fluido de arrefecimento, porque este encontra-se à temperatura ambiente (depende das condições exteriores - podendo ser ar ou água).

No caso do evaporador o coeficiente de transferência de calor do lado do refrigerante depende da diferença de temperaturas entre o refrigerante e o fluido e do coeficiente de convecção.

Na maioria dos permutadores o líquido circula a velocidades que provocam escoamento turbulento para uma melhor transferência de calor. O regime turbulento é obtido devido à perda de pressão. O valor da perda de pressão depende da geometria dos tubos e dos defletores. Do lado do refrigerante a perda de pressão resulta na diferença entre as temperaturas de saturação de entrada e saída do permutador. Esta diferença influencia a temperatura média logarítmica que por sua vez influencia o coeficiente de transferência de calor. O fluxo do fluido de arrefecimento pode ser no sentido do fluido refrigerante ou no sentido contrário.

O processo de transferência de calor é dividido em três: (1) arrefecimento (*desuperheating*) – consiste no arrefecimento do vapor superaquecido até ao estado de vapor saturado; (2) condensação – o calor latente começa a dissipar e ocorre a mudança de estado provocando uma significativa diminuição na velocidade e no volume do refrigerante; e (3) sub-arrefecimento (*subcooling*) – arrefecimento do líquido refrigerante para além do seu estado saturado. Para um arrefecimento inicial e sub-arrefecimento ideal é recomendada a utilização de contra-corrente entre o refrigerante e o fluido. A maior parte da área de transferência de calor é responsável pela condensação que ocorre a uma temperatura relativamente constante – uma ligeira diminuição na temperatura de condensação pode ser explicada pela perda de pressão no condensador. (ASHRAE, 2008)

Para um sistema de refrigeração funcionar corretamente, a pressão e temperatura de condensação têm de ser mantidas dentro de certos limites. Um aumento na temperatura de condensação pode resultar na perda de capacidade de refrigeração, o sistema requer mais energia e sobrecarrega o compressor. Quando a pressão de condensação é demasiado baixa, pode atrasar o fluxo de refrigerante, fazendo com que o sistema perca capacidade de refrigeração, pode ocasionar a formação de gelo, e pode causar a paragem do compressor por baixa pressão. A maioria dos sistemas de refrigeração utilizam válvulas de expansão termostáticas para regular a pressão e a temperatura de condensação. Um condensador pode ter a capacidade de armazenar toda a quantidade de refrigerante quando o sistema requer manutenção. Os condensadores, se condensados a água, são alimentados por uma bomba de água - no lado da remoção de calor, que permite regular o seu caudal, alterando a capacidade de transferência de calor.

O processo de transferência de calor no condensador é dividido em três: (1) aquecimento; (2) evaporação – mudança de estado; e (3) sobreaquecimento (*superheating*). A maior parte da área de transferência de calor é responsável pela evaporação que ocorre a uma temperatura relativamente constante. (ASHRAE, 2008)

Existem vários tipos de permutadores que trocam calor com água: (1) *shell-and-tube*, (1.1) de expansão direta, ou (1.2) inundados, (2) *shell-and-coil*, (3) *tube-in-tube*, e (4) permutadores de placas.

Nos permutadores *shell-and-tube* de expansão direta, Figura 1.3 o refrigerante circula em tubos distribuídos horizontalmente enquanto que a água circula dentro do recipiente, fora dos tubos, através dos defletores, colocados ao longo do recipiente, de modo direcionar e aumentar a velocidade do fluido, provocando um escoamento turbulento, aumentando assim a transferência de calor. (ASHRAE, 2008)

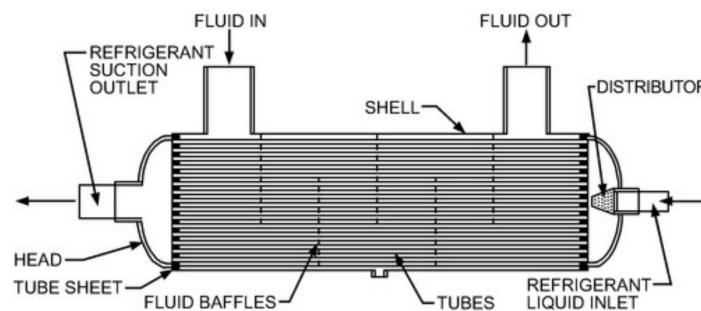


FIGURA 1.3: Permutador *shell-and-tube* de expansão direta, extraído de ASHRAE (2008)

Nos permutadores *shell-and-tube* inundados (Figura 1.4) a água circula dentro dos tubos enquanto que o refrigerante inunda o recipiente. A separação do vapor do refrigerante líquido ocorre na zona de superior do recipiente, onde não existem tubos. (ASHRAE, 2008)




FIGURA 1.4: Permutador inundado *shell-and-tube*, extraído de ASHRAE (2008)

Nos permutadores *shell-and-coil* a água flui numa ou mais serpentinas dentro de um recipiente onde circula o refrigerante. O refrigerante condensa, ou evapora em contacto com as serpentinas. A perda de pressão na linha de água é significativamente mais elevada do que em condensadores *shell-and-tube*. Os permutadores *tube-and-tube* são constituídos por um conjunto de tubos coaxiais. A água, normalmente, circula no tubo interior e o refrigerante no exterior.

Os permutadores de placas compreendem uma série de placas paralelas separadas por juntas de vedação que permitem o fluxo de contra-corrente entre a água e o refrigerante. Também existem permutadores de placas de expansão direta. Num permutador de placas o congelamento pode significar a perda do sistema. (Jones, 2007)

Nos permutadores a ar a capacidade do permutador aumenta com o aumento do fluxo de ar, logo a maioria dos permutadores arrefecidos a ar, contam com convecção forçada através de ventilação. A convecção forçada de grandes volumes de ar para arrefecimento com baixa resistência leva ao uso geral de ventiladores. (Jones, 2007)

Os permutadores a ar podem ser categorizados segundo o tipo de tubo que utilizam: (1) placas e aletas, (2) aletas, e (3) microcanais. Permutadores de placas e aletas são constituídos por um tubo de cobre, alumínio ou aço que serpenteia um conjunto de aletas limitadas por duas placas. Os permutadores de microcanais são utilizados em aplicações compactas. Compostos por tubos achatados, que evoluíram para um conjunto de microcanais integrados com aletas perpendiculares aos mesmos para transferência de calor. (ASHRAE, 2008)

1.2.3 Dispositivo Expansor

O dispositivo expansor é colocado na linha de líquido, linha entre o condensador e o evaporador. Em sistemas de refrigeração são usados maioritariamente três tipos de dispositivos expansores: (1) tubos capilares, (2) válvulas expansoras termostáticas, e (3) válvulas expansoras eletrónicas. A principal função dos dispositivos expansores é a redução da pressão do líquido refrigerante, da elevada pressão de condensação para a baixa pressão de evaporação. Realiza-se pela regulação da quantidade de refrigerante que alimenta o evaporador por controlo do sobreaquecimento. (ASHRAE, 2008)

1.3 Tipificação de Avarias

Um estudo experimental realizado por Comstock et al. (1999), patrocinado pela ASHRAE, teve como principal objetivo a obtenção de uma base de dados de operação de um sistema de refrigeração água-água para o desenvolvimento de métodos de detecção e diagnóstico de falhas aplicados a estes sistemas. Foram testadas diferentes condições de falha, e os resultados comparados com condições de operação nominal. Outro objetivo do estudo foi a compilação das falhas mais comuns em sistemas de refrigeração através de um estudo com diversas empresas de refrigeração. As falhas foram analisadas e ordenadas segundo a sua probabilidade de ocorrência e o seu custo de reparação.

A base do programa desenvolvido nesta dissertação é baseada na abdução de evidências. O comportamento dos parâmetros do sistema, os sintomas, são relacionados com os modos de falha de modo a estabelecer relações entre as falhas e os respectivos sintomas. A identificação dos sintomas leva ao diagnóstico das falhas. Os sintomas, as falhas e as suas relações derivam de uma FMEA aplicada às falhas estudadas no estudo em questão. O processo teórico de uma análise FMEA é detalhado no Apêndice A.

A FMEA pode ser utilizada para investigar as falhas mais prováveis de cada componente de um sistema de refrigeração. Os parâmetros aplicados são: severidade do efeito da falha, probabilidade de ocorrência da falha, e facilidade de detecção e reparação de falha ou do seu efeito. A severidade e detetabilidade são, normalmente, determinadas com base em conhecimento especialista e experiência empírica enquanto que a ocorrência pode ser estimada com base numa análise estatística de bases de dados de ações de manutenção em sistemas de refrigeração. (Cavique et al., 2013)

1.3.1 Compilação de falhas no estudo ASHRAE

A compilação de falhas foi realizada através da compilação de formulários de manutenção com cinco fases: (1) Tipo de equipamento – foram analisados três sistemas: um sistema com compressor centrífugo, e dois sistemas com compressor de parafuso, um com condensador arrefecido a ar, o outro a água. (2) Causa para manutenção – motivos para intervenção no sistema: falha mecânica, falha elétrica, perda de capacidade de refrigeração, perda de eficiência e manutenção de rotina. (3) Tipo de falha – dividido em várias categorias, descritas pormenorizadamente de

seguida. (4) Ação realizada – ação corretiva do problema: substituição, reparação, carregamento, ou limpeza. (5) Custo – custo da ação de manutenção.

Cada componente abrange diversas avarias potenciais. (1) Níveis do sistema – inclui falhas como gases não condensáveis no refrigerante, introduzidos durante más ações de manutenção; fugas de refrigerante; e excesso de óleo no evaporador, causado pelo carregamento em excesso de óleo no compressor. (2) Lubrificação – inclui falhas gerais, relacionadas não com o sistema mas com um componente em específico, como o arrefecedor de óleo, que pode ser arrefecido com o próprio refrigerante; a caixa de distribuição de óleo, mecanismo de distribuição de óleo para o sistema; a bomba de óleo, podendo ser uma unidade separada ou acoplada ao compressor; baixa pressão de óleo; e elevado fluxo de óleo. (3) Caixa de controlo – inclui falhas relacionadas com fornecimento de energia, com o sistema de controlo e com os atuadores. (4) Compressor – é feita a distinção entre compressores centrífugos e de parafuso. Para um compressor de parafuso são incluídas falhas como: problema mecânico com válvula de isolamento do compressor; sistema de controlo de capacidade com defeito mecânico ou elétrico; temperatura do motor, falha mecânica ou elétrica; rolamentos danificados; e falha catastrófica do motor, requerendo completa substituição do motor. Para um compressor centrífugo são incluídas falhas como: problema mecânico com o rotor do compressor; sistema de controlo de capacidade com defeito mecânico ou elétrico; temperatura do motor, falha mecânica ou elétrica; rolamentos danificados; e falha catastrófica do motor. (5) Tubagens – falhas são limitadas às linhas de refrigerante entre componentes do sistema de refrigeração. São incluídas falhas como: linha líquida com defeito, linha entre o condensador e evaporador; linha de arrefecimento do motor, derivação da linha de líquido; válvula de expansão; e filtro secador, verificação de obstruções. (6) Evaporador – inclui falhas relacionadas com a diminuição de caudal do fluxo de ar ou água. (7) Condensador – inclui falhas relacionadas com a diminuição de caudal do fluxo de água; e com a obstrução de tubos dentro do condensador.

Os resultados do estudo foram normalizados percentualmente segundo a probabilidade de ocorrência e segundo o custo da manutenção. A normalização dos diversos valores obtidos permite a visualização e comparação numa escala percentual equivalente. O resultado do estudo para todos os tipos de compressores é apresentado na Figura 1.5. Os tipos de falhas foram agrupados por componentes principais.

As falhas mais comuns registadas estão relacionadas com o controlador. Este tipo de falhas são facilmente detetadas e reparadas. No entanto, durante a




FIGURA 1.5: Resultados do inquérito do estudo por Comstock et al. (1999)

manutenção a instalação tem de estar parada. A frequência de falhas relacionadas com níveis do sistema é expectável devido às intervenções por causa de fugas de refrigerante, apesar de facilmente tratadas. Falhas relacionadas com o compressor são pouco frequentes mas com um custo elevado de reparação. Problemas a nível do motor e problemas elétricos são responsáveis pela maior parte do custo das reparações. A maioria das falhas a nível elétrico e a nível do compressor são de fácil deteção, sem necessidade de sensores ou controladores. No entanto, falhas de degradação que levam à falha de componentes ou à sobrecarga do motor são importantes de serem consideradas e detetadas devido ao impacto que podem ter e à possibilidade de evitar, corrigir ou minimizar esse mesmo impacto.

1.3.2 Implementação de falhas no estudo ASHRAE

As falhas aplicadas e o seu modo de implementação difere ligeiramente entre cada uma. (1) Redução do caudal de água no condensador – o caudal de água foi controlado através de uma válvula eletrónica. O caudal foi reduzido em incrementos de 10% para cada nível de severidade. (2) Redução do caudal de água no evaporador – o caudal de água foi controlado através de uma válvula eletrónica. O caudal foi reduzido em incrementos de 10% para cada nível de severidade. (3) Fuga de refrigerante – a fuga foi simulada através da redução da quantidade de refrigerante

no sistema. A quantidade de refrigerante foi reduzida em incrementos de 10% para cada nível de severidade. (4) Excesso de refrigerante – o excesso foi simulado através do aumento da quantidade de refrigerante no sistema. A quantidade de refrigerante foi aumentada em incrementos de 10% para cada nível de severidade. (5) Excesso de óleo – o excesso foi simulado através do aumento da quantidade de óleo no sistema. A quantidade de óleo foi aumentada em incrementos de 10% para cada nível de severidade (6) Obstrução do condensador – a obstrução de tubos no condensador foi simulada através do bloqueio de tubos.

O objetivo da documentação destes sintomas é a criação de regras baseadas nos mesmos que permita a identificação, e futuramente, a previsão de falhas em sistemas de refrigeração. As falhas, os sintomas e as suas relações são descritos de seguida.

Diminuição de Caudal no Condensador

A diminuição de caudal do fluido de arrefecimento, ar ou água, no condensador poderá ter várias causas. Em sistemas arrefecidos a ar, poderá ser uma avaria no ventilador, em sistemas arrefecidos a água, poderá ser uma avaria na bomba de água, caixas de admissão de água ou filtros colmatados, ou incrustações nos canos devido a microrganismos. A diminuição do caudal de água a entrar no condensador, mantendo a temperatura de entrada de água constante, provoca um aumento da temperatura de saída de água. Este aumento leva a que a temperatura e pressão do próprio condensador também aumentem, assim como a pressão que o compressor tem de vencer, fazendo o consumo energético aumentar também. O aumento da temperatura do condensador, a temperatura constante de entrada de água e o regime em contra-corrente do condensador, levam a que a diferença entre temperaturas entre a água de entrada e o refrigerante de saída seja maior. Quando a diferença entre temperaturas é maior, aumenta o potencial para transferência de calor no fim do condensador. A diminuição de caudal de água no condensador pode ocasionar um aumento do sub-arrefecimento.

Diminuição de Caudal no Evaporador

A diminuição de caudal do fluido a arrefecer no evaporador poderá ter várias causas dependendo do fluido utilizado, à semelhança do condensador. A diminuição de caudal de água a entrar no evaporador, mantendo a temperatura de entrada de água constante, provoca uma diminuição da temperatura de saída de água. A diferença entre as temperaturas de entrada e saída de água aumenta. Com a diminuição da temperatura da água, a temperatura e pressão do evaporador podem

diminuir. A diminuição da temperatura do evaporador, a temperatura constante de entrada de água e o regime em contra-corrente do evaporador, levam a que a diferença entre temperaturas entre o refrigerante de saída e a água de entrada seja maior. Quando a diferença entre temperaturas é maior, pode aumentar o potencial para transferência de calor no fim do evaporador. Menos área é necessária para evaporação e mais área é aproveitada para o sobreaquecimento. No entanto, ao contrário do condensador, o ligeiro aumento do sobreaquecimento é notado pela válvula expansora. A válvula aumenta o fluxo de refrigerante, reduz a transferência de calor e equilibra o sobreaquecimento. A diminuição de pressão do evaporador, é menos evidente do que a diminuição de pressão do condensador. A diminuição da pressão de evaporação pode levar ao congelamento do evaporador. No caso de permutadores de placas é considerada uma falha muito grave. O congelamento, pode originar fissuras no permutador que permitem a entrada de água no circuito, podendo causar a perda total do sistema.

Fuga de Gás Refrigerante

O refrigerante pode escapar através de micro fendas nos permutadores ou nas válvulas, ou mesmo nas tubagens. A diminuição da quantidade de refrigerante no sistema leva a uma diminuição das pressões do condensador e do evaporador – podendo levar ao congelamento do evaporador, situação semelhante à anterior em permutadores de placas. No entanto, a válvula expansora, ao regular o fluxo de refrigerante regula a pressão no evaporador. A diminuição da pressão de condensação causa uma diminuição da temperatura de saturação. A diferença entre as temperaturas no condensador diminui, assim como o potencial de transferência de calor, levando a uma diminuição do sub-arrefecimento. A diminuição da temperatura do refrigerante causa o ligeiro aumento da diferença entre as temperaturas à entrada do evaporador e um aumento da temperatura dos gases à saída do compressor. Devido a um fator de segurança do sistema, a diminuição inicial da quantidade de refrigerante causou um inesperado aumento da capacidade de refrigeração. A válvula expansora compensava a diminuição de pressão, abrindo e deixando passar mais refrigerante. No limite de válvula a pressão de evaporação diminui e o sobreaquecimento aumenta. Ao diminuir a quantidade de refrigerante, a pressão de evaporação vai baixar colocando o permutador em risco de congelamento.

Manutenção incorreta

Se durante ações de manutenção, o carregamento do gás refrigerante não for devidamente medido, o sistema pode ficar carregado em excesso. O aumento da quantidade de refrigerante no sistema leva a que as pressões do evaporador e do

condensador aumentem também. O aumento da pressão de condensação causa um aumento da temperatura de saturação que leva a um aumento do sub-arrefecimento, e um aumento da pressão que o compressor tem de vencer, logo o consumo energético também aumenta. O aumento da temperatura do refrigerante leva a que a diferença entre as temperaturas de saída do condensador aumente.

O carregamento de óleo também pode não ser devidamente medido. Com o aumento da quantidade de óleo é expectável que o óleo alcance o evaporador e iniba a transferência de calor. No entanto, o óleo não sai facilmente do compressor - válido para sistemas em que o óleo não esteja misturado com o refrigerante. A submersão do veio de manivelas no óleo viscoso apenas resulta numa perda mecânica devido ao atrito natural da sua viscosidade e num aumento das temperaturas do óleo.

Condensador obstruído

A obstrução do condensador é causada pela deposição de impurezas, microrganismos, e por reações químicas que provocam corrosão ou fissuras. A obstrução dos tubos de um condensador *shell-and-tube* reduz a área para transferência de calor. A redução da área de transferência de calor resulta no aumento da pressão do condensador. O aumento de pressão é acompanhado pelo compressor e por um aumento do consumo energético. Em condensadores arrefecidos a água, o fluxo da água de arrefecimento é constante, se a área seccional de fluxo diminui, a velocidade aumenta, resultando em menos tempo para chegar a um equilíbrio térmico entre a água e o refrigerante. A temperatura de saída da água diminui, resultando no aumento da diferença de temperaturas à entrada do condensador e na diminuição da diferença entre as temperaturas de entrada e saída de água. A válvula de expansão regula a quantidade de refrigerante que mantém a pressão do evaporador e o sobreaquecimento constantes.

Ar no refrigerante

Os gases não-condensáveis instalam-se no condensador durante ações de manutenção mal realizadas ou devido a fugas durante a operação. Num sistema com um compressor hermético, ar no circuito é extremamente perigoso para o compressor. Perante a entrada de uma alguma quantidade de ar, a redução da área de transferência de calor, provoca um aumento substancial na pressão do condensador, enquanto que a temperatura não aumenta tanto. Devido ao aumento de pressão do condensador, a pressão que o compressor tem de vencer é bastante mais elevada, pondo em causa o seu próprio funcionamento. Quando a quantidade de gases não-condensáveis aumenta a pressão a vencer é de tal forma elevada que pode levar ao

fluxo de refrigerante no sentido inverso.

A admissão de ar no sistema leva à infiltração de sujidade que pode obstruir o circuito devido à formação de substâncias ácidas, danificando a válvula de expansão; e pode levar à formação de gelo que provoca baixas pressões de admissão e descarga – sintomas associados com falta de refrigerante.

No caso de compressores herméticos, a existência de poucas gramas de ar (húmido atmosférico) é uma falha mais grave. O vapor de água pode condensar e provocar danos no motor do compressor.

1.3.3 Aplicação da Análise de Modos de Falha e Efeitos

O objetivo de uma FMEA é avaliar todos os modos de falha de um produto ou processo. Uma falha ocorre quando um produto não cumpre os seus requisitos funcionais total ou parcialmente. As falhas não estão limitadas ao produto, também devem ser incluídas falhas derivadas de erros de utilização. Cada modo de falha tem um ou mais potenciais efeitos, alguns são mais prováveis de ocorrer que outros. Cada potencial efeito tem um risco associado. O risco é a potencial consequência de um evento provável. Quanto mais grave a consequência ou mais provável o evento, maior será o risco. O processo é responsável pela identificação das falhas, dos efeitos, e dos riscos associados a um produto ou processo, e pela redução e eliminação dos mesmos.

Cavique et al. (2013) apresentaram uma contribuição – apoiada pela Axiomática de Projeto - *Axiomatic Design* (AD) – para ajudar na tomada de decisão utilizando a variação esperada dos requisitos para cada solução de projeto. Este estudo focou-se na tomada de decisão entre dois equipamentos de refrigeração para refrigerar um centro de dados. A decisão dependia do custo e da criticidade de uma possível falha, assumindo que ambos cumpriam os requisitos de refrigeração. O custo foi definido como um intervalo de valores mínimos e máximos de consumo energético segundo o mercado europeu. A criticidade - função de três parâmetros: severidade, ocorrência e detetabilidade e reparação - foi determinada para cada solução através de uma FMEA aplicada a sistemas de refrigeração. Esta é avaliada para cada modo de falha, associados, ou não, a um componente do sistema.

Yang et al. (2017) e Yang et al. (2018) propuseram uma FMEA para sistemas Aquecimento, Ventilação e Ar Condicionado - *Heating, Ventilation and Air Conditioning* (HVAC) através da exploração de ordens de trabalho geradas por Sistemas de Gestão Energética de Edifícios - *Building Energy Management Systems* (BEMS)

usando técnicas de exploração de dados. Além do contributo a nível computacional, foram apresentados pertinentes problemas com os sistemas de refrigeração e com os métodos de FDD associados a sistemas HVAC, devido à natureza do ambiente de trabalho dos sistemas e às condições especiais do mesmo. Estes problemas incluem: tolerância ou ignorância de falhas em períodos longos de trabalho, falta de normas de operação, falta de documentos para sistemas metódicos de análise e identificação e prevenção de falhas no sistema, no produto e no processo.

Os problemas identificados são comuns a vários sistemas, incluindo os sistemas dos navios patrulhas. (1) A performance de um sistema de refrigeração pode ser medida pelo consumo energético e pelo conforto dos utilizadores. No entanto, quando o sistema tem uma falha, os sintomas dessa falha podem ser facilmente tolerados e ignorados pelos utilizadores – se a temperatura subir demasiado, pode abrir-se uma janela para arrefecer, se a temperatura baixar demasiado, os utilizadores podem vestir outra peça de roupa para aquecerem. Consequentemente o mal funcionamento do sistema é facilmente ignorado ou tolerado. (2) O trabalho de automação e controlo dos sistemas é feito, imediatamente antes, ou depois do edifício estar ocupado, e não é seguido após a instalação. A avaria de sensores leva a que os dados recolhidos do sistema deixem de ser fiáveis. (3) Os sistemas conseguem manter a sua operação apesar de algumas falhas, causado desconforto ou alto consumo de energia, mas como a sua operação não é interrompida algumas dessas falhas não são reportadas ou registadas durante anos. Isto dificulta a aquisição de bases de dados sobre sistemas a trabalhar em condições de falha. (4) A complexidade de alguns sistemas leva a que modelos FMEA não possam ser aplicados. A falta de modelos para estes sistemas mais complexos leva a um desafio maior para identificar falhas e concentrar esforços na manutenção de componentes em detrimento da manutenção, muitas vezes inexecutável, do sistema todo. (5) Os sistemas de automação são instalados pelos construtores originais e fornecem apenas um armazenamento temporário e a curto prazo de dados. Muitos sistemas têm, consequentemente, bases de dados incompletas ou muito reduzidas. (6) A tecnologia para armazenamento de dados está cada vez mais desenvolvida, mas alguns sistemas têm muitos dados incompletos, vazios ou com erros devido a inúmeros problemas como: falhas de energia, problemas na rede de comunicações e falhas nos sensores. Estes dificultam a recolha e análise dos dados históricos operacionais.

O método de FDD desenvolvido não tem capacidade para abranger todas as falhas possíveis de um sistema de refrigeração. Face à quantidade de modos de falha e causas é necessário que o programa se foque nas mais importantes. Os problemas mencionados acima refletem a maioria dos desafios na FDD em sistemas HVAC. O

foco do programa é dirigido para pequenos indícios que levem a condições futuras de falha. Desvios que não sejam detetados por alarmes ou pré-alarmes pré-definidos. A análise FMEA tem como objetivo obter os modos de falha essenciais e adequados para o programa de FDD.

Uma FMEA realizada através das opiniões de diversos especialistas na área culminou com os modos de falha selecionados para aplicação no programa. Os valores dos parâmetros integrais da FMEA para as falhas analisadas foram reunidos baseados na revisão do estudo da ASHRAE. Existem causas com elevados valores de probabilidade de ocorrência numa situação de funcionamento normal mas com níveis de severidade baixos ou normais. No entanto, a evolução destes sintomas leva a possíveis condições futuras de falha com níveis de severidade elevados. Estas situações foram priorizadas sobre situações com probabilidades de ocorrência menores e valores de severidades maiores, como falhas relacionadas com o compressor e com o dispositivo expensor, devido à natureza de deteção de falhas do programa.

Numa situação normal de funcionamento da instalação, em que não são detetados alarmes ou pré-alarmes as falhas mais comuns surgem de uma diminuição da permuta de calor no condensador ou no evaporador, numa pequena fuga de refrigerante ou ao nível de sensores e controladores.

A diminuição da permuta de calor no condensador pode ser causada por uma avaria no ventilador, filtros colmatados e aletas corroídas. A diminuição da permuta de calor no evaporador pode ser provocada por uma redução no caudal de água de arrefecimento, que, por sua vez, pode ser causada por filtros colmatados - devido a impurezas e produtos biológicos na água de arrefecimento, bombas avariadas e manobra incorreta de válvulas. Uma fuga de refrigerante pode ocorrer devido a fissuras nas linhas ou nas juntas por mau contacto ou vibração.

A diminuição da permuta de calor no condensador e no evaporador é um sintoma que pode levar a condições de falha graves noutros componentes do sistema de refrigeração. Uma fuga de refrigerante leva à paragem eventual do sistema. No entanto, as baixas pressões resultantes também podem danificar alguns dos componentes.

A observação da pressão e temperatura do condensador permite obter informação sobre uma possível diminuição na permuta de calor do mesmo. A diferença entre as temperaturas de entrada e saída de água no evaporador permite inferir sobre uma possível diminuição na permuta de calor e a monitorização da pressão

do evaporador permite avaliar a diminuição da pressão do sistema, verificando a existência de fugas.

1.4 Sistemas de Refrigeração

Esta dissertação pode ser aplicada aos sistemas de refrigeração dos navios da classe Viana do Castelo. No entanto, por dificuldade de aquisição de dados do sistema de controlo da instalação, e por ser perigoso causarem-se avarias num sistema de bordo, a parte experimental foi feita num sistema ar-água.

O sistema de refrigeração dos navios em questão é um sistema água-água, cujo refrigerante é o *R134-a*. Tanto o condensador como o evaporador trocam calor entre o refrigerante e água. No caso dos navios, o condensador troca calor com a água do mar e o evaporador com água glicolada.

A instalação utilizada para o teste e validação do modelo desenvolvido é um sistema de refrigeração ar-água, cujo refrigerante é o *R410A*. O condensador troca calor com o ar exterior e o evaporador troca calor com água. Os sistemas são diferentes. No entanto, as falhas que são identificadas pelo programa, são falhas ao nível das funções dos componentes do sistema. Essas funções são comuns e independentes do tipo, do refrigerante ou dimensão do sistema de refrigeração em análise. O objetivo principal é validar tanto o programa como o modelo e a metodologia utilizada num sistema de refrigeração de modo a que possa ser aplicado futuramente a outros sistemas.

1.4.1 Navios de Patrulha Oceânicos

Os Navios de Patrulha Oceânicos (NPOs) são navios utilizados, prioritariamente, em ações não combatentes. Desempenham, principalmente, missões no âmbito da segurança e autoridade do Estado no mar e missões de interesse público. Possuem uma autonomia considerável, o que lhes permite permanecer no mar, em missão, durante largos períodos sem necessidade de apoio logístico. A classe Viana do Castelo é constituída pelos NPOs *NRP* Viana do Castelo, *NRP* Figueira da Foz, *NRP* Sines e *NRP* Setúbal. Os navios são particularmente vocacionados para atuar na zona económica exclusiva nacional desenvolvendo tarefas de busca e salvamento marítimo, fiscalização da pesca, controlo dos esquemas de separação de tráfego, prevenção e combate à poluição marinha, prevenção e combate a atividades ilegais como o narcotráfico, a imigração ilegal, o tráfico de armas e outros ilícitos, em colaboração com outras autoridades nacionais.

Com um comprimento máximo de 83,1 m, uma boca máxima – largura da secção mestra do navio – de 12,95 m, e um calado máximo – distancia vertical entre a superfície da água e a parte mais baixa da quilha – de 3,83 m, o navio apresenta um deslocamento médio de 1850 ton. O sistema de propulsão CODOE (COmbined Diesel Or Electric) para dois hélices de passo variável permitem ao navio atingir velocidades máximas de 21 nós e velocidades de cruzeiro de 15 nós. O sistema de produção de energia é composto por quatro grupos eletrogéneos. O navio conta ainda com um propulsor de proa, estabilizadores ativos, uma grua e um turco – para as duas embarcações a bordo, e convés de voo de helicópteros, apresentando uma guarnição de 42 elementos.

O sistema de ar condicionado é responsável por manter o interior do navio dentro das condições de projeto, Tabela 1.1 – sob temperatura limite da água do mar de 30 °C, dentro das condições limite do ar exterior, Tabela 1.2. Em cada casa de ventilação encontram-se baterias de aquecimento e arrefecimento como unidades terminais para garantirem as condições interiores desejadas. O condicionamento do ar é feito através de dois circuitos – instalação a quatro tubos – de água refrigerada e água aquecida – por um permutador do circuito de água da caldeirinha ou do circuito de água de arrefecimento dos motores principais. O circuito de água refrigerada e o circuito de água aquecida são pressurizados por duas bombas centrífugas em paralelo, com um caudal de 59 m³/h e de 15 m³/h, respetivamente.

TABELA 1.1: Condições de projeto do sistema dos NPOs

| | Condições interiores de projeto | |
|-------------------|---------------------------------|---------|
| | Verão | Inverno |
| Temperatura do ar | 25 °C | 20 °C |
| Humidade relativa | 50 % | 35 % |

TABELA 1.2: Condições limite do sistema dos NPOs

| | Condições exteriores limite | |
|-------------------|-----------------------------|---------|
| | Verão | Inverno |
| Temperatura do ar | 38 °C | -2 °C |
| Humidade relativa | 70 % | 90 % |

O sistema de refrigeração é responsável por refrigerar a água que alimenta as baterias de arrefecimento das casas de ventilação. O navio possui dois *chillers*,

grupos nº1 e nº2. O sistema água-água é constituído por dois condensadores *shell-and-tube*, que rejeitam calor para a água do mar – circuito alimentado por duas bombas centrífugas de caudal de 50 m³/h em paralelo, dois compressores alternativos do tipo aberto com seis cilindros, dois dispositivos expansores e um evaporador *shell-and-tube* – composto por dois circuitos de refrigerante, um por grupo, e um de água refrigerada (mistura de água (85%) com glicol (15%) para baixar o ponto de congelação). Cada compressor tem três estágios de compressão: 33%, 66% e 100% da capacidade do compressor. O sistema oferece seis estágios: 17%, 34%, 51%, 68%, 85% e 100% da capacidade de refrigeração. O primeiro estágio corresponde a uma capacidade mínima de 33 kW, e o último corresponde a uma capacidade máxima de 200 kW. A gestão dos estágios do compressor é controlado por um sensor de temperatura instalado na saída do evaporador. O controlo do *chiller* é efetuado por um sensor de temperatura instalado à entrada do evaporador – *set point* de 12 °C. O controlo no retorno permite gerir melhor as flutuações e picos do sistema, a temperatura à entrada do evaporador varia lentamente conforme a inércia do sistema.

1.4.2 Instalação de Teste

Para o teste e validação do programa é necessária a simulação de condições de falha num sistema de refrigeração. Devido ao estado da prontidão dos navios, não é do seu melhor interesse colocar a instalação em risco ao simular falhas para a validação do programa. A instalação para teste também deve ter a possibilidade de recolha de dados de diversos parâmetros do sistema que permitam a descrição do estado termodinâmico do sistema.

A instalação utilizada para a aquisição de dados, para o desenvolvimento do programa e para validação e teste é o sistema de climatização ANL H 081 da *AERMEC* com uma capacidade de refrigeração de 20 kW em condições Eurovent. O sistema ANL arrefecido com o ar exterior, utiliza o refrigerante *R410A* para arrefecimento e aquecimento de água em aplicações domésticas, comerciais e industriais. As unidades têm permutadores de calor e compressores scroll. O sistema ANL H 081, pode funcionar em modo de refrigeração ou de aquecimento. Com caudal de água constante utiliza um compressor scroll hermético on/off de acordo com a temperatura de saída de água, definida para 7°C, e uma válvula termostática. Utiliza um permutador de placas como evaporador para arrefecer água e um permutador de tubos aletados como condensador arrefecido a ar com um ventilador axial, em modo de arrefecimento. A partir dos 20 °C (temperatura do ar exterior) o ventilador

funciona à velocidade máxima. A instalação arrefece um espaço de escritórios das 8h00 às 20h00 em Sintra, Portugal.

O sistema de controlo da instalação regista os dados dos sensores, alarmes e pré-alarmes. O painel de controlo conecta-se através de uma porta RS485 ao sistema Modem. A porta WAN do Modem conecta um cabo Ethernet à LAN do escritório. A rede LAN regista os dados pela internet na base de dados *AERNET*, uma base de dados da *AERMEC*. O administrador local da *AERNET* pode aceder aos dados da instalação e definir os parâmetros de registo. Os dados são recolhidos a cada 60 s com uma taxa de transmissão de 19200 bps. Os dados e alarmes recolhidos pelo dispositivo são todos enumerados no Anexo I.

O circuito de refrigerante, Figura 1.6 é composto pelos seguintes componentes: (1) Permutador de calor de tubos aletados, como condensador, (tubos de cobre e aletas de alumínio). Ventilador axial de rotor externo com pás helicoidais, motor de 6 pólos com proteção térmica. (2) Válvula inversora de quatro vias, para inverter o ciclo. (3) Compressor scroll hermético de alta eficiência (montado em suportes elásticos anti-vibração), acionado por um motor elétrico de dois pólos com proteção térmica interna. Aquecedores do cárter padrão, ativados automaticamente quando a unidade pára, desde que a instalação se encontre em funcionamento. (4) Permutador de calor de placas, como evaporador, em aço inoxidável, isolado externamente com material anti-condensação de neoprene. (5) Válvulas de não-retorno (6) Válvula mecânica termostática, com equalizador externo localizado à saída do evaporador, regula o fluxo de refrigerante no evaporador com base na carga e garante o sobreaquecimento correto. (7) Acumulador de líquido, para compensar a diferença entre os volumes do evaporador e condensador. (8) Filtro secador, feito, hermética-mecanicamente, com material higroscópico, capaz de reter impurezas e quaisquer vestígios de humidade presentes no circuito de refrigeração.

O circuito hidráulico, Figura 1.7 é composto pelos seguintes componentes: (1) Permutador de placas (2) Pressostato entre a entrada e a saída do evaporador. (3) Sensores de temperatura à entrada e à saída do evaporador. (4) Filtro de água, equipado com malha filtrante de aço, evita o entupimento do permutador de calor do lado do sistema devido a impurezas dentro do circuito. (5) Válvulas de alívio de pressão, calibradas a 6 bar.

O circuito de refrigeração tem três seguranças principais: um pressostato de alta pressão, de calibração fixa e reinicialização manual, e dois transdutores, um no circuito de alta pressão o outro no circuito de baixa, que geram pré-alarmes.




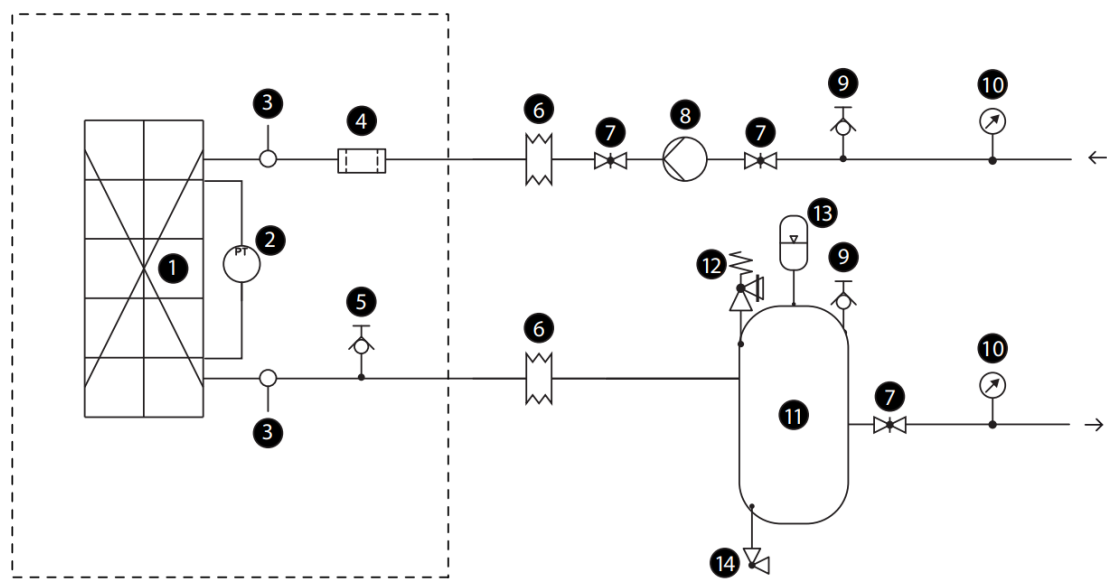
FIGURA 1.6: Circuito de refrigerante do sistema ANL H 081, extraído do manual da *AERMEC*

Em termos de acessórios, o sistema tem: suportes anti-vibração; um suporte para condensações; resistências elétricas anticongelantes para o tanque de compensação e para o permutador de placas;

O desempenho do sistema para ambos os modos de funcionamento e as respectivas gamas de temperatura está descrito na Tabela 1.3. EER e COP são respectivamente o Rácio de Eficiência Energética - *Energy Efficiency Ratio* (EER), o Coeficiente de Desempenho - *Coefficient Of Performance* (COP).

TABELA 1.3: Performance do sistema ANL H 081

| Modos de Funcionamento | | Arrefecimento | Aquecimento |
|------------------------|----------|---------------|-------------|
| Parâmetros | Unidades | 12°C - 7°C | 40°C - 45°C |
| Capacidade | kW | 20,0 | 21,0 |
| Energia | kW | 6,7 | 6,1 |
| Corrente | A | 12,0 | 13,0 |
| EER/ COP | W/W | 3,01 | 3,46 |
| Caudal de água | L/h | 3452 | 3638 |
| Perda de pressão | kPa | 44 | 53 |



Components as standard

- 1 Plate heat exchanger
- 2 Differential pressure switch
- 3 Water temperature sensors (IN/OUT)
- 4 Water filter
- 5 Air drain valve

Components not provided and responsibility of the installer

- 6 Anti-vibration joints
- 7 Flow shut-off valves
- 8 Pump
- 9 Air drain valve

- 10 Pressure gauge
- 11 Storage tank
- 12 Pressure relief valve
- 13 Expansion vessel
- 14 Drain valve

FIGURA 1.7: Circuito hidráulico do sistema ANL H 081, extraído do manual da *AERMEC*

Capítulo 2

Métodos de Detecção e de Diagnóstico de Falhas

Este capítulo apresenta uma perspectiva sobre a metodologia de detecção e de diagnóstico de falhas num sistema generalizado e em sistemas de refrigeração. Os métodos mais comuns utilizados na detecção e diagnóstico de falhas são apresentados e brevemente descritos assim como as técnicas e práticas relacionadas. As técnicas, teorias e tecnologias relacionadas com a detecção e diagnóstico de falhas aplicadas ao sistema de refrigeração em estudo são também descritas. O objetivo deste capítulo é o esclarecimento do fundamento teórico dos métodos utilizados no capítulo seguinte.

A monitorização contínua do funcionamento do sistema e dos seus principais parâmetros permitem uma análise do seu estado. A eficiência e eficácia dos sistemas também depende disso. A eficiência de um sistema diminui devido à ocorrência de falhas, repentinas, inesperadas e perigosas e à degradação de componentes individuais. A manutenção minimiza o risco de falha. No entanto, não deveria ser aplicada em ações corretivas com a instalação já danificada. Para atuar em manutenção preventiva é necessário saber quando e onde atuar. A detecção e diagnóstico prematura de falhas é fundamental. Os métodos utilizados para detecção são, normalmente, diferentes dos métodos utilizados para diagnóstico. (Reddy et al., 2006)

2.1 Sistemas Periciais

Sistemas Periciais - *Expert Systems* (ES) são modelos inteligentes que permitem a modelação de conhecimento intuitivo, experiência e opiniões especialistas, mais conhecidas como “*rules of thumb*”. O conhecimento adquirido com a experiência dos especialistas é utilizado e integrado nestes modelos com dados quantitativos e ferramentas algorítmicas para desenvolvimento de sistemas de diagnóstico. Uma das

diferenças entre ES e sistemas baseados em conhecimento de diagnóstico é que a técnica utilizada em ES é o processo da aplicação de informação conhecida a ambientes de informação não quantificada sem precedentes, através de inferência baseada no conhecimento adquirido. Ambas as técnicas de diagnóstico utilizam conhecimento de especialistas como base para a sua base de conhecimento. Os sistemas baseados em conhecimento utilizam uma representação simbólica do conhecimento enquanto que os ES utilizam métodos algorítmicos e estatísticos. (Graham-Jones & Mellor, 1995)

Um ES é constituído pelos seguintes componentes: (1) a interface, utilizada para o registo e extração de conhecimento, é o componente de aquisição e representação de conhecimento; (2) a base de conhecimento, contém factos e regras no âmbito do problema, é baseado em procedimentos para fazer deduções lógicas entre sintomas e causas; (3) *blackboard*, onde é descrito o problema, os constrangimentos e pormenores; (4) mecanismo de inferência, que fornece a metodologia para o raciocínio sobre a informação na base de conhecimento e no *blackboard* e formula as conclusões. (Graham-Jones & Mellor, 1995)

A base de conhecimento de ES é representada por regras derivadas de conhecimento especialista que permitem descrever um sistema, total ou parcialmente. Este conhecimento pode ser qualitativo - através de regras heurísticas ou métodos probabilísticos (como a DST); ou quantitativo - através de métodos estatísticos ou reconhecimento de padrões.

Soliman et al. (1999) propõem uma metodologia para integrar conhecimento subjetivo (heurístico) e objetivo (analítico) para o diagnóstico de falhas e tomada de decisões utilizando lógica difusa. A integração de métodos de diagnóstico baseados em modelos e conhecimento num esquema de diagnóstico de modo a melhorar a performance das ferramentas num ambiente de sistemas complexos e não lineares é demonstrada. A lógica difusa é a ferramenta utilizada para a integração dos dois tipos de conhecimento, através da fusão dos dois caminhos paralelos: no primeiro, os modelos matemáticos são aplicados e no segundo os modelos baseados em conhecimento.

Existem várias metodologias para mecanismos de inferência, nomeadamente sistemas baseados em regras - que representam o conhecimento sob a forma de regras e factos; em modelos - que utilizam modelos matemáticos que dependem de estruturas de conhecimento e do comportamento dos sistemas; ou em casos - que resolvem problemas com base em experiências anteriores. (Graham-Jones & Mellor, 1995)

Mecanismos de inferência baseados em regras são normalmente sistemas difusos, devido à dificuldade de definição de valores limite discretos e precisos. Estes sistemas difusos põem em prática a lógica difusa e os conjuntos difusos com as respectivas funções de pertinência. Uma descrição teórica dos conjuntos difusos, dos diferentes tipos de funções de pertinência e das operações entre elas é apresentada no Apêndice B.

A estrutura básica de um mecanismo de inferência difuso consiste em três componentes principais: uma base de regras, que contém a seleção das regras difusas; uma base de dados, que contém as funções de pertinência utilizadas nas regras difusas; e um mecanismo de raciocínio, responsável pela computação baseada nas regras e nas suas funções de pertinência. O resultado de um sistema de inferência é normalmente um valor difuso, logo é necessário transformá-lo num valor discreto. Três tipos de sistemas de inferência difusos são aplicados na maioria das situações: modelos Mamdani, modelos Sugeno, e modelos Tsukamoto. (Jang et al., 1997)

Yen (1989) propõe e descreve o ES protótipo implementado, GERTIS (*General Evidential Reasoning Tool for Intelligent Systems*), que aborda as questões da combinação, evidência e produção de explicações para hipóteses hierárquicas relacionadas. O GERTIS usa um modelo de raciocínio da DST alargado para ultrapassar as dificuldades da aplicação da teoria original aos sistemas especializados assim como produz explicações utilizando o conhecimento sobre a estrutura do espaço da hipótese e o efeito de cada regra.

Beynon et al. (2001) propõem um novo sistema de software que utiliza um novo método (DS/AHP) que combina aspetos do Processo Analítico Hierárquico - *Analytical Hierarchy Process* (AHP) com a DST para efeitos de Tomada de Decisão de Múltiplos Critérios - *Multi Criteria Decision Making* (MCDM). O método permite ao decisor um nível de controlo maior sobre as decisões tomadas na identificação dos níveis de favoritismo noutros grupos de decisão. Mais especificamente, a análise Dempster-Shafer (DS)/AHP permite análises adicionais, incluindo níveis de incerteza e conflito nas decisões tomadas. É introduzido um ES que permite a aplicação de DS/AHP a MCDM.

Wang et al. (2004) desenvolveram um ES para diagnóstico em medicina tradicional chinesa incorporando várias técnicas de *Machine Learning* (ML), um algoritmo híbrido de aprendizagem aplicado a uma rede bayesiana, classificadores Naïve-Bayes com uma nova estratégia de pontuação para seleção de recursos, e um método de regras de associação restritas. O ES baseado em regras *if-then* aplicado à medicina tradicional chinesa foi distinto para a resolução do problema da obtenção de

conhecimento. O conhecimento é fornecido de várias fontes através de um diagrama causal, de regras de associação e de regras de raciocínio derivadas dos classificadores.

2.2 Detecção e Diagnóstico de Falhas

A FDD aplicada a sistemas de HVAC está diretamente relacionada com os custos de operação e manutenção dos sistemas HVAC.

Enquanto que a ignorância e a tolerância das condições ambientais interiores são os maiores desafios da detecção de falhas por parte dos utilizadores, a falta de informação ou informação completa e a incerteza são os maiores desafios dos métodos de detecção e de diagnóstico de falhas em sistemas de refrigeração.

A falta de informação refere-se à falta de sensores, controladores, dados de operação em condições nominais e condições de falha – dificultando o desenvolvimento de modelos físicos. A incerteza refere-se aos erros de medição, às relações probabilísticas entre sintomas e falhas e ao conhecimento especialista impreciso, (Huang et al., 2015). A falta de informação dificulta a modelação dos modelos que distinguem as condições de funcionamento nominal das condições de funcionamento em falha.

A ignorância refere-se à falta de percepção, do utilizador, de alterações subtis às condições de conforto, provocadas pelo incorreto funcionamento do sistema, que pode levar à ignorância de possíveis falhas. A tolerância refere-se à capacidade de adaptabilidade do utilizador face a condições de conforto fora das condições nominais também provocadas pelo incorreto funcionamento do sistema, que leva à tolerância de possíveis falhas, (Yang et al., 2018). A ignorância e tolerância do utilizador perante condições ambientais não ideais pode levar a que uma falha não seja detetada numa fase inicial.

Reddy et al. (2006) descreveram um processo generalizado de supervisão automática online de um sistema em seis fases gerais. No entanto, nesta dissertação são apenas empregues três fases: o pré-processamento dos dados, a detecção e o diagnóstico de falhas. Todas as fases são descritas, as fases utilizadas na dissertação são mais pormenorizadas. Para as fases da detecção e diagnóstico de falhas são descritos vários métodos que podem ser aplicados. O modelo de FDD desenvolvido nesta dissertação é orientado para uma atuação antes de uma situação de alarme. A identificação do desvio dos parâmetros permite atuar em antecipação.

1. Desenvolvimento e instalação da rede de sensores

Os métodos de FDD monitorizam constantemente a operação de vários processos e componentes, através de sensores e controladores, de modo a detetar e prevenir a presença de falhas. Esta fase envolve a identificação do tipo de falhas a serem avaliadas, avaliando a localização, a precisão e o tipo de sensor ou controlador necessário. Os sistemas de refrigeração têm vários subsistemas que interagem entre eles. A complexidade dos sistemas de comando e controlo é proporcional à complexidade do sistema a controlar. As relações completas de causa e efeito entre falhas e sintomas num sistema complexo são difíceis de decifrar. Mesmo com sistemas de automatização e controladores avançados, o sistema desenvolve falhas durante a instalação ou operação, resultando num desperdício energético e/ou num ambiente desconfortável. Uma falha é o desvio de um variável observada ou de um parâmetro calculado de uma gama de valores aceitáveis.

2. Pré-processamento dos dados de operação

Os dados retirados dos sensores são, normalmente, sujeitos a um programa de pré-processamento de dados. As medições do sistema podem ser online ou através de aquisição de ficheiros de dados. Esses ficheiros podem compreender desde segundos a horas em dados de operação. Os dados são integrados num determinado intervalo de tempo ou sujeitos a filtros, de modo a remover valores de pico e maus sinais. Os valores poderão ser avaliados em qualidade, através da verificação da gama de parâmetros aceitável ou através da resolução de equações de equilíbrio termodinâmico. Este processo pode, muitas vezes, detetar automaticamente defeitos nos sensores.

3. Detecção de falhas

A deteção de falhas apenas identifica o defeito no sistema, não considera as anomalias baseadas em eventos ou estados transitórios, sendo o seu objetivo descobrir falhas e operações defeituosas no sistema. A deteção de uma falha é feita através da comparação dos valores de operação com os valores expectáveis. Quando o desvio excede um limiar definido, é acionado um alarme ou um pré-alarme. Os dados processados são analisados de modo a perceber se o sistema está a funcionar fora das condições nominais. Esta fase consiste em três passos:

- (1) Definição dos parâmetros nominais de funcionamento.

A definição dos parâmetros nominais pode ser feita utilizando os dados de

operação nominal. Podem ser feitas interpolações aritméticas ou transformações algébricas; modelação de um sistema semelhante; o cálculo das principais propriedades termodinâmicas e das correspondentes relações entre parâmetros. Estes valores nominais são utilizados como variáveis de controlo perante os valores adquiridos das variáveis observadas.

(2) Método de detecção de falhas

Os métodos de detecção utilizam os dados processados para prever ou as condições nominais ou condições anormais de funcionamento para os parâmetros identificados. A detecção de falhas apoia-se em dados. No entanto, os métodos para a detecção dividem-se. Existem métodos baseados no conhecimento de especialistas que estudam o sistema e a sua natureza e são aplicados de maneira orientada. Métodos baseados em análise de dados focam-se nos dados e não no sistema, assentam no estudo das relações e variações das variáveis apresentadas e modelam um sistema correspondente.

(2.1) Métodos qualitativos, métodos baseados em conhecimento apoiam-se no conhecimento especialista, conseguindo maximizar o conteúdo da informação de detecção e diagnóstico. São utilizados para sistemas pouco complexos, com poucas variáveis de entrada e de saída, e quando a modelação computacional ou matemática é demasiado complexa ou dispendiosa. Tem uma elevada capacidade de lidar com incerteza, falta de informação e informação contraditória. A precisão do modelo depende do entendimento da natureza do sistema e dos seus modos de falha. Existem vários modos de aplicação destes métodos baseados no conhecimento de especialistas:

(2.1.1) A verificação de que os valores dos parâmetros recolhidos se encontram dentro da gama definida; a definição dos limites inferiores e superiores do limiar aceitável da variação de um parâmetro entre valores nominais e valores em condição de falha;

(2.1.2) A utilização da redundância física de sensores, através de dois ou mais sensores seleccionados, para a leitura do mesmo parâmetro.

(2.2) Métodos quantitativos, métodos baseados em análise de dados baseiam-se no treino suportado pelos dados de operação retirados do sistema. Necessitam de uma grande quantidade de dados com uma elevada gama de estados de operação, incluindo operação sob modos de falha, visto que não é possível extrapolar fora das situações registadas. São flexíveis na sua dimensionalidade, através da redução da quantidade de dados processados por determinação de variáveis relevantes. Os métodos não requerem um conhecimento dos processos físicos do sistema. No

entanto, não podem ser aplicados a outros sistemas, diferentes do qual foram treinados. Analogamente a métodos baseados em conhecimento, os métodos baseados em dados contemplam vários modos de aplicação:

(2.2.1) A calibração do sistema em condições nominais, implica a criação de um modelo, contendo todos os valores de todos os parâmetros observados cujos valores são associados a diferentes regimes de funcionamento normal sendo que as relações entre parâmetros são constantemente registadas. A deteção de falha deriva da aplicação desse modelo calibrado em condições de operação nominais a condições de falha;

Ahmad e Atta (2014) propuseram um sistema com sensores de corrente de efeito de *hall* ligados à rede elétrica de cada sistema HVAC do edifício. A saída em tempo real do sensor de corrente é amostrada e transmitida sem fios para a sala de controlo do edifício. O sinal recebido de cada sistema HVAC é transformado no domínio de frequência e analisado para qualquer falha mecânica ou elétrica sendo comparado com dados de sistemas semelhantes em funcionamento nominal.

Yang et al. (2020) desenvolveram um método baseado em aprendizagem de dados para construir mecanismos de inferência de prognóstico para deteção de falhas em sistemas de refrigeração. O modelo proposto ajuda a desenvolver modelos preditivos a partir de dados históricos de operação e manutenção com o objetivo de reduzir o consumo energético e o custo operacional.

(2.2.2) Modelos de caixa preta, formulados com base na relação entre variáveis de entrada e de saída de um sistema, não considerando o seu significado físico. Modelos constituídos por outros modelos de comportamento das variáveis derivados de dados históricos sobre o sistema. Estes modelos podem ser baseados em técnicas estatísticas, em redes neuronais artificiais e em reconhecimento de padrões.

Lo et al. (2007) desenvolveram uma técnica computacional inteligente baseada num Algoritmo Genético Difuso - *Fuzzy Genetic Algorithm* (FGA) para detetar automaticamente falhas num sistema HVAC. O sistema de Deteção de Falhas Automática - *Automatic Fault Detection* (AFD) monitoriza o sistema HVAC através de um sistema de inferência difuso. A capacidade de otimização dos algoritmos genéticos permite a criação de regras difusas adequadas. As falhas são representadas através de diferentes níveis no sistema de AFD e distinguidas pelo sistema difuso depois da calibração do sistema de regras difusas com dados de operação em funcionamento nominal. O algoritmo proposto para a construção de um AFD) para

sistemas HVAC é um Algoritmo Genético - *Genetic Algorithm* (GA) difuso, utilizados para produzir um conjunto adequado de regras difusas. São algoritmos de procura baseados nos mecanismos da seleção natural e reprodução genética. A sua capacidade de procura em grandes e complexos espaços global e eficientemente e de localizar soluções ótimas faz com que sejam adequados para a produção de um conjunto de regras difusas.

Namburu et al. (2007) desenvolveram uma técnica genérica de deteção e diagnóstico de falha para chillers centrífugos através de um método quantitativo baseado em dados, um método de caixa preta, para prever a resposta do sistema sobre condições de falha. As principais técnicas de classificação de falhas utilizadas foram: (1) Máquina de Vetor de Suporte - *Support Vector Machine* (SVM), (2) Análise de Componentes Principais - *Principal Component Analysis* (PCA), e (3) Mínimos Quadrados Parciais - *Partial Least Squares* (PLS). O processo de deteção e diagnóstico desenvolvido consiste na fase offline onde os dados são usados: para treinar os três classificadores (SVM, PCA, PLS) antes de serem exportados para fase online, e para treinar um modelo de estima PLS para avaliar a severidade das falhas; e na fase online onde são compreendidas três fases: deteção, isolamento ou classificação, e identificação ou estima da severidade.

(2.2.3) Modelos de caixa cinzenta, combina conhecimento físico ou princípios básicos para especificar os termos matemáticos do modelo, e dados de operação para determinar os parâmetros do modelo empiricamente, de modo a obter um modelo para o sistema. Os parâmetros do modelo são inicialmente estimados através dos dados de treino – dados do fabricante, testes em laboratório ou dados do sistema a operar nas condições nominais. Os modelos de caixa cinzenta apesar de requerem conhecimento sobre o sistema necessitam de menos dados para obter um modelo que se ajusta ao sistema real, assim como permitem maior confiança para extrapolações fora do âmbito dos dados de treino.

(3) Deteção de falhas

A deteção de falhas é o processo, desencadeado pelos dois passos anteriores, de deteção de uma condição anormal de funcionamento. A diferença entre a oscilação normal devido à natureza do sistema e a variação crescente ou decrescente de um valor devido a uma defeito tem de ser definida de modo a detetar falhas. Os métodos anteriormente descritos permitem detetar variações nos valores dos parâmetros do sistema observados. Existem vários métodos para decidir se tais variações são consideradas falhas ou oscilações naturais do sistema. Estes métodos também são associados em métodos baseados em conhecimento ou em dados.

(3.1) Métodos qualitativos, métodos baseados no conhecimento de especialistas. São aplicados de forma semelhante a este processo de deteção.

(3.1.1) A definição de regras heurísticas, implica a identificação de falhas segundo um conjunto de regras definidas por conhecimento especialista. Com base na ativação dos parâmetros do sistema, o desvio – dos valores perante a sua condição nominal – previamente detetado, são definidas regras que conjugam as diversas ativações e derivam uma conclusão. Do conjunto de regras é derivado um mecanismo de inferência para deteção de falhas.

Afgan e Carvalho (1996) apresentam o conceito de um sistema de deteção de falha on-line para um permutador de calor. Através do estudo da eficiência do permutador, com base no conceito de NTU (*Number of Transferred Units*), e nas variáveis utilizadas para medir as propriedades do permutador, é criado um sistema de inferência baseado em conhecimento para a FDD.

(3.1.2) A utilização de métodos probabilísticos, baseados em probabilidade bayesiana ou na DST, permite combinar evidências de diferentes especialistas e de outras fontes de modo a obter uma medida de confiança que certo evento pode acontecer. Tem a possibilidade de categorizar incertezas decorrentes devido à falta de conhecimento como probabilidades discretas associadas a um conjunto de valores. Permite ainda associar diversas ativações dos parâmetros e combinar as probabilidades associadas a cada um, calculando uma ou mais falhas mais prováveis.

Li et al. (2021) propuseram um método de diagnóstico de falhas integrando duas abordagens: um método qualitativo, baseado em conhecimento – com boa interpretabilidade, e um método quantitativo, baseado em dados – com boa precisão de diagnóstico. O método proposto desenvolve uma Rede Bayesiana de Diagnóstico - *Diagnosis Bayesian Network* (DBN) baseada no conhecimento de especialistas assim como em dados de operação. O algoritmo de Rede Bayesiana - *Bayesian Network* (BN) é extensivamente aplicado no campo de diagnóstico de falhas e pode ser baseado em conhecimento ou em dados. Uma BN para diagnóstico de falhas é um modelo gráfico probabilístico que expressa relações causais entre falhas e sintomas através de uma estrutura de uma rede e um conjunto de parâmetros probabilísticos. Uma DBN consiste em dois componentes: estrutura e parâmetros. Uma estrutura DBN é um gráfico acíclico direto composto por nós e arcos. Existem dois tipos de nós: nós de falha – representação conceptual de uma falha – com dois estados: com e sem defeito; e nós de sintomas – representação conceptual de variáveis características ou de índices de performance sensíveis à ocorrência de falhas – com diferentes níveis de severidade da falha com três estados: alto, baixo e normal. Os arcos representam as

relações entre falhas e sintomas. Para cada nó de falha é atribuído uma distribuição probabilística de ocorrência (com ou sem defeito – inverso do primeiro). Para cada nó de sintoma é atribuído uma probabilidade condicional definida pela relação com as falhas associadas. Uma abordagem aperfeiçoada baseada num algoritmo genético é utilizada para otimizar as estruturas DBN com base nos dados operacionais. Gráficos de variáveis locais são produzidos a partir da rede para interpretação visual direta dos mecanismos de falha. Os especialistas podem avaliar a certeza dos resultados do diagnóstico visualizando os gráficos e, em seguida, tomar decisões com maior grau de confiança.

Mokarram e Khosravi (2021) aplicaram a DST para calcular ponderações para os parâmetros de entrada e computação em nuvem para criar uma solução integrada de informação reunida de diferentes regiões com o objetivo principal de determinar a localização ótima para plantação de laranjeiras. O método DST, que é frequentemente utilizado em muitos problemas de computação em nuvem, foi empregue para determinar locais adequados para o cultivo de árvores de fruto, respondendo com diferentes graus de confiança. A maior vantagem do método DST é permitir a avaliação e quantificação da incerteza. A teoria funciona com base num conjunto de princípios propostos para a combinação de dados de várias fontes, sendo a mais importante a regra de combinação Dempster. Os graus de risco medidos neste modelo são conhecidos como graus de crença. O método culmina na obtenção de mapas de aptidão fundiária de áreas aptas para o cultivo de laranja em diferentes níveis de risco.

Cheng et al. (2000) mostrou que os limites inferior e superior obtidos da DST podem ser utilizados para calcular o intervalo de probabilidade de falha do evento superior – numa árvore de falha – diretamente sem necessidade de os transformar em formas de três valores. Embora os intervalos tenham níveis de confiança diferentes, funções de pertença podem ser utilizadas para descrever opiniões subjetivas enquanto que operações matemáticas calculam a análise quantitativa da árvore de falhas. A teoria da evidência permite obter os limites inferior e superior – crença e plausibilidade – de cada modo de falha utilizando técnicas probabilísticas com diferentes opiniões que podem ser consideradas, evitando preconceitos de certos especialistas.

Chakraborty e Elzarka (2019) desenvolveram um modelo baseado em dados utilizando uma técnica de aumento de gradiente extremo (XGBoost) para ser aplicado num limiar dinâmico de modo a detetar falhas em tempo real. Este método ajusta o limiar dinâmico de acordo com a média e o desvio padrão dos dados

das previsões em tempo real. O algoritmo proposto reúne conhecimento especialista para estabelecer a árvore de falhas e análise de dados para processamento de valores. O problema da definição de um limiar fixo é abordado: se for colocado muito alto, algumas falhas podem não ser detetadas; se for colocado muito baixo, a probabilidade de ocorrerem falsos alarmes é muito alta. A detecção de falhas indica um desvio de performance do resultado expectável por um limiar pré-definido.

(3.2) Métodos quantitativos, métodos baseados em análise de dados. São aplicados à detecção de falhas de maneira análoga.

(3.2.1) A utilização de métodos estatísticos para a detecção de falhas é possível através da extensa quantidade de dados. Cada falha registada é associada a várias ativações de parâmetros. A ativação de parâmetros aciona uma probabilidade estatística da falha correspondente. A quantidade de registos facilita a detecção de futuras falhas, mas independentemente dessa quantidade, não é possível interpolar a detecção de uma falha não registada.

Huang et al. (2015) propuseram um protótipo para um projeto de um sistema HVAC sob incerteza, capaz de incorporar incerteza diretamente no projeto do sistema e, mais importante, capaz de avaliar a performance de um projeto numa fase inicial nos termos de múltiplos índices de performance e requisitos e preferências dos clientes. O protótipo lida com um sistema HVAC sob incertezas de carga de pico de refrigeração, incluindo as principais etapas de qualificação de incerteza, previsão de carga de pico, dimensionamento de componentes de HVAC e MCDM. As incertezas são qualificadas utilizando distribuição estatística. Como vários índices de desempenho são considerados no projeto, o tamanho dos componentes do sistema cai sobre a estrutura da MCDM.

(3.2.2) O reconhecimento de padrões é utilizado de forma semelhante a métodos estatísticos através de modelos computacionais baseados em redes neuronais e aprendizagem de dados. Técnicas de classificação ou regressão são aplicados aos dados através de algoritmos classificadores. Estes métodos dependem de aprendizagem supervisionada.

Gálvez et al. (2021) propuseram uma abordagem híbrida para ultrapassar o problema da falta de dados de falhas em um sistema HVAC instalado num comboio de passageiros. O método proposto combina modelos físicos com modelos orientados por dados para implementar processos de diagnóstico e prognóstico num sistema complexo. O modelo, baseado em física, gera dados sobre condições de trabalho saudáveis e defeituosas; as falhas são produzidas em diferentes níveis de degradação

e podem aparecer individualmente ou em conjunto. Uma fusão de dados sintéticos e dados medidos é usada para treinar, validar e testar o método para FDD do sistema HVAC.

4. Diagnóstico de falhas

O diagnóstico de falhas é o processo de localização dos fatores físicos provocantes da falha, o objetivo principal é descobrir o tipo, localização e causa da falha detetada. Os métodos utilizados para obter um mapeamento dos sintomas são complexos mecanismos de inferência. O diagnóstico de falhas divide-se em duas etapas: o isolamento e a identificação.

(1) Isolamento da falha, responsável pela determinação do tipo, localização no sistema, e, possivelmente, o tempo de ocorrência. A função primária do isolamento da falha é a identificação do defeito específico de uma lista de possibilidades baseadas nos sintomas aparentes. Esta fase é complexa devido a possibilidade de não ser possível isolar completamente uma falha de uma forma distinta. Uma falha pode resultar em múltiplos sintomas. No entanto, falhas distintas podem resultar em sintomas semelhantes.

(2) Identificação da falha, responsável pela determinação da severidade e variação no tempo da falha. Os métodos de identificação de falhas confundem-se com os métodos de deteção. Estes métodos baseiam-se também em métodos baseados em conhecimento ou em dados. A identificação de falhas inclui, além da deteção, a atribuição da falha a um componente específico. A particularização é uma parte do diagnóstico de falhas que não está contemplado na deteção.

A utilização de gráficos de fluxo de informação permite associar previamente sintomas – ativação de parâmetros, cujos valores estão fora da gama de funcionamento nominal – a falhas através de métodos de análise como por exemplo, uma árvore de falhas, uma árvore de eventos, ou uma FMEA. Estas análises através de conhecimento do especialista permitem criar não só uma árvore de relações entre falhas e os respetivos sintomas, ou parâmetros, assim como a hierarquia entre falhas e a sua criticidade.

Du et al. (2014) apresentam uma ferramenta robusta de diagnóstico para melhorar a eficiência energética e o conforto térmico de unidades de tratamento de ar. Através de uma combinação de técnicas de classificação utilizando redes neuronais foi possível detetar anormalidades em unidades de tratamento de ar. Com a combinação de redes básicas e auxiliares, utilizando tecnologias de exploração de dados, análise de agrupamentos e classificadores foi possível detetar, isolar e identificar diferentes

modos de falha. Novas falhas foram reconhecidas e inseridas na base de dados de modo a complementar a biblioteca.

Padmanabh et al. (2021) apresentam uma abordagem sistemática para a análise de múltiplos fluxos de dados de chillers para identificar potenciais falhas. Os fluxos de dados provenientes dos sensores do ecossistema de chillers monitorizam os parâmetros. Os chillers têm mecanismos instalados para gerar alarmes quando os valores dos sensores atingem valores para além de limites determinados por conhecimento especialista. Certas combinações desses alarmes, definidas por regras heurísticas, levam à deteção e diagnóstico de uma falha.

5. Avaliação de falha

A avaliação de falha é o processo de avaliação dos danos impactantes da falha para o sistema, assim como a alocação dos custos da manutenção. Esta avaliação é feita normalmente baseada na experiência do especialista do sistema e da sua natureza, ou em estudos estatísticos de dados históricos de manutenção de sistemas semelhantes ou equivalentes.

6. Ações

Dependendo do resultado da avaliação de falha o sistema pode ou não desencadear ações, se possível, segundo a criticidade da falha. Algumas falhas podem exigir a paragem imediata do sistema, em casos que a integridade do sistema ou segurança das pessoas está em causa. Outras falhas menos graves podem ser apenas monitorizadas até o custo da reparação ser justificado.

2.3 Teoria de Dempster-Shafer

A Teoria Matemática da Evidência foi introduzida por Dempster em 1967 e desenvolvida por Shafer em 1976. A teoria é uma generalização da Teoria Bayesiana, que considera a incerteza e a imprecisão, simultaneamente. A teoria é de importância significativa devido a elucidar as crenças existentes sobre um evento ou vários eventos como conjuntos. Com o auxílio dessa teoria, é possível avaliar e compor as evidências existentes de uma situação. (Zadeh, 1986)

Zadeh (1986) apresentou uma abordagem simples à teoria de DST no contexto de bases de dados relacionais. Este ponto de vista clarificou alguns dos problemas controversos da DST e facilitou a sua utilização em aplicações de AI. A visão relacional da DST delineada expôs ideias e suposições básicas subjacentes da teoria, tornando-a mais compreensível. Apontou para extensões da teoria nomeadamente

em aplicações à AI: a extensão para relações de segunda ordem em que os dados de entrada não estão restritos a valores nítidos e que as suas distribuições podem ser especificadas sem precisão; e a extensão que relaciona a combinação de fontes de informação com credibilidades diferentes.

Yager (1987) discutiu os conceitos básicos da abordagem DS, atribuições básicas de probabilidade, funções de crença e funções de probabilidade. Discutiu como representar vários tipos de conhecimento nesta estrutura. Discutiu medidas de entropia e especificidade para estruturas de crença. Discutiu a combinação e extensão das estruturas de crença. Apresentou algumas preocupações associadas à regra de combinação de Dempster inerente à normalização devido ao conflito. Apresentou duas técnicas alternativas para combinar estruturas de crenças. A primeira usando a regra de Dempster, enquanto que a segunda é baseada numa modificação dessa regra. Discutiu a questão da credibilidade de uma testemunha. Focou-se maioritariamente em fornecer uma metodologia para combinação de evidência na estrutura de DS que evitasse os problemas identificados por Zadeh (1986).

2.3.1 Teoria de Bayes

A inferência Bayesiana é um método de inferência estatística que utiliza fundamentalmente o teorema de Bayes para atualizar a probabilidade de uma hipótese à medida que mais informação ou evidências são disponibilizadas. A teoria adota três axiomas para o grau de crença numa certa evidência e a regra da probabilidade condicional para atualizar a probabilidade da hipótese quando novas evidências são consideradas. Nos três princípios básicos são listados, $P(A)$ representa a probabilidade de um evento A , definido pela frequência do mesmo baseado em observações prévias. (Guo, 2004)

1. $P(A) \rightarrow [0,1]$
2. Se A representa um evento, então $P(A) = 1$
3. Se A e B são eventos mutuamente exclusivos, então $P(A \cup B) = P(A) + P(B)$

Na teoria Bayesiana, uma probabilidade anterior (*prior*) subjetiva é atribuída a uma preposição. Novas evidências são incorporadas de modo a atualizar a probabilidade anterior para uma probabilidade posterior. O teorema de Bayes pode ser representado como

$$P(A|B) = \frac{P(A)P(B|A)}{P(B)} \quad (2.1)$$

A é o vetor de parâmetros que interessam e B é o vetor de observações prévias. O teorema de Bayes também é denominado a regra de probabilidade condicional de Bayes. $P(A|B)$ é a função de densidade posterior para A sintetizando toda a informação sobre B. $P(B|A)$ é a informação algebricamente equivalente a probabilidade para A, e $P(A)$ é a probabilidade anterior representando a opinião do especialista sobre A. O teorema pode ser reescrito como

$$\textit{Probabilidade condicional posterior} \propto \textit{Probabilidade anterior} \times \textit{Observação} \quad (2.2)$$

O teorema de Bayes e a regra de probabilidade condicional de Bayes são a base da inferência Bayesiana, a atualização da probabilidade de uma hipótese com base em conhecimento adquirido. O valor desta expressão permite a quantificação e sistematização da ideia da constante alteração de probabilidades de uma hipótese, quando considerando novas evidências. A inferência Bayesiana é um mecanismo de inferência correto e bem fundamentado matematicamente se a probabilidade anterior for conhecida. No entanto, a teoria Bayesiana não permite lidar com a falta de informação e incerteza.

2.3.2 Fundamentos da Teoria de Dempster-Shafer

A DST permite-nos combinar evidências de diferentes especialistas e de outras fontes de modo a obter uma medida de confiança que certo evento possa acontecer. Uma característica desta teoria é a possibilidade de categorizar incertezas decorrentes devido à falta de conhecimento como probabilidades discretas associadas a um conjunto de valores. A DST pode ser interpretada como uma generalização da teoria probabilística onde as probabilidades são atribuídas a conjuntos em vez de serem atribuídas a acontecimentos exclusivos. Tradicionalmente, a evidência é associada a um evento possível. Na DST, a evidência pode ser associada a múltiplos eventos, na forma de conjuntos.

Uma das características mais importantes da teoria de Dempster-Shafer é que foi concebida para lidar com níveis de precisão diferentes no que diz respeito à informação e não são necessários mais pressupostos para representar a informação. Também permite a representação direta da incerteza das respostas do sistema onde uma entrada imprecisa pode ser caracterizada por um conjunto, ou um intervalo, e a saída resultante é também um conjunto, ou um intervalo. (Sentz & Ferson, 2002)

Pappalardo (2006) utilizou a DST quando a informação não era suficiente

ou a existente era ambígua, incompleta ou em conflito, para obter a métrica necessária para aplicar o segundo axioma da AD – minimizar a informação e maximizar a probabilidade de sucesso. A informação está relacionada com a probabilidade Bayesiana, mas quando está incompleta esse modelo não pode ser utilizado. A DST é um método para raciocínio sob incerteza.

Existem três funções importantes na DST: a função de massa de probabilidade básica (*bpa* ou m), a função de crença (*bel*) e a função de plausibilidade (*pl*). A massa de probabilidade básica para o conjunto A , $m(A)$, expressa a evidência que suporta a premissa de um elemento X , do universo, pertencer ao conjunto A e a mais nenhum subconjunto. Formalmente m é representada por três condições, onde $P(X)$ representa os conjuntos de potência do universo de X , \emptyset o conjunto vazio, e A um conjunto pertencente a X :

1. $m: P(X) \rightarrow [0,1]$
2. $m(\emptyset) = 1$
3. $\sum_{A \in P(X)} m(A) = 1$

Análogo à teoria probabilística, se A e B forem acontecimentos e $P(A)$ a probabilidade do acontecimento A acontecer, a massa de probabilidade de A é a probabilidade de A acontecer exclusivamente no universo de acontecimentos. $P(A)$ considera a possibilidade de A acontecer independentemente de B acontecer ou não. $m(A)$ considera o acontecimento B , se A e B acontecerem ao mesmo tempo, a $m(A,B)$ é influenciada.

A partir da massa de probabilidade básica, os limites inferior e superior de um intervalo podem ser calculados. O intervalo contém a probabilidade precisa do conjunto de interesse. O limite inferior, crença (*belief*), Equação 2.3, é definido como a soma das massas de probabilidade dos subconjuntos (B) de um conjunto de interesse ($B \subseteq A$). O limite superior, plausibilidade (*plausibility*), Equação 2.4, é a soma de todas as massas de probabilidade dos conjuntos (B) que intersejam o conjunto de interesse ($B \cap A \neq \emptyset$).

$$Bel(A) = \sum_{B \subseteq A} m(B) \quad (2.3)$$

$$Pl(A) = \sum_{B \cap A \neq \emptyset} m(B) \quad (2.4)$$

O valor da função crença para cada conjunto é igual à soma das massas de probabilidade dos conjuntos cuja união é igual ao próprio conjunto. O valor de crença é o limite inferior de probabilidade e é o valor que suporta diretamente a hipótese. A crença mede a força da evidência perante uma hipótese. O valor da função plausibilidade para cada conjunto é igual à soma das massas de probabilidade dos conjuntos cuja interseção não é vazia. O valor de plausibilidade é o limite superior de probabilidade porque considera toda a evidência que não contradiz a hipótese.

Considerando o seguinte conjunto, {"a"}, {"b"} e {"a", "b"} com massas de probabilidade de respectivamente, 0,5, 0,3 e 0,2. O valor da função crença para o conjunto {"a"} é igual à sua massa de probabilidade porque não tem nenhum subconjunto associado. O valor da função plausibilidade é igual à soma entre os conjuntos cuja interseção com o conjunto não é vazia ($m(\{"a"\}) + m(\{"a", "b"\}) = 0,7$), (Tabela 2.1). O mesmo raciocínio é aplicado aos seguintes conjuntos para obter os restantes valores das funções de crença e plausibilidade.

TABELA 2.1: Cálculo dos valores de crença e plausibilidade

| Conjuntos | Massas | Crença | Plausibilidade |
|------------|--------|--------|----------------|
| {"a"} | 0,5 | 0,5 | 0,7 |
| {"b"} | 0,3 | 0,3 | 0,5 |
| {"a", "b"} | 0,2 | 1 | 1 |

Cavique et al. (2021) apresentam uma abordagem metódica, baseada nos princípios de AD, sustentada pela DST, para resolver eventos futuros. Em cenários com alta incerteza é utilizada a DST – para definir as funções de crença e plausibilidade da probabilidade de sucesso – e a AD como ferramenta para um bom projeto – uma sólida estrutura de abordagem a catástrofe. Este artigo define o que é um cenário usando a metodologia em AD – definida por necessidades e constrangimentos; apresenta uma abordagem para calcular o conteúdo da informação; e descreve uma estratégia defensiva para “fornecer as necessidades básicas de água para a população” em resposta a uma emergência de escassez de água.

2.3.3 Combinação de Evidências

A combinação de evidências tem o objetivo de agregar e sintetizar informação de múltiplas fontes. A regra de combinação de evidências da DST apoia-se na hipótese que as fontes de informação são independentes. As regras de combinação são métodos de agregação de informação de várias fontes. Existem várias formas de

agregar informação, as mais básicas são a interseção e a união de conjuntos. Numa situação onde todas as fontes são consideradas adequadas, uma operação conjuntiva pode ser utilizada (A e B e C ...). Noutra situação em que apenas existe uma fonte adequada é utilizada uma operação disjuntiva (A ou B ou C ...). Algumas situações requerem uma conjunção entre as duas operações, considerando relações mais complexas (A e B ou C, A e C ou B ...).

A regra de combinação de múltiplas massas de probabilidade básica de Dempster destaca fortemente a paridade de várias fontes de informação e ignora toda a informação contraditória, através de um fator de normalização. A regra de Dempster é uma regra de combinação conjuntiva, apenas sendo consideradas operações de interseção de conjuntos. A combinação de duas evidências, duas massas de probabilidade de dois conjuntos, para o subconjunto A é igual à soma dos produtos das massas de probabilidade dos dois conjuntos quando a interseção entre os dois ($B \cap C$) for igual a A, escrita como

$$m_{12}(A) = \frac{\sum_{B \cap C = A} m_1(B)m_2(C)}{1 - K} \quad (2.5)$$

sendo, $A \neq \emptyset$ e $m_{12}(\emptyset) = 0$ e,

$$K = \sum_{B \cap C = \emptyset} m_1(B)m_2(C) \quad (2.6)$$

K representa a massa de probabilidade básica associada com o conflito da informação. K é a soma dos produtos das massas de probabilidade dos conjuntos cuja interseção é nula. O denominador 1-K na regra de Dempster é o fator de normalização, ignorando completamente o conflito entre os dois conjuntos, atribuindo ao conjunto nulo, qualquer massa de probabilidade associada ao conflito. (Yager, 1987)

Considerando o conjunto anterior como conjunto 1 e o seguinte, {"a", "b"} e {"b", "c"} com massas de probabilidade de respetivamente, 0,4 e 0,6, como conjunto 2, a combinação de evidências segundo a regra de Dempster é demonstrada na Tabela 2.2.

A combinação de evidência para o subconjunto {"a"} é, numa primeira fase, apenas o produto de {"a"} com {"a", "b"}. Para o subconjunto {"b"} é a soma entre três produtos: {"b"} com {"a", "b"}, {"b"} com {"b", "c"} e {"a", "b"} com {"b", "c"}. Para o subconjunto {"a", "b"} é o produto de {"a", "b"} com {"a",

TABELA 2.2: Combinação do conjunto 1 e do conjunto 2

| Combinação de Evidências | | | Conjunto 1 | | |
|--------------------------|------------|-----|------------|-------|------------|
| | | | {“a”} | {“b”} | {“a”, “b”} |
| | | | 0,5 | 0,3 | 0,2 |
| Conjunto 2 | {“a”, “b”} | 0,4 | {“a”} | {“b”} | {“a”, “b”} |
| | | | 0,2 | 0,12 | 0,08 |
| | {“b”, “c”} | 0,6 | vazio | {“b”} | {“b”} |
| | | | 0,3 | 0,18 | 0,12 |

“b”}. A interseção de {“a”} com {“b”, “c”} resulta num conjunto vazio. O valor de K é igual à soma dos produtos cuja interseção é nula ($K=0,5 \times 0,6=0,3$). Os resultados dos produtos podem ser corrigidos com o valor de K, Tabela 2.3, para obter as massas de probabilidade da combinação de evidências dos dois conjuntos:

TABELA 2.3: Cálculos da Combinação dos conjuntos

| Conjunto | Operação inicial | Correção após K | Bel | Pl |
|------------|--|----------------------|-------|-------|
| {“a”} | $0,5 \times 0,4=0,2$ | $0,2/(1-0,3)=0,286$ | 0,286 | 0,4 |
| {“b”} | $0,3 \times (0,4+0,6)+0,2 \times 0,6=0,42$ | $0,42/(1-0,3)=0,6$ | 0,6 | 0,714 |
| {“a”, “b”} | $0,2 \times 0,4=0,08$ | $0,08/(1-0,3)=0,114$ | 1 | 1 |
| K | $0,5 \times 0,6=0,3$ | | | |

Dutta (2015) propõe uma tentativa de combinação de estruturas DS com uma conjunção de elementos focais discretos e difusos. A incorporação de elementos focais difusos permite o cálculo dos limites de crença e plausibilidade. A técnica proposta é aplicada a um caso de avaliação de risco da saúde de um indivíduo quando exposto a água contaminada. O risco é calculado através da multiplicação de diversos fatores, alguns obtidos discretamente, outros estimados através de funções de pertinência difusas. Estas funções são uma combinação de várias funções, cada uma com a sua massa de probabilidade para a obtenção de uma melhor ajustada.

A combinação de evidências tem de ser utilizada corretamente, uma aplicação incorreta pode levar a obtenção de resultados fictícios. O aspeto da normalização das massas de probabilidade após a combinação dos conjuntos pode ser prejudicial

no caso de conjuntos que não estejam representados em ambas as evidências. É importante que as estruturas a serem combinadas tenham acontecimentos que se interessem, mesmo com probabilidades baixas.

Por exemplo, um indivíduo fala com dois médicos devido a um sintoma que tem. O primeiro médico acredita que o paciente tem meningite, com uma probabilidade de 99% ou um tumor no cérebro, com uma probabilidade de 1%. O segundo médico acredita que o paciente tem um traumatismo, com uma probabilidade de 99% ou um tumor no cérebro, com uma probabilidade de 1%. Segundo a regra da combinação de Dempster a massa de probabilidade e o valor de crença para a hipótese do indivíduo ter um tumor no cérebro é igual a um. (Exemplo retirado de Sentz e Ferson (2002)).

Capítulo 3

Modelo

Este capítulo tem como principal objetivo introduzir e descrever a metodologia utilizada na criação de um programa MATLAB de FDD para um sistema de refrigeração. A metodologia descrita pode ser aplicada a vários sistemas de refrigeração, devido às regras e princípios fundamentais que os descrevem. Esta metodologia pode ser também aplicada a diversos sistemas complexos com possibilidade de aquisição de dados se houver um entendimento do seu funcionamento. Devido ao facto de não ter sido possível obter dados do sistema de refrigeração do navio foi utilizada a instalação descrita no Capítulo 1 para modelação e validação do programa desenvolvido. Os dados do sistema são adquiridos através de um dispositivo de controlo remoto, via web, ligado à instalação.

3.1 Fundamentos Teóricos

O objetivo principal do programa desenvolvido em MATLAB é a deteção e o diagnóstico de condições que levem a falhas no sistema de refrigeração. O diagnóstico é obtido através da abdução de sintomas do sistema. Estes sintomas são reflexão do comportamento de certos parâmetros, cujos valores são interpretados pelo programa.

O número limitado de parâmetros lidos do sistema reduz o número de sintomas que podem ser detetados e por sua vez o número de falhas que podem ser diagnosticadas. A seleção das falhas para análise é produto de uma FMEA.

O estudo de um sistemas de climatização como sistema complexo permitiu a compreensão das relações e interações entre os parâmetros que o descrevem. A estruturas DS criadas associam o estado de cada parâmetro com um conjunto de

acontecimentos (falhas) associados a uma probabilidade de ocorrência. A consideração de acontecimentos conjuntos permite o cálculo dos valores dos limites de crença e plausibilidade.

A aplicação dos conjuntos difusos na definição do estado de um parâmetro, permite a consideração de um grau de pertença ao respetivo estado que permite a manipulação das probabilidades das estruturas DS associadas.

A combinação de evidências permite a obtenção de um diagnóstico mais fiável e robusto.

O sistema de refrigeração para teste já tem alarmes e pré-alarmes instalados. As falhas estudadas são falhas que já ocorreram, o objetivo do estudo é a compilação de informação para poder diagnosticar as respetivas falhas antecipadamente. Falhas relacionadas com o compressor não são tratadas diretamente no programa. Breuker (1997) afirmou que a maioria das falhas do compressor resultam da sobrecarga do motor devido a falhas noutros componentes do sistema.

Falhas no condensador e no evaporador não são tão comuns como as referidas mas podem ser severamente impactantes a nível de custo. O funcionamento da instalação em condições anormais provocado por falhas no condensador e no evaporador sobrecarregam o compressor. Falhas no compressor são facilmente detetadas, mas no evaporador e no condensador não tanto. O objetivo do programa é detetar falhas ao nível destes componentes de modo a evitar modos de falha mais graves a nível do compressor.

3.1.1 Aplicação da Teoria de Dempster-Shafer

A DST permite considerar incerteza e falta de informação e também permite atribuir valores probabilísticos a conjuntos de falhas possíveis. Os fundamentos da DST foram aplicados no programa em três situações distintas: na obtenção de estruturas que contêm os modos de falha e as respetivas massas de probabilidade; na regra de combinação de evidências de Dempster para combinação de determinadas estruturas - a criação dos três grafos para avaliação; e no cálculo dos limites de crença e plausibilidade das estruturas correspondentes.

A relação dos sintomas dos modos de falha com os parâmetros selecionados para a avaliação de falha é descrita através de estruturas que seguem os princípios da DST. As estruturas referidas relacionam o estado dos parâmetros selecionados com as falhas e probabilidades associadas referentes ao respetivo estado. Foram analisados quatro parâmetros: pressão e temperatura do condensador, pressão do

evaporador e diferença de temperatura de água no evaporador. Para cada parâmetro consideraram-se três estados possíveis em relação aos valores expectáveis: baixo, normal e alto. Em Li et al. (2021) também foram considerados os mesmos três estados para definir os parâmetros analisados nas BN. Os valores expectáveis são calculados com base nas temperaturas do ar exterior e da água, respetivamente. Estes permitem obter um valor de referência para comparação com os valores lidos pelo sistema.

As condições de falha consideradas para o programa de deteção e diagnóstico são interpretadas como acontecimentos cuja probabilidade de ocorrência depende do estado do parâmetro a que estão associadas. A diminuição de permuta de calor no condensador “PC” está associada à combinação de um diagnóstico de temperatura e pressão do condensador mais elevada que o expectável. A diminuição de permuta de calor no evaporador “PE” pode estar associada ao aumento da diferença entre as temperaturas de entrada e saída de água do evaporador. O estado dos valores de pressão, do condensador e evaporador, estão associados aos níveis de refrigerante do sistema. O excesso de refrigerante “ER”, está associado a níveis de pressão elevados enquanto que a falta de refrigerante “FR” está associada a níveis de pressão mais baixos. A pressão do condensador tem um maior grau de liberdade em termos de variação do que a pressão do evaporador. Devido à evolução logarítmica de pressão com a temperatura do refrigerante, valores mais altos admitem variações maiores. O diagnóstico destes dois acontecimentos é centrado então na avaliação da pressão do evaporador. Os valores de pressão e temperatura expectáveis são calculados a partir das condições exteriores.

A estas condições de falha estão associados um conjunto de causas possíveis. A falta de permuta no condensador pode ser causada por uma obstrução no condensador, uma avaria no ventilador, ou ainda, filtros colmatados e aletas corroidas. A falta de permuta no evaporador pode ser causa de uma redução no caudal de água de arrefecimento, esta poderá ser causada por uma avaria na bomba, por filtros colmatados ou por uma manobra incorreta de válvulas.

Além das condições de falha foram considerados mais dois acontecimentos: o funcionamento normal da instalação “FN” e erros ao nível de sensores ou controladores “SC”.

É possível existir informação contraditória ao longo do diagnóstico de falhas. Na instalação em questão, o compressor não trabalha constantemente, é controlado através da temperatura de entrada de água no evaporador, controlo do retorno, e de uma gama de variação aceitável. O compressor em questão também não tem

estágios sendo um compressor ON/ OFF. Durante os arranques do compressor é natural que sejam verificadas algumas discrepâncias nos parâmetros do sistema, e que nos parâmetros de pressão sejam registados muitas vezes valores de pico. No entanto não só os acontecimentos correspondentes ao arranque do compressor são descartados no filtro inicial dos dados, como também é aplicada uma média móvel aos valores obtidos. A possibilidade de ser detetada uma falha devido a um regime de transição é reduzida. Uma explicação possível para a existência de informação contraditória pode ser o mau funcionamento de um sensor ou de um controlador.

Para os três estados considerados dos quatro parâmetros observados, obtém-se doze condições de falha. Para cada estado dos parâmetros avaliados, cada estrutura DS, foram definidas várias possíveis falhas, acontecimentos, e as probabilidades correspondentes. As falhas atribuídas a cada estado dos parâmetros selecionados e as massas de probabilidade associadas foram determinadas com base na FMEA realizada e na opinião conjunta de especialistas na área. Dependendo do parâmetro e do respetivo estado as probabilidades destes acontecimentos assumem valores diferentes. A estrutura associada a um estado de um respetivo parâmetro terá massas de probabilidade mais elevadas nos acontecimentos correspondentes às falhas esperadas dos sintomas, correspondendo ao estado do respetivo parâmetro. Além da consideração de modos de falha, também foi considerado um modo normal de funcionamento e um modo de falha associado a problemas ou erros relacionados com sensores e controladores.

Em cada estrutura é considerada a possibilidade de dois acontecimentos estarem a acontecer ao mesmo tempo. Isto é possível através da consideração de um acontecimento conjunto. Devido a estes acontecimentos conjuntos é possível proceder ao cálculo dos valores dos limites de crença e plausibilidade.

A combinação de informação de duas fontes permite uma melhor interpretação de um determinado resultado. A combinação de evidências dos dois parâmetros associados ao condensador permite obter um diagnóstico mais apropriado à situação real. A combinação das estruturas associadas leva à criação de três estruturas finais, correspondendo a três grafos diferentes: o diagnóstico de falha segundo a avaliação da pressão e temperatura do condensador, da pressão do evaporador e da diferença entre as temperaturas de entrada e saída de água de arrefecimento. A cada grafo pode corresponder um resultado diferente mediante o estado dos respetivos parâmetros.

Inicialmente as estruturas foram obtidas com base em conhecimento especialista. Reuniram-se as falhas possíveis e a sua probabilidade de ocorrência para

os possíveis estados de cada parâmetro. As doze estruturas recolhidas inicialmente estão enumeradas no Anexo II. No entanto, as falhas e as respectivas massas foram pensadas num ambiente de falha e não num ambiente de funcionamento normal com probabilidade de falha futura. Adicionalmente, a natureza da combinação de evidências da DST requer que as estruturas tenham conjuntos com mais do que uma falha - para o cálculo dos limites de crença e plausibilidade (se não existirem interseções, os limites terão o mesmo valor que a massa do próprio acontecimento). Um dos aspetos importante é que as estruturas a serem combinadas tenham acontecimentos que se interessem, mesmo com probabilidades baixas, como referido anteriormente.

Foram desenvolvidas novas estruturas, adaptadas à DST, adequadas à combinação de evidências e ao diagnóstico de falhas num sistema de refrigeração. O primeiro passo foi a seleção das falhas a aplicar no programa. Os principais acontecimentos são as falhas, selecionadas da FMEA aplicada. Para cada parâmetro e para cada estado de falha, estados “alto” e “baixo”, foi selecionada a falha com maior probabilidade de ocorrência. Existem falhas que estão associadas a mais que um estado de cada parâmetro, Tabela 3.1.

TABELA 3.1: Falhas associadas ao estado de cada parâmetro

| Falhas | | Parâmetros | | | |
|--------|-------|------------|---------|---------|--------|
| | | P. Cond | T. Cond | P. Evap | Dif T. |
| Estado | Alto | PC | | ER | PE |
| | Baixo | FR | | | |

¹ PC - Perda de Permuta de Calor no Condensador

² PE - Perda de Permuta de Calor no Evaporador

³ ER - Excesso de Refrigerante

⁴ FR - Fuga de Refrigerante

Os conjuntos de cada estrutura são baseados numa possibilidade real da interseção de acontecimentos. Para as estruturas associadas aos estados “alto” e “baixo” foram considerados três conjuntos: a interseção da falha mais provável com o acontecimento de funcionamento normal e com o acontecimento falha de sensores ou controladores, e a interseção dos acontecimentos de funcionamento normal e falha de sensores ou controladores. As massas foram atribuídas mantendo um equilíbrio entre permanecer consistente com a opinião dos especialistas e permitir a combinação das estruturas.

Recorrendo à Tabela 3.1, a falha mais provável para os parâmetros de pressão e temperatura do condensador é o “PC”, para a do evaporador é o “ER” e para a diferença de temperaturas é o “PE”. A Tabela 3.2 ilustra as falhas e massas de probabilidade das estruturas associadas a cada parâmetro, onde X é a falha mais provável associada a cada parâmetro. Apesar das massas de probabilidade estarem previamente definidas devem permitir uma liberdade de correção de modo a considerar o grau de afastamento de uma condição de funcionamento nominal. O parâmetro y é o valor de saída do sistema de inferência difuso que oscila entre os 10% negativos e positivos $([-0,1;0,1])$. Um valor de y positivo significa que o valor do parâmetro está acima do valor correspondente à condição nominal de funcionamento. As massas de probabilidade das falhas correspondentes ao estado “alto” do respetivo parâmetro aumentam com o valor de y , enquanto que as massas das falhas correspondentes ao estado “baixo” do respetivo parâmetro diminuem com o valor de y . Na situação oposta, um valor de y negativo significa que o valor do parâmetro está abaixo do valor correspondente à condição nominal de funcionamento. As massas de probabilidade comportam-se de forma oposta. A massa de probabilidade do acontecimento associado ao funcionamento normal da instalação diminui com o módulo do valor de y , devido ao facto da condição de funcionamento normal ser prejudicada por qualquer valor de y , seja positivo ou negativo. Os conjuntos são todos enumerados no Anexo III.

TABELA 3.2: Falhas e massas de probabilidade de cada parâmetro

| Alto | | Normal | | Baixo | |
|--------|------------|--------|-----------|--------|------------|
| foc | mass | foc | mass | foc | mass |
| X | $0,425+y$ | X | $0,2+y$ | X | $0,025+y$ |
| FN | $0,05- y $ | FN | $0,4- y $ | FN | $0,05- y $ |
| FR | $0,025-y$ | FR | $0,2-y$ | FR | $0,425-y$ |
| SC | 0,25 | SC | 0,1 | SC | 0,25 |
| X, SC | 0,1 | FN, X | 0,05 | FR, SC | 0,1 |
| X, FN | 0,1 | FN, FR | 0,05 | FR, FN | 0,1 |
| FN, SC | 0,05 | | | FN, SC | 0,05 |

Uma análise empírica de um sistema de refrigeração e do seu comportamento permite prever o resultado da combinação de certas evidências. As estruturas associadas à pressão e à temperatura do condensador são as estruturas combinadas para formar o primeiro grafo. As estruturas são comuns aos dois parâmetros, falhas semelhantes provocam o desvio para cima ou para baixo do valor nominal correspondente. Num sistema de detecção de falhas é importante minimizar a quantidade de alarmes falsos sem descartar a hipótese de existência de uma falha. É importante considerar as possibilidades de combinação de evidências perante os dois parâmetros, Tabela 3.3.

TABELA 3.3: Resultado provável da combinação de evidências

| Estado 1 | Estado 2 | Resultado |
|----------|----------|-----------|
| Alto | Alto | |
| Baixo | Baixo | Falha |
| Alto | Normal | |
| Baixo | Normal | |
| Normal | Normal | FN |
| Alto | Baixo | SC |

Se ambos os parâmetros são altos ou ambos são baixos, então o resultado deve ser a falha correspondente; se um é alto e o outro é normal, ou um baixo e um normal, então ainda é provável que exista a possibilidade de falha, se são ambos normais então a instalação está em funcionamento normal; finalmente se um dos parâmetros é alto e o outro baixo, é possível que a instalação esteja num regime transitório em que os parâmetros ainda não estabilizaram, ou que seja uma falha a nível de sensores e controladores.

3.1.2 Aplicação dos Conjuntos Difusos

Os conjuntos difusos permitem definir o estado de um parâmetro de uma forma mais concreta face a limites definidos com valores discretos ao considerar um grau de pertença a cada respetivo estado. Um sistema de inferência difuso é composto por três blocos principais: os parâmetros de entrada, a base de regras e os parâmetros de saída. A avaliação do estado dos quatro parâmetros passa pela criação das funções de pertença que descrevem os possíveis estados, pela avaliação

do parâmetro em questão, a ativação das regras e saída de um valor, o grau de pertença a um respectivo estado.

Os conjuntos difusos foram utilizados para definir o grau de pertença de um parâmetro ao estado correspondente. O grau de pertença é refletido num ligeiro ajuste das probabilidades de ocorrência das estruturas DS.

Para os parâmetros de pressão (pressão do condensador e evaporador), as funções de pertença são calculadas de forma análoga. O estado dos parâmetros não depende um valor fixo, mas da temperatura do ar exterior e da temperatura de saída de água, respetivamente. Em função desses parâmetros são calculados cinco valores que permitem construir as funções de pertença. Para a temperatura de condensação e diferença de temperaturas de água as funções de pertença são criadas de forma diferente porque os parâmetros correspondem a uma diferença de valores, o funcionamento normal corresponde a um intervalo difuso entre valores pré-definidos.

Após a criação das funções de pertença, o valor do parâmetro em questão é avaliado, segundo a base de regras previamente descrita. O valor de saída difuso é avaliado perante outras funções de pertença para obtenção de um valor de saída discreto.

O valor de saída corresponde ao afastamento do valor do parâmetro avaliado perante o valor ideal correspondente. Este afastamento, com um intervalo de 10% abaixo e acima do valor ideal permite descrever o estado do parâmetro correspondente com maior exatidão. Quanto mais baixo está o valor lido em relação ao valor suposto, mais perto dos 10% negativos estará o valor de saída, analogamente, quanto mais alto está o valor lido em relação ao valor suposto, mais perto dos 10% positivos estará o valor de saída. Se o valor lido corresponder ao valor pretendido, o valor de saída será zero.

A caracterização do grau de pertença ao estado alto, baixo e normal através dos conjuntos difusos permite a alteração das massas de probabilidade das estruturas correspondentes ao respetivos estados. As massas de probabilidade de falhas relacionadas com o estado alto do parâmetro aumentam com valores positivos e diminuem com valores negativos do grau de pertença, falhas relacionadas com o estado baixo do parâmetro diminuem com valores positivos e aumentam com valores negativos. Falhas relacionadas com o funcionamento normal da instalação são prejudicadas tanto com valores positivos ou negativos, as massas de probabilidade destas diminuem com o módulo do grau de pertença. As funções de pertença utilizadas

para a caracterização dos parâmetros e as constantes utilizadas para descrever as mesmas são descritas em pormenor na descrição do programa.

3.2 Programa

O programa *MATLAB* de deteção e diagnóstico de falhas tem como objetivo a identificação de falha num sistema de refrigeração. A deteção e diagnóstico é feita através da monitorização de certos parâmetros lidos pela instalação para o cálculo das percentagens de crença e plausibilidade das possíveis falhas para o respetivo estado da instalação. O programa: o *script* principal e todas as funções associadas, são apresentados no Apêndice C.

São analisados quatro parâmetros: a pressão do condensador, a temperatura do condensador, a pressão do evaporador e a diferença de temperatura de água no evaporador. Para cada parâmetro são atribuídos três possíveis estados: alto, normal ou baixo. O estado de cada parâmetro, fora do normal, pode ser provocado por possíveis falhas. A probabilidade das respetivas falhas é traduzida pelas massas de probabilidade de estruturas compostas por vários acontecimentos.

A análise dos quatro parâmetros resulta nos três grafos, sendo que as estruturas do estado da pressão e temperatura do condensador e as estruturas da pressão do condensador e do evaporador são combinadas segundo a regra de combinação de evidências de Dempster. Os resultados dos três grafos são apresentados graficamente. O programa está dividido em cinco blocos principais: aquisição de dados, pré-processamento de dados, processamento de dados, sistema de inferência difuso e combinação de evidências. Na Figura 3.1 é apresentado o fluxograma do programa desenvolvido. É possível observar os blocos principais assim como as funções fundamentais.

A aquisição de dados compreende a importação dos dados de um ficheiro *MS Excel* para uma tabela de dados. Antecedente à aquisição de dados está programada uma inicialização. A função dessa inicialização é a interação com o utilizador para seleção do dados respetivos a um dia específico para considerar no programa. Isto é possível porque os dados encontram-se todos guardados, em ficheiros diferentes, na mesma pasta. Existe ainda a possibilidade de utilizar o programa em inglês. Tanto os comandos solicitados pelo programa como as legendas e títulos dos gráficos produzidos são alterados consoante a língua selecionada.

O pré-processamento da tabela de dados é dividido em três operações principais. A seleção dos parâmetros relevantes para o programa que mantém as colunas

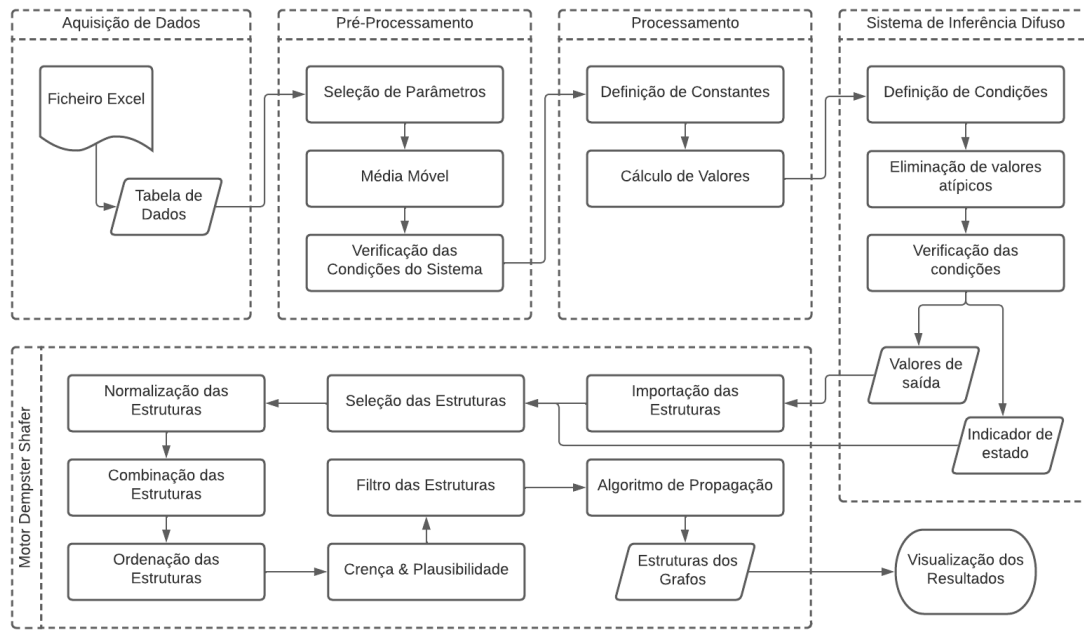


FIGURA 3.1: Fluxograma do programa desenvolvido

de dados e apaga o resto dos dados, através de um vetor de seleção de colunas. Uma operação de média móvel, para evitar discrepâncias de valores a determinados parâmetros lidos pelo sistema (temperatura do condensador, pressão do condensador e pressão do evaporador). E finalmente a verificação das condições de funcionamento do sistema de modo a filtrar dados fora das condições de funcionamento desejadas para análise de falha. É verificado o funcionamento da instalação (On/Off), o modo de funcionamento (verão/inverno), e o estado do compressor, além de quando está desligado também não é considerado o primeiro instante após o arranque do compressor devido a valores de pico no arranque, porque o programa analisa os dados do sistema em regime estacionário.

A tabela de dados segue para o processamento de dados para o cálculo de parâmetros adicionais. As temperaturas de condensação e evaporação expectáveis são calculadas através da temperatura do ar exterior e da água de saída, respectivamente, e são utilizadas para o cálculo dos limites das respectivas pressões do condensador e evaporador. São calculadas também a diferença entre as temperaturas de condensação e a diferença entre as temperatura de entrada e de saída da água de circulação, arrefecida no evaporador. Para o sistema de inferência é necessário o cálculo de cinco valores de referência para a construção das funções de pertinência: o valor de pressão, de condensação ou evaporação, correspondente à temperatura calculada, de condensação ou evaporação, e quatro outros valores: dois acima e dois

abaixo.

A função principal do sistema de inferência difuso é a definição do estado de cada parâmetro (alto, normal ou baixo) e o seu respectivo grau de pertença. Com os cinco valores obtidos no processamento são construídas cinco funções de pertença para a verificação do estado dos quatro parâmetros a analisar. O valor lido pelo sistema, para os parâmetros selecionados, é o valor de entrada do sistema de inferência. O produto do sistema de inferência é o valor que traduz o grau de pertença ao respectivo estado do parâmetro. É aplicado um algoritmo aos valores de saída de modo a detetar e corrigir variações extremas pontuais. Os valores de saída do sistema de inferência, agora corrigidos, são armazenados numa tabela. A condição de cada parâmetro é verificada e registada numa tabela indicadora de estado.

As duas tabelas criadas no sistema de inferência difusa são utilizadas na combinação de evidências segundo a teoria de Dempster Shafer. Um conjunto de doze estruturas, uma por cada estado (três estados – alto, normal e baixo) por cada parâmetro (quatro parâmetros – pressão e temperatura do condensador, pressão do evaporador e diferença das temperaturas de água) é importado para o programa. Cada estrutura é composta por um conjunto de falhas e massas de probabilidade, de acordo com a probabilidade da falha correspondente ser responsável pelo diagnóstico da respetiva estrutura. Os valores das massas de probabilidade variam ligeiramente de acordo com os valores de saída do sistema de inferência que caracterizam o grau de pertença ao respectivo estado. Das doze estruturas importadas são selecionadas apenas quatro, uma estrutura por parâmetro, correspondente ao respectivo estado segundo a tabela identificadora de estado. Com a alteração dos valores de massa de probabilidade, as estruturas são corrigidas por um algoritmo de normalização – a soma das massas de probabilidades tem de ser igual a um. O primeiro dos três grafos (grafo A), é a combinação entre as estrutura da pressão e temperatura do condensador, segundo a regra de combinação de evidências de Dempster. O segundo grafo (grafo B) é a estrutura da pressão do evaporador. O último grafo (grafo C) é a estrutura da diferença de temperaturas de água. As estruturas dos três grafos são ordenadas segundo os valores das massas de probabilidade dos respetivos acontecimentos. São calculados os limites de crença e plausibilidade e filtrados os acontecimentos com mais de uma falha associada. Por fim é aplicado um algoritmo de propagação ao conjunto de estruturas. Este algoritmo altera os valores das massas de probabilidade segundo a continuidade da ocorrência de um certo acontecimento. Ao longo do tempo, com base na estrutura anterior, o algoritmo aumenta as massas de probabilidade da respetiva estrutura com base na repetição contínua do mesmo diagnóstico.

O conjunto de estruturas para cada grafo é importado para a última função do programa de modo a permitir a visualização dos resultados. As massas de probabilidade dos valores de plausibilidade e de crença, para cada falha, são apresentadas num gráfico de barras.

Para uma melhor compreensão do programa é seguido um exemplo do diagnóstico do primeiro grafo das 8h39 de dia 29 de junho. Este exemplo acompanha desde a aquisição de dados uma entrada de dados correspondente aos valores de todos os parâmetros lidos pela instalação no instante considerado. O diagnóstico final pode ser verificado no primeiro grafo (gráfico de topo) da Figura 4.4. Devido à semelhança entre grafos, apenas vão ser expostas as operações relativas ao primeiro grafo, incluindo a combinação de evidências.

3.2.1 Aquisição e Estrutura de Dados

A aquisição dos dados de entrada compreende à aquisição e ao armazenamento dos parâmetros do sistema de refrigeração. A aquisição de dados do sistema é feita através de um dispositivo de controlo remoto, via web, instalado num sistema de refrigeração. Os dados e alarmes recolhidos pelo dispositivo são exportados para um ficheiro *MS Excel*. Durante uma semana é gravado um ficheiro diário, em que o sistema regista dados a cada minuto. Todos os dados e alarmes recolhidos pelo dispositivo são enumerados no Anexo I. Os dados do ficheiro *MS Excel* são importados para uma tabela de dados.

É possível observar a evolução da estrutura dos dados ao longo do programa na Figura 3.1. As estruturas de dados são identificadas pela forma romboidal. Os dados lidos do ficheiro *MS Excel* são armazenados no programa numa tabela. A tabela de dados é lida pelos vários módulos do programa. O pré-processamento modifica os dados da tabela enquanto que o processamento adiciona dados à tabela. O sistema de inferência lê a tabela de dados e cria duas tabelas de dados adicionais: a tabela com os valores de saída e a tabela com os indicadores de estado. As duas novas tabelas são utilizadas, respetivamente, pelas funções de importação e seleção das estruturas DS. Estas estruturas compostas por dois campos: as falhas e massas de probabilidade associadas ao um respetivo estado de um determinado parâmetro. Às estruturas correspondem quatro parâmetros, mas com a combinação de evidências as mesmas resultam em três grafos. O resultado do programa é obtido pela produção de gráficos através da leitura dos dados das estruturas DS de cada um dos grafos.

Relativamente ao exemplo mencionado acima, são enumerados os dados recolhidos imediatamente antes e depois do instante observado, Tabela 3.4, de modo a ser possível visualizar o efeito da média móvel nos dados de entrada.

TABELA 3.4: Exemplo - Dados de entrada

| Hora | T. Cond | T. Ar | P. Cond |
|-------|---------|---------|----------|
| 8h38m | 30,5 °C | - | 18,2 bar |
| 8h39m | 30,5 °C | 16,2 °C | 18,6 bar |
| 8h40m | 30,7 °C | - | 18,6 bar |

3.2.2 Pré-Processamento de Dados

A maioria dos dados adquiridos inicialmente são alarmes, pré-alarmes ou parâmetros de configuração. Para o programa apenas interessam os parâmetros que permitem descrever o estado termodinâmico do sistema assim como alguns dados de controlo. Os dados da tabela são filtrados por um vetor de modo a obter apenas os dados de interesse, enumerados na Tabela 3.5.

TABELA 3.5: Dados de entrada - Parâmetros do sistema

| Descrição | Variável | Unidade |
|--------------------------------|-----------|---------|
| Hora de registo | Timestamp | s |
| Temperatura de entrada de água | tiA | °C |
| Temperatura de saída de água | tuA | °C |
| Temperatura do condensador | tSb | °C |
| Temperatura do ar exterior | tAE | °C |
| Pressão do condensador | AP | bar |
| Pressão do evaporador | bP | bar |
| Setpoint em uso | SEt | °C |
| Potência do compressor | Po | % |
| Setpoint de verão | StF | °C |
| Estado da instalação | ON/OFF | 0/1 |

Para evitar discrepâncias e valores de pico nos valores lidos de temperatura e pressão do condensador e pressão do evaporador os valores dos respetivos parâmetros são recalculados através de uma média móvel de três valores - cada valor é recalculado como a média entre si e os valores imediatamente acima e abaixo.

Os valores do instante observado no exemplo passam a ser os seguintes, Tabela 3.6. Estes dados são agora verificados pela função `Filter`. Não é ilustrado,

mas para efeitos de exemplo, foi escolhido um instante em que a instalação reúne todas as condições de funcionamento.

TABELA 3.6: Exemplo - Pré-Processamento de Dados

| Hora | T. Cond | T. Ar | P. Cond |
|-------|------------|---------|-------------|
| 8h39m | 30,5667 °C | 16,2 °C | 18,4667 bar |

A função **Filter** é responsável pelo filtro da tabela de dados de modo a obter apenas os dados em condições favoráveis de avaliação. A primeira verificação é o estado da instalação – assume valores binários consoante o funcionamento da instalação, estando desligada, os dados referentes a essa hora são eliminados. A segunda verificação é o modo de funcionamento – o valor do setpoint em uso é comparado com o setpoint de verão, apenas são admitidos dados com a instalação a trabalhar em modo de refrigeração. A terceira e última verificação é o estado do compressor, um ciclo que percorre as linhas da tabela verifica se o compressor está ou não em funcionamento – o parâmetro assume valores de zero ou cem por cento, detetando também o instante em que o mesmo arranca – valores em estado transitório são desprezados de forma a evitar valores de pico. Após cada verificação as colunas envolvidas são eliminadas para diminuir a quantidade de dados da tabela.

3.2.3 Processamento de Dados

O primeiro passo do processamento de dados é a definição das constantes utilizadas para o cálculo dos valores complementares. Estas constantes foram inicialmente obtidas através de conhecimento especialista sobre os sistemas de refrigeração, mas refinadas numa fase de calibração do sistema.

O estado de cada parâmetro é determinado segundo o grau de pertença a cada estado determinado pelo sistema de inferência difuso. O sistema difuso constrói as funções de pertença segundo valores dependentes de condições ambientais. Para cada avaliação é necessário proceder ao cálculo de cinco valores que permitem a posterior avaliação. Os limites definidos para a classificação do estado das pressões de condensação e de evaporação são calculados. O estado da temperatura do condensador depende da diferença entre a temperatura lida do condensador e a temperatura expectável de condensação. O estado da diferença das temperaturas de entrada e saída de água também é determinado através de dois valores limites, mas estes valores são pré-definidos. A diferença das temperaturas de entrada e saída de água é calculada através da subtração da temperatura de entrada de água pela temperatura de saída de água.

A pressão de condensação depende da temperatura de condensação e esta da temperatura do ar exterior. À temperatura do ar exterior são somados 10°C para obter a temperatura de condensação expectável. Essa temperatura entra numa função, `CalcLimits` para calcular os dois limites inferiores e os dois superiores da pressão de condensação, calculados através da soma, ou subtração, de uma variação ao valor de pressão expectável correspondente. A função tem valores do refrigerante utilizado na instalação, *R410a*, de modo a traçar a função polinomial ilustrada na Figura 3.2. A função permite interpolar os valores de pressão desejados dependendo da temperatura inserida. Com a temperatura de condensação expectável obtém-se a pressão expectável correspondente, P_3 . Para a pressão de condensação é admitida uma gama de variação de 5°C. Os primeiros limites de pressão inferior e superior são interpolados para a temperatura de condensação menos e mais 5°C, respetivamente, P_1 e P_5 . Os segundos valores limite são interpolados para a temperatura de condensação expectável menos e mais 5°C, mais 1°C, respetivamente, P_2 e P_4 .

Relativamente aos dados, agora pré-processados, é calculada a temperatura de condensação expectável, Tabela 3.7.

TABELA 3.7: Exemplo - Processamento de Dados (1)

| Hora | T. Cond | T. Ar | P. Cond | T. Cond expectável |
|-------|------------|---------|-------------|--------------------|
| 8h39m | 30,5667 °C | 16,2 °C | 18,4667 bar | 26,2 °C |

Com a temperatura de condensação expectável são obtidos os limites, Tabela 3.8, para as funções de pertinência para avaliação do estado da pressão. A pressão correspondente é obtida através da relação, característica para cada refrigerante, entre a temperatura e a pressão.

TABELA 3.8: Exemplo - Processamento de Dados (2)

| | P1 | P2 | P3 | P4 | P5 |
|------------------------------|---------|---------|---------|---------|---------|
| Temperatura (°C) | 20,2 | 21,2 | 26,2 | 31,2 | 32,2 |
| Pressão correspondente (bar) | 13,4238 | 13,8352 | 16,0365 | 18,4780 | 18,9951 |

A pressão de evaporação depende da temperatura de evaporação e esta da temperatura de entrada de água. À temperatura de entrada de água são subtraídos 10°C para obter a temperatura de evaporação expectável. Essa temperatura entra na mesma função, `CalcLimits`, para calcular os limites inferior e superior da pressão de evaporação. Com a temperatura de evaporação expectável obtém-se a pressão expectável correspondente, P_3 . Para a pressão de evaporação é admitida uma gama de variação de 4°C. Os limites de pressão inferior e superior são interpolados para a temperatura de evaporação menos e mais 5°C, respetivamente, P_1 e P_5 . Os segundos

valores limite são interpolados para a temperatura de evaporação expectável menos e mais 4°C, mais 1°C, P_2 e P_4 .

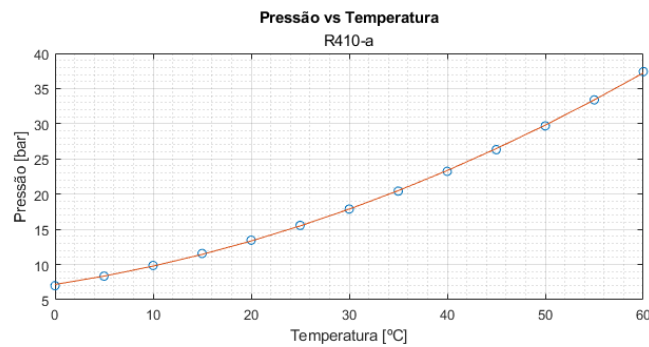


FIGURA 3.2: Função polinomial para interpolação

São adicionadas à tabela as colunas com os respectivos valores de temperatura de condensação, diferença entre as temperaturas de condensação – a temperatura calculada e a temperatura lida pela instalação, limites inferior e superior da pressão de condensação, temperatura de evaporação, limites inferior e superior da pressão de evaporação, e diferença das temperaturas de entrada e saída de água.

3.2.4 Sistema de Inferência Difuso

Com os cinco valores para cada parâmetro calculados no processamento de dados é possível construir as funções de pertinência para avaliação do estado dos parâmetros. Para obtenção dos valores de saída também são projetadas cinco funções de pertinência. A função `FuzzyFunction` é responsável por transformar os cinco valores limites e o valor do parâmetro a ser avaliado num valor y , que representa o grau de pertinência ao respectivo estado.

As funções de pertinência para a avaliação da pressão do condensador e do evaporador dependem dos valores calculados, as funções de pertinência para a avaliação da temperatura do condensador oscilam em torno de zero e as funções de pertinência para a avaliação da diferença de temperatura da água à entrada e saída do evaporador oscilam em torno de 5°C, Figura 3.3.

Para a avaliação da temperatura de condensação é calculada a diferença entre a temperatura medida e a temperatura expectável, Tabela 3.9.

TABELA 3.9: Exemplo - Processamento de Dados (3)

| T. Cond | T. Cond expectável | Diferença |
|---------|--------------------|-----------|
| 30,5 °C | 26,2 °C | 4,3 °C |

O valor de entrada nas funções de pertinência (valor no eixo das abscissas) há de corresponder a um ou mais valores ordenados, correspondentes à sobreposição das funções de pertinência. O vetor correspondente a esse resultado tem cinco elementos (um por função de pertinência representada no gráfico). A soma dos valores dos elementos do vetor é a unidade. O valor de cada elemento corresponde ao grau de pertinência a cada função e oscila entre 0 e 1.




FIGURA 3.3: Funções de Pertinência Difusas para a avaliação dos quatro parâmetros

As funções de pertinência para a obtenção dos valores de saída oscilam em torno do zero dentro de um intervalo entre -10% e +10%, Figura 3.4.

O vetor com os elementos que caracterizam o grau de pertinência a cada função de pertinência do gráfico para os valores de entrada entra agora no gráfico para os valores de saída. Cada função de pertinência deste gráfico é preenchida em porcentagem de acordo com o valor do elemento do vetor correspondente à posição das funções de pertinência do novo gráfico. O preenchimento parcial de uma ou mais funções de pertinência resulta numa área. O valor das abscissas do centroíde dessa área corresponde ao valor de saída.



FIGURA 3.4: Funções de Pertinência Difusas para a obtenção do valor de saída

Os valores da pressão e temperatura do condensador são avaliados perante as funções de pertinência difusas, Figura 3.5. A interseção do valor de entrada com as funções de pertinência corresponde à percentagem de área preenchida nas funções de pertinência de gráfico de valores de saída.




FIGURA 3.5: Exemplo - Sistema de Inferência Difuso (1)

Perante o sistema de inferência difuso, os valores de entrada considerados no exemplo são processados dando origem ao valor de y . Na Figura 3.6 é possível observar o cálculo do centroíde das áreas correspondentes aos valores das funções de pertinência interseçados pelos valores dos parâmetros reais lidos pelo sistema. O centroíde da área composta pelas duas áreas preenchidas de acordo com o seu grau de pertinência é o ponto médio entre os dois, considerando a proporção das massas correspondentes.

A função `DelOutliers` tem como principal função a eliminação de valores atípicos, através da deteção de alterações súbitas nos valores de saída do sistema de inferência. Através da leitura dos valores imediatamente acima e abaixo do valor observado, a função tem como propósito suavizar as curvas de variação e despistar qualquer valor de pico extremo.

A verificação das condições de falha através do estado dos parâmetros é aplicada simultaneamente a toda a tabela de dados. A verificação é composta em duas fases mas cada uma pode ser detalhada em várias outras. É iniciada uma tabela de zeros com quatro colunas, conforme os parâmetros avaliados – pressão do condensador, temperatura do condensador, pressão do evaporador, e diferença de temperaturas – com a dimensão da tabela de dados. A tabela identificadora do estado dos parâmetros percorre a função `CheckState` quatro vezes, uma por cada parâmetro. A função tem como valores de entrada: a tabela, os dados do

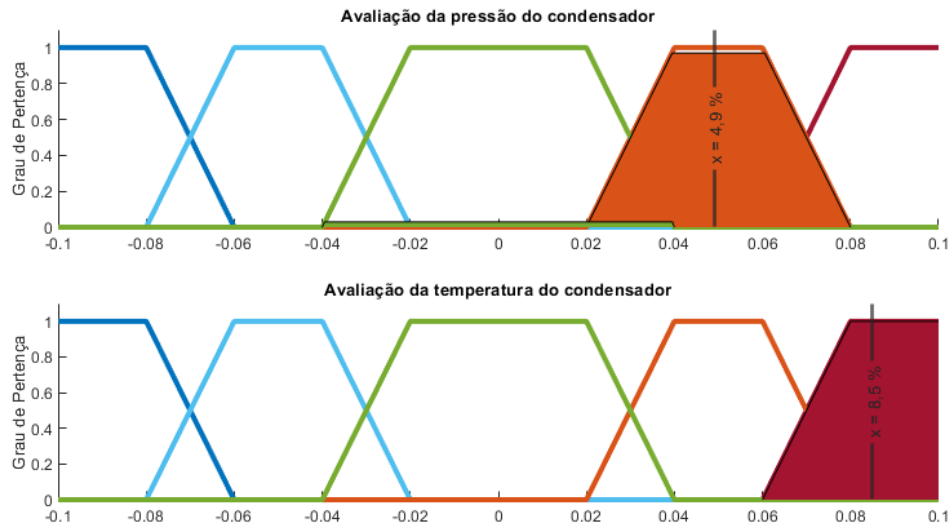


FIGURA 3.6: Exemplo - Sistema de Inferência Difuso (2)

parâmetro a avaliar, os limites inferior e superior e um identificador da condição de falha. Os identificadores para condição de falha são respetivamente um, dois, três e quatro para a pressão do condensador, temperatura do condensador, pressão do evaporador, e diferença de temperaturas.

As estruturas DS estão ordenadas segundo os parâmetros e os seus respetivos estados, o valor da tabela é que permite identificar que estrutura está associada ao estado do respetivo parâmetro, Tabela 3.10.

TABELA 3.10: Identificadores de cada estado perante cada parâmetro

| Estruturas DS | | Estado dos parâmetros | | |
|---------------|-----------|-----------------------|--------|-------|
| | | Alto | Normal | Baixo |
| Parâmetros | P. Cond | 1 | 2 | 3 |
| | T. Cond | 4 | 5 | 6 |
| | P. Evap | 7 | 8 | 9 |
| | Dif. de T | 10 | 11 | 12 |

A função realiza cinco operações: a primeira operação é a transformação do identificador da condição de falha num multiplicador. A segunda operação, é a soma a todos os valores da coluna identificada pelo respetivo multiplicador da condição de falha. Isto permite realizar as seguintes operações de forma semelhante para todas as falhas apesar dos seus valores serem diferentes.

As duas operações seguintes são verificações de condição. É somada uma unidade se o valor avaliado for menor que o limite inferior e se for menor que o limite superior. A última operação é a soma de mais uma unidade. Estas cinco operações permitem chegar aos valores da Tabela 3.10, dependendo do estado do valor do parâmetro em análise.

No final das funções é inserida uma nova coluna com a hora do registo e reorganizadas as colunas. Os valores indicativos do estado dos parâmetros são substituídos pelas palavras “Alta”, “Normal” e “Baixa”, através da função `TableConditions` para facilitar uma consulta posterior, se necessária.

3.2.5 Motor Dempster-Shafer

As estruturas DS são inseridas no *MATLAB* e importadas para o programa através da função `CreatingStruct`. A estrutura de dados admite diferentes campos. As falhas são armazenadas no campo *foc* de elementos focais, e as massas de probabilidade no campo *mass*. Para cada um dos quatro parâmetros selecionados, existem três possíveis estados.

Relativamente aos parâmetros acompanhados pelo exemplo, o valor de *y* era inferior a 5 % na pressão do condensador, mas superior na temperatura. À pressão do condensador é atribuído o estado de “Normal”, mas à temperatura é atribuído o estado de “Alta”. As estruturas associadas correspondem às estruturas da Tabela 3.11.

TABELA 3.11: Exemplo - Motor Dempster-Shafer (1)

| Pressão | | Temperatura | |
|---------|------|-------------|-------|
| foc | mass | foc | mass |
| PC | 0,2 | PC | 0,425 |
| FN | 0,4 | FN | 0,05 |
| FR | 0,2 | FR | 0,025 |
| SC | 0,1 | SC | 0,25 |
| FN, PC | 0,05 | PC, SC | 0,1 |
| FN, FR | 0,05 | PC, FN | 0,1 |
| | 0,05 | FN, SC | 0,05 |

Após a importação das estruturas para o programa, são selecionadas as estruturas de cada parâmetro correspondente ao respetivo estado do mesmo. A seleção das estruturas é feita através da tabela identificadora de estado, resultado do sistema de inferência difuso. Para cada parâmetro fica então associada uma

estrutura correspondente ao seu estado para todas as ocorrências registradas ao longo do tempo. São criados os vetores A1, A2, B e C, correspondendo a cada um dos parâmetros.

Com os valores obtidos pelo sistema de inferência, as estruturas já não são idênticas devido ao correspondente valor de y . É possível observar o efeito que o sistema de inferência teve na alteração das probabilidades. Apesar da pressão do condensador ter sido considerada “Normal”, encontrava-se no limite da transição. Devido ao valor de y é possível estabelecer um grau de pertença. A massa de probabilidade do acontecimento “PC” foi beneficiada em detrimento do “FR” e do “FN”. As duas estruturas são representadas, respetivamente, na Tabela 3.12.

TABELA 3.12: Exemplo - Motor Dempster-Shafer (2)

| Pressão | | Temperatura | |
|---------|-------|-------------|--------|
| foc | mass | foc | mass |
| PC | 0,249 | PC | 0,51 |
| FN | 0,351 | FN | -0,035 |
| FR | 0,151 | FR | -0,06 |
| SC | 0,1 | SC | 0,25 |
| FN, PC | 0,05 | PC, SC | 0,1 |
| FN, FR | 0,05 | PC, FN | 0,1 |
| | | FN, SC | 0,05 |

Devido à alteração das massas de probabilidade, provocada pelo valor de saída do sistema de inferência y , a soma das massas de cada estrutura pode não resultar na unidade. A função `Normalize` deteta acontecimentos com valores de massa negativos, iguala-os a zero e redistribui pelos restantes acontecimentos.

Após a normalização, Tabela 3.13, as estruturas estão prontas para a combinação de evidências. Os acontecimentos cujas massas de probabilidade eram negativas não são incluídas na redistribuição do valor de massa.

A combinação da pressão (A1) e temperatura do condensador (A2) é feita através da função `Combine2Structs`. A função está esquematizada no fluxograma da Figura 3.7. Dentro de um ciclo, as estruturas dos dois vetores correspondentes vão sendo combinadas dando origem ao novo vetor (A). A combinação das estruturas é feita segundo as fases descritas anteriormente. A fase da combinação linear das estruturas é executada pela função `LinearCombination`. A soma das massas de probabilidade dos acontecimentos cujos elementos focais são vazios, resultantes

TABELA 3.13: Exemplo - Motor Dempster-Shafer (3)

| Pressão | | Temperatura | |
|---------|--------|-------------|-------|
| foc | mass | foc | mass |
| PC | 0,2572 | PC | 0,508 |
| FN | 0,3592 | FN | 0 |
| FR | 0,1592 | FR | 0 |
| SC | 0,1082 | SC | 0,248 |
| FN, PC | 0,0582 | PC, SC | 0,098 |
| FN, FR | 0,0582 | PC, FN | 0,098 |
| | | FN, SC | 0,048 |

da combinação é executada pela função `SumFocNill`. A soma das massas de probabilidade dos acontecimentos com o mesmo elemento focal é executada pela função `SumEqualFoc`. A eliminação dos acontecimentos cujos elementos focais são vazios (`nill index`) ou cujos elementos focais são iguais (`del index`) é executada pela função `DelRowStruct`. A correção das massas de probabilidade dos acontecimentos através do valor de K (K_{tot}), calculado na função `SumFocNill`, é executada pela função `CorrMass`. O produto desta última função é a estrutura final após a combinação de evidências.

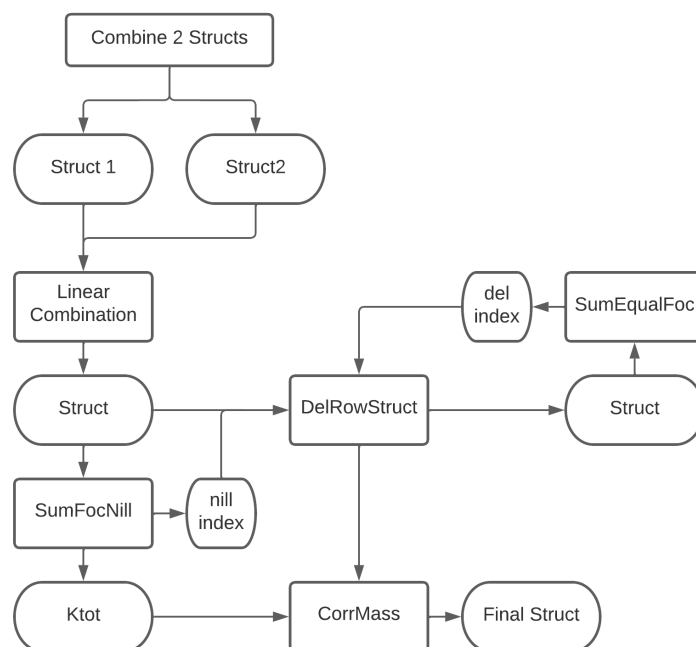


FIGURA 3.7: Fluxograma da função de combinação de estruturas

A combinação de estruturas segundo a regra de combinação de evidências

de Dempster é realizada em fases. Cada fase é interpretada por uma função. A utilização de funções tem como objetivo a independência entre operações. Segundo o processo de combinação de evidências previamente descrito, a primeira fase é a combinação linear das estruturas. A combinação de duas estruturas com n e m acontecimentos, respetivamente, dá origem a uma estrutura de dimensão $n \times m$. A combinação linear consiste em duas operações: a interseção dos elementos focais (se a interseção for vazia, dá origem a um conjunto vazio), e a multiplicação das massas de probabilidade. A fase seguinte corresponde à soma das massas de probabilidade dos conjuntos vazios, de modo a obter o valor de K (para o cálculo do valor de normalização), e ao registo dos índices dos mesmos conjuntos para serem eliminados. A fase seguinte, semelhante à anterior, corresponde à soma das massas de probabilidade de elementos focais iguais, e ao registo dos índices dos conjuntos somados para serem eliminados. A última fase corresponde à correção das massas de probabilidade com o valor de normalização.

Devido ao facto de se tratar do primeiro grafo as duas estruturas são combinadas para dar origem à estrutura da Tabela 3.14. A pressão foi classificada como “Normal”. No entanto tinha um y elevado. A temperatura foi classificada como “Alta”, também com um y elevado. O resultado da combinação é o esperado. O acontecimento “PC” prevalece sobre todos os outros. A probabilidade do acontecimento oposto, o “FR”, é nula e a probabilidade do “FN” e do “SC” é, em ambos os casos baixa.

TABELA 3.14: Exemplo - Motor Dempster-Shafer (4)

| foc | mass |
|--------|--------|
| PC | 0,6588 |
| FN | 0,1941 |
| FR | 0 |
| SC | 0,1298 |
| FN, PC | 0,0174 |

Após a combinação das estruturas e obtenção das estruturas correspondentes ao primeiro grafo, os acontecimentos das estruturas dos três grafos são ordenadas pela função `OrderStruct`.

Os limites de crença e plausibilidade são calculados para os três vetores, três grafos, para todos os registos, através da função `SetBel_Pl`. Os valores de crença e plausibilidade são calculados dentro dessa função através das funções `Belief` e

Plausibility, respetivamente. Os valores são atribuídos aos acontecimentos da estrutura.

O cálculo dos valores limites de crença e plausibilidade também é efetuado por duas funções, também divididas em fases. A função é executada para cada estrutura, mas procede ao cálculo individual do respetivo valor de cada acontecimento. Para o cálculo do valor de crença a primeira fase é o cálculo da união entre o elemento focal do acontecimento em questão com todos os outros acontecimentos. A segunda fase é a verificação da igualdade entre a união e o próprio elemento focal. A terceira fase é a soma dos valores das massas de probabilidade dos acontecimentos que cumpram com a igualdade da segunda fase. Para o cálculo do valor de plausibilidade a primeira fase é o cálculo da interseção entre o elemento focal do acontecimento em questão com todos os outros acontecimentos. A segunda fase é a verificação que a interseção dos acontecimentos não resulta num conjunto vazio. A terceira fase é a soma dos valores das massas de probabilidade dos acontecimentos que cumpram com a igualdade da segunda fase.

Após o cálculo dos limites de crença e plausibilidade os acontecimentos que consideram duas falhas são filtrados, através da função `FilterStruct`, ficando as estruturas apenas com os quatro acontecimentos principais.

Após o cálculo dos valores limites de crença e plausibilidade e do filtro aplicado a estrutura combinada, Tabela 3.15, é integrada no algoritmo de propagação.

TABELA 3.15: Exemplo - Motor Dempster-Shafer (5)

| foc | mass | Bel | Pl |
|-----|--------|--------|--------|
| PC | 0,6588 | 0,6588 | 0,6761 |
| FN | 0,1941 | 0,1941 | 0,2114 |
| FR | 0 | 0 | 0 |
| SC | 0,1298 | 0,1298 | 0,1298 |

Antes de serem projetadas num gráfico as estruturas dos três grafos, passam por um algoritmo de propagação com o objetivo de alterar os valores de crença e plausibilidade de um certo acontecimento conforme a sua ocorrência no tempo. A função `Propagation` é responsável pela alteração, ou não, dos valores de crença e plausibilidade dos três grafos ao longo do tempo. Um diagnóstico isolado assume um valor discreto e constante, mas uma sequência de diagnósticos semelhantes deve ter um impacto positivo no mesmo. O algoritmo de propagação é baseado neste princípio lógico, as massas de probabilidade de ocorrências adjacentes cujo acontecimento com maior massa de probabilidade é igual, sofrem um aumento gradual.

No entanto, quando o acontecimento com maior massa de probabilidade de duas ocorrências adjacentes não é igual, a massa de probabilidade do acontecimento relacionado com falhas ao nível de sensores e controladores aumenta. Se os parâmetros oscilarem descontroladamente a massa de probabilidade de ser um problema a nível de sensores aumenta.

3.2.6 Gráficos de saída

A função `Evaluation` é responsável por avaliar o desempenho do diagnóstico do programa e por calcular o respetivo valor de exatidão. Perante os registos horários de começo e término das simulações de falhas os resultados dos três grafos são avaliados segundo o acontecimento com maiores valores de plausibilidade. Se o diagnóstico corresponder à condição do sistema é registado um diagnóstico correto. A soma dos respetivos é dividida pelo número total de registos avaliados de modo a obter o valor de exatidão.

A função `PlotBarGraph` é responsável por criar os gráficos de barras para cada um dos três grafos. Os valores de crença e plausibilidade para cada acontecimento são traçados ao longo do tempo, de acordo com o registo dos dados pela instalação. As barras correspondentes aos valores de crença estão sobrepostas às barras dos respetivos valores de plausibilidade. Acima de cada barra é exibida a percentagem do valor de plausibilidade. Para cada grafo também são projetados os valores dos parâmetros de interesse para o respetivo grafo. Para o primeiro grafo são traçadas linhas para os valores da temperatura do ar exterior, da temperatura e da pressão do condensador. Para o segundo grafo são traçadas as linhas para os valores da temperatura do ar exterior, da pressão do condensador, da temperatura de água à saída do evaporador e da pressão do evaporador. Para o terceiro grafo são traçadas as linhas para os valores da temperatura de água à saída do evaporador e da diferença entre as temperaturas de água. Na eventualidade de um ficheiro ter muitos dados, são criados vários gráficos para facilitar a visualização dos mesmos.

Capítulo 4

Resultados e Discussão

Este capítulo tem como principal objetivo apresentar e descrever a validação do modelo desenvolvido através dos dados recolhidos pela instalação para teste e discutir os resultados obtidos. Foram recolhidos dados dos parâmetros do sistema de refrigeração durante períodos de funcionamento normal e durante períodos onde foram simuladas falhas. A simulação de falhas, o diagnóstico do programa, a exatidão do programa de deteção e de diagnóstico de falhas e os resultados obtidos são discutidos em pormenor.

4.1 Simulação de Falhas

Como referido anteriormente, a simulação de falhas num sistema de refrigeração a bordo de um navio não foi viável. Correlacionando o efeito que as falhas têm na instalação e nos seus parâmetros e com os dados disponíveis, que permitem descrever o estado termodinâmico do sistema, foram escolhidas duas falhas para a parametrização do programa.

A simulação da redução de permuta no condensador, foi obtida através da obstrução do condensador, com a colocação de uma cobertura plástica na grelha de admissão de ar do condensador. A simulação da redução de permuta no evaporador foi obtida através da diminuição do caudal de água no evaporador, provocada pelo fecho da válvula de admissão de água. Durante os períodos em que não estão a ser simuladas falhas considerou-se que o sistema funcionava em condições normais de funcionamento.

Os dados registados vão de 24 de junho às 11h30 a 21 de julho às 18h30 de 2022. O período de recolha de dados foi favorável ao desenvolvimento de um modelo de previsão de falhas. Durante o mesmo foram registados valores de temperatura do ar baixos e bastante elevados. A grande variação térmica é ideal para a calibração

de um modelo. A estação meteorológica mais próxima com dados online perto de Sintra é Lisboa. Em Lisboa, o dia mais frio do período de registo foi dia 24 de junho com uma temperatura mínima/máxima de 15,1/ 23,4 °C. As temperaturas subiram para registar valores de 26,0/ 39,5 °C no dia 8 de julho, mas tornaram a aumentar para 23,8/ 40,9 °C no dia 13 de julho. Relativamente aos dados recolhidos em Sintra pelo *AERNET* durante o período de registo, a mínima foi de 19 °C no dia 24 de junho. Nos dias 8 e 13 de julho durante o horário de trabalho, a temperatura variou entre os 29,4 °C e os 41 °C e entre os 27,6 °C e os 39,2 °C, respetivamente. A gama abrangente de temperaturas externas observadas foi ampla o suficiente para verificar o comportamento de um sistema HVAC em modo de refrigeração.

A modelação do programa e o ajuste das constantes acima referidas foi feita em duas fases. A fase de calibração dos parâmetros perante o funcionamento normal da instalação e perante condições de falha ocorreu durante a primeira semana onde foi simulada a diminuição do caudal de água de arrefecimento de dia 23 de junho até às 18 horas e 55 minutos de dia 24 de junho e durante a segunda semana onde foi simulada a obstrução do condensador das 15 horas e 40 minutos de dia 27 de junho até às 16 horas e 45 minutos de dia 29 de junho. A fase de teste e verificação do diagnóstico do programa ocorreu durante a terceira semana onde foram simuladas duas falhas: a diminuição do caudal de água de arrefecimento no dia 7 de junho das 12 horas e 10 minutos às 14 horas e 20 minutos e a obstrução do condensador das 17 horas e 05 minutos às 18 horas e 45 minutos. Durante a quarta e quinta semana não foram simuladas falhas.

4.2 Diagnósticos Obtidos

O programa recolhe os dados do sistema, processa a informação e exporta gráficos com o diagnóstico das condições de falha para os três grafos desenvolvidos. Durante as quatro semanas de aquisição de dados foi possível obter gráficos para o diagnóstico da condição do sistema de refrigeração.

Os gráficos são obtidos diariamente. No entanto, durante alguns dias foram obtidos demasiados dados para visualizar em apenas um gráfico. Para uma boa visualização dos gráficos de barras foi definido um limite de dados admissíveis. Para além desse limite são projetados vários gráficos relativos ao mesmo dia. Os resultados do diagnóstico de falha do programa desenvolvido estão enumerados no Apêndice C.

Os gráficos estão divididos em três grafos com três diagnósticos diferentes. Para cada grafo são projetados em barras os dois maiores valores da plausibilidade e crença em percentagem dos respetivos acontecimentos. O valor da plausibilidade de cada acontecimento está exibido acima da respetiva barra. O diagnóstico do funcionamento normal da instalação corresponde ao acontecimento respetivo. O diagnóstico de uma condição de falha corresponde à respetiva falha. O diagnóstico de uma falha devido a sensores e controladores está, por norma, associado a períodos de instabilidade e regimes de transição.

É possível observar o efeito do algoritmo de propagação nos valores de plausibilidade e crença ao longo do tempo. A consistência de um diagnóstico provoca um ligeiro aumento acumulativo no maior valor de plausibilidade. O valor de crença do mesmo acontecimento também sofre um aumento, mas não acompanha o aumento dos valores de plausibilidade. Os valores de plausibilidade e crença do segundo acontecimento com maior valor de plausibilidade também sofrem um ligeiro aumento, apenas em menor proporção.

De dia 23 até dia 24 de junho foi provocada uma diminuição de caudal no fluxo de água que percorre o evaporador. O momento exato de abertura da válvula está registado no grafo como fim de falha. A diminuição de caudal provoca um aumento na diferença de temperaturas de água. O terceiro grafo é responsável pela análise do respetivo parâmetro. É possível observar o diagnóstico de dia 24 de junho na Figura 4.1. Enquanto a válvula se encontra fechada a diferença de temperaturas está acima dos valores aceitáveis e o diagnóstico é o acontecimento com maiores valores de crença e plausibilidade, “PE” - diminuição de Permuta de calor no Evaporador. Os valores de crença e plausibilidade evoluem desde 50/ 70 %, respetivamente, até 70/ 97 %, aproximadamente, devido ao algoritmo de propagação. Após a abertura da válvula, a diferença de temperaturas estabiliza e o diagnóstico passa a corresponder ao acontecimento “FN” - Funcionamento Normal.

De dia 27 até dia 29 foi colocada uma obstrução no condensador. A obstrução impede o fluxo de ar de arrefecimento no condensador. A redução do fluxo de ar provoca um aumento na pressão e temperatura do condensador. O primeiro grafo é responsável pela análise de ambos os parâmetros. O diagnóstico de dia 27 de junho pode ser observado na Figura 4.2. O registo da obstrução do condensador também se encontra identificado, como início de falha. Até à obstrução o diagnóstico predominante é o “FN”. A partir da obstrução o diagnóstico passa a ser o acontecimento “PC” - diminuição de Permuta de calor no Condensador. Devido à combinação de evidências a diferença entre os valores de crença e plausibilidade é menor. Os valores

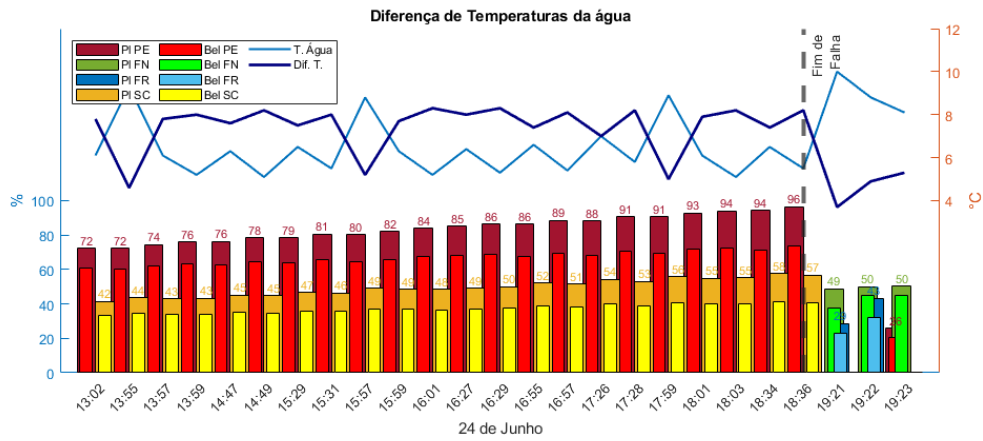


FIGURA 4.1: Diagnóstico de falha de dia 24 de junho (3º grafo)

de plausibilidade para o diagnóstico começam nos 64 % e evoluem até aos 72 %.




FIGURA 4.2: Diagnóstico de falha de dia 27 de junho (1º grafo)

Durante o dia 28 a obstrução no condensador continua colocada. O diagnóstico de dia 28 de junho pode ser observado na Figura 4.3. A falha permanece durante todo o dia. O diagnóstico corresponde predominante à “PC”. No entanto, também foram incorretamente diagnosticados alguns instantes como “FN”. Os valores de plausibilidade tem tendência a aumentar ao longo de sucessivos diagnósticos mas oscilam entre os 60 % e os 70 %.

Dia 29 foi retirada a obstrução no condensador, registada conforme os anteriores. Tanto a temperatura e a pressão do condensador estabilizam novamente para valores nominais. O correto diagnóstico de falha atinge valores de plausibilidade de 76% até à retirada da obstrução. Após a mesma, o diagnóstico de “FN” volta a predominar.

4.2. Diagnósticos Obtidos

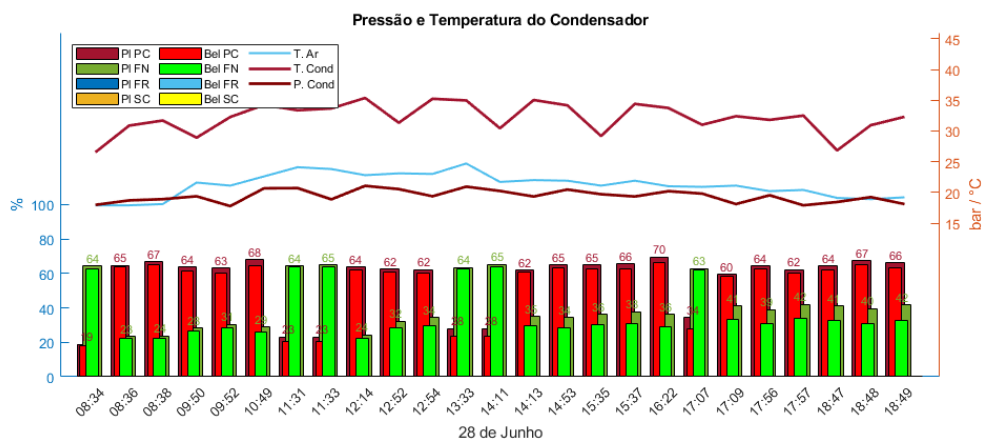


FIGURA 4.3: Diagnóstico de falha de dia 28 de junho (1º grafo)

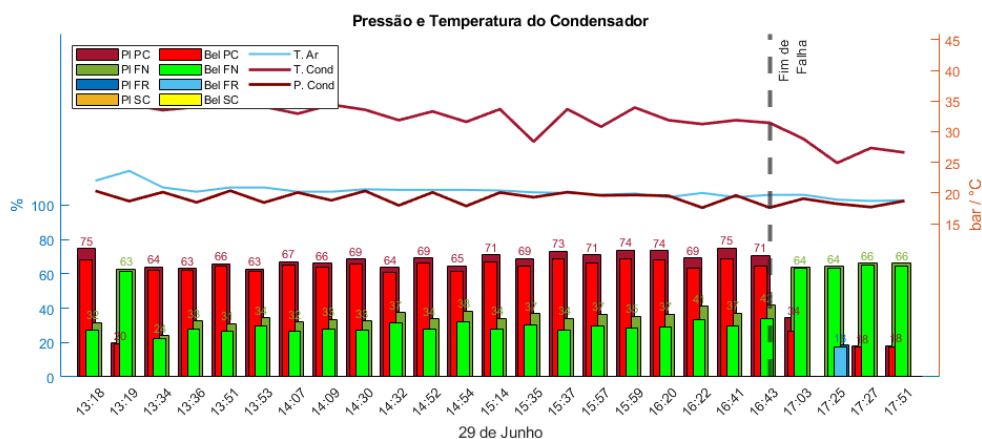


FIGURA 4.4: Diagnóstico de falha de dia 29 de junho (1º grafo)

Dia 7 de julho foram provocadas duas falhas. A primeira, diminuição do caudal da água no evaporador, está representada nas Figuras 4.5 e 4.6. Os momentos de fecho e abertura da válvula estão registados de acordo. A segunda, obstrução no condensador, está representada na Figura 4.7. Os momentos da colocação e retirada da obstrução também estão registados.

O fecho da válvula não foi corretamente identificada pelo programa, no período de simulação da falha o acontecimento com valores de crença e plausibilidade mais elevados é o “FN”, que aumentam desde os 50 % até aos 63 %. No entanto é possível observar que o acontecimento com os segundos maiores valores de crença e plausibilidade altera durante o período de simulação de falha. O acontecimento “PE” assume valores de plausibilidade que rondam os 26 % durante o período de falha. Apesar do diagnóstico não estar correto é possível observar que foi detetada uma alteração aos valores nominais. Uma análise aos valores lidos pela instalação durante o período em questão revela que a variação provocada pela simulação da condição

de falha não foi significativa. A consideração deste pequeno intervalo de tolerância para o correto diagnóstico desta ocorrência específica pode levar à provocação de um elevado número de indesejados falsos alarmes.

A obstrução do condensador já foi corretamente diagnosticada. Imediatamente antes do início da falha os valores de plausibilidade para o “FN” rondam os 90 %. Após a obstrução o diagnóstico passa a corresponder à “PC” em que os valores de plausibilidade evoluem de 63 % até 69 %.

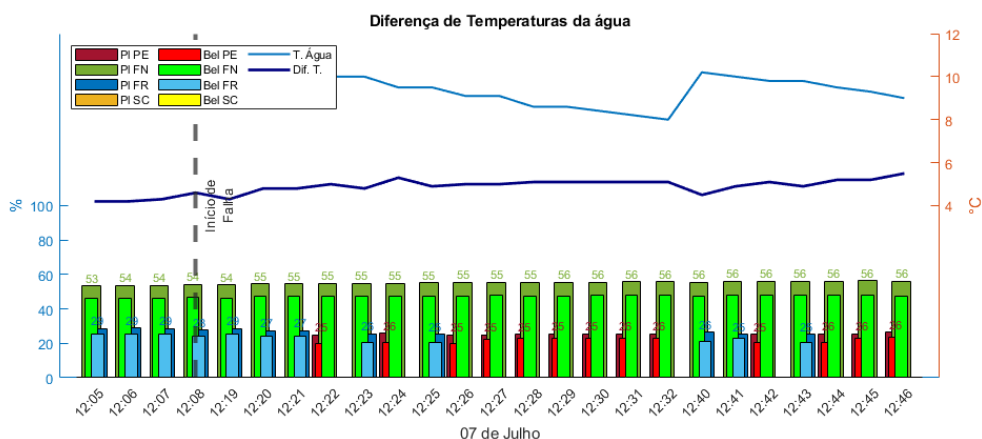


FIGURA 4.5: Diagnóstico de falha de dia 7 de julho (1) (3º grafo)




FIGURA 4.6: Diagnóstico de falha de dia 7 de julho (2) (3º grafo)

Nos restantes dias, dias em que não foram simuladas falhas e não se verificaram condições de falha, o programa diagnosticou corretamente a condição de funcionamento da instalação. No entanto foi verificado o diagnóstico ocasional de falta de refrigerante - “FR”, maioritariamente no segundo grafo - pressão do evaporador. As baixas de pressão de evaporação registadas inferiram um diagnóstico de falha, sobre supostas condições normais de funcionamento do sistema de refrigeração. Após o período de estudo e recolha de dados, foi verificada a uma possível

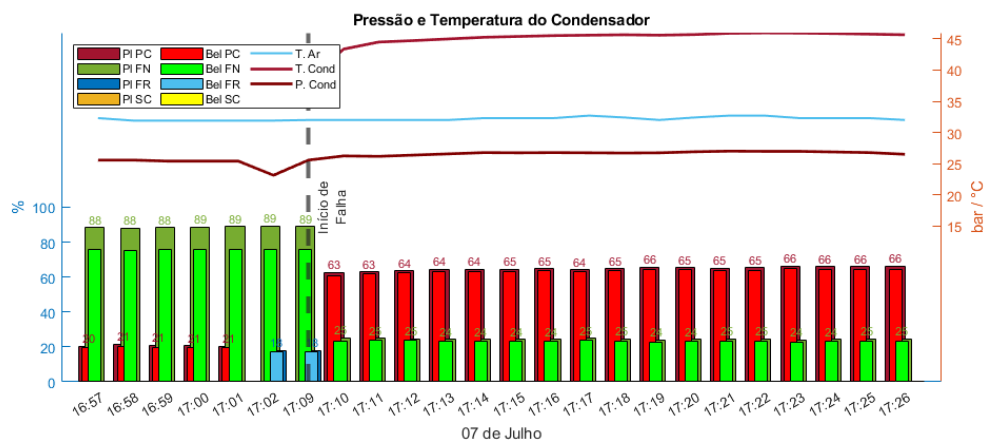


FIGURA 4.7: Diagnóstico de falha de dia 7 de julho (4) (1º grafo)

falta de refrigerante no sistema real, detetada antecipadamente pelo programa antes de qualquer alarme ou pré-alarme intrínseco à instalação.

4.3 Avaliação de Desempenho

Com o diagnóstico do programa e com os registos da simulação de falhas é possível obter a exatidão da deteção e do diagnóstico de falhas do programa face às falhas provocadas. A exatidão do programa é calculada através da divisão dos eventos corretamente diagnosticados pelo número total de eventos registados diariamente. O diagnóstico de uma falha e de funcionamento normal são considerados simultaneamente. É calculado o valor de exatidão do programa para cada um dos grafos obtidos.

Os valores de exatidão do diagnóstico para todos os dias por grafos estão enumerados na Tabela 4.1. O primeiro grafo corresponde à combinação entre a pressão e temperatura do condensador, o segundo grafo à pressão do evaporador e o terceiro à diferença entre as temperaturas de entrada e saída de água no evaporador. Nos dias em que foram simuladas falhas está identificado o grafo afetado como sobrescrito.

Como observado no diagnóstico da Figura 4.1, a exatidão do diagnóstico de dia 24 de junho para o grafo onde é provocada a falha é bastante elevada (98,11 %). No entanto a exatidão do diagnóstico do segundo grafo é mais baixa (90,57 %). Não foi simulada nenhuma falha, mas o aumento da diferença das temperaturas de entrada e saída de água do evaporador pode ter causado oscilações nos valores de pressão do mesmo que levou ao diagnóstico de condições de falha. É possível

TABELA 4.1: Exatidão do diagnóstico do programa

| Dias | 1ºGrafo | 2ºGrafo | 3ºGrafo |
|----------------------|---------|---------|---------|
| 06/24 ³ | 98,11% | 90,57% | 98,11% |
| 06/27 ¹ | 88,37% | 53,49% | 100% |
| 06/28 ¹ | 73,33% | 2,22% | 100% |
| 06/29 ¹ | 95,92% | 21,43% | 100% |
| 06/30 | 100% | 94,34% | 100% |
| 07/01 | 93,15% | 82,19% | 100% |
| 07/04 | 92,55% | 86,17% | 100% |
| 07/05 | 97,20% | 98,13% | 100% |
| 07/06 | 95,45% | 90,15% | 100% |
| 07/07 ^{3,1} | 99,03% | 98,31% | 70,13% |
| 07/08 | 99,62% | 97,74% | 99,81% |
| 07/11 | 100% | 95,02% | 100% |
| 07/12 | 99,63% | 97,01% | 100% |
| 07/13 | 99,21% | 96,31% | 100% |
| 07/14 | 99,59% | 97,21% | 100% |
| 07/15 | 99,31% | 95,86% | 100% |
| 07/18 | 96,34% | 95,73% | 100% |
| 07/19 | 95,73% | 90,60% | 100% |
| 07/20 | 84,38% | 79,17% | 100% |
| 07/21 | 90,41% | 94,52% | 100% |

verificar a evolução do diagnóstico do segundo grafo para dia 24 de junho nos gráficos do Apêndice C.

A exatidão do diagnóstico para dia 27 de junho não é tão elevada no grafo onde é simulada a falha (88,37 %), quando comparada com outros dias. De manhã, por volta das 8h30, durante o arranque da instalação é incorretamente diagnosticado o funcionamento normal da instalação, observado na Figura 4.2. Devido à pouca quantidade de dados recolhida ao longo do dia, esses breves minutos causam um impacto significativo no valor da exatidão.

A situação relativamente a dia 27 repete-se dia 28 de junho. Ao longo do dia pequenas oscilações nos valores observadas são detetadas no diagnóstico da Figura 4.3. Essas oscilações levam a que durante pequenos intervalos de tempo seja incorretamente diagnosticado o “FN” da instalação. O valor de exatidão do diagnóstico para o grafo em questão diminui (73,33 %). Estas oscilações para valores dentro dos limites nominais de funcionamento podem ser justificados perante uma condição que

não é de falha, mas que futuramente poderá provocar uma falha. A inércia de um sistema permite que o sistema aguarde com certas condições menos favoráveis de funcionamento. Abdicar de detetar pequenas oscilações pode comprometer a detecção de condições de falha futuras, mas considerar qualquer oscilação como alarme é ter em conta falsos alarmes. O algoritmo de propagação é relevante nesta situação porque tem em conta a evolução temporal do diagnóstico e permite obter valores de plausibilidade e crença mais realistas após vários diagnósticos sequenciais.

A exatidão do diagnóstico de dia 29 é mais elevada em relação aos dois dias anteriores. O fim da simulação de falha é corretamente diagnosticado, o valor da exatidão aumenta para 95,92 %.

Como discutido acima, o diagnóstico de dia 7 de julho para a primeira falha simulada, referente ao terceiro grafo, Figuras 4.5 e 4.6, não foi bem sucedido. O valor da exatidão de diagnóstico corresponde aos acontecimentos de funcionamento normal corretamente identificados, fora do período de simulação de falha (70,13 %). Em relação à segunda falha simulada, referente ao primeiro grafo, o diagnóstico foi correto, Figura 4.7, correspondendo a um valor de exatidão de diagnóstico bastante elevado (99,03 %).

Nos dias em que não foram simuladas falhas o acontecimento predominante em todos os grafos é o “FN”. Além do funcionamento normal foi detetada regularmente uma condição de falha não simulada. A falta de refrigerante é um dos diagnósticos comuns do segundo grafo devido às baixas pressões de evaporação detetadas. Como referido anteriormente, após o período de recolha de dados, verificou-se a possibilidade de uma falta de refrigerante na instalação, detetada antecipadamente antes de qualquer alarme ou pré-alarme. Devido ao facto dessa condição de falha não ter sido considerada, o seu diagnóstico para efeitos de contabilização é incorreto, prejudicando o valor de exatidão de diagnóstico de vários dias. O diagnóstico dos três grafos está graficamente representado nos diagnósticos no Apêndice C. Os valores de exatidão de diagnóstico são consistentemente elevados, variando entre os 90 % e os 100 %, devido às pequenas oscilações detetadas pelo programa.

Capítulo 5

Conclusões

Esta dissertação apresenta uma das primeiras aplicações da DST à deteção de falhas por abdução de sintomas em sistemas de refrigeração. O programa desenvolvido é capaz de corretamente detetar e identificar condições de falha num sistema de refrigeração antes da deteção de alarmes ou pré-alarmes.

O estudo de um sistema de refrigeração como sistema complexo permitiu a aplicação de uma FMEA para obtenção de falhas adequadas ao programa. Os FS e as funções de pertença foram utilizados na definição dos possíveis estados de cada parâmetro avaliado, assim como na interpretação do grau de pertença ao respetivo estado. A DST foi a teoria base da metodologia. Como teoria probabilística foi utilizada para construir e combinar estruturas compostas pelas causas possíveis, e pelas respetivas probabilidades, das condições de falha detetadas pela abdução de sintomas.

De 24 de junho a 21 de julho de 2022, em Sintra, Portugal, foram recolhidos dados para modelação e teste do programa de FDD. O período de recolha de dados foi consideravelmente bom devido à gama de temperaturas registadas. O registo de dias com temperaturas frias e temperaturas muito quentes permitiu a modelação do comportamento de um sistema de refrigeração sobre diversas condições de carga.

Foram simuladas duas condições de falha para testar o programa desenvolvido. Foi testada uma obstrução no ventilador do condensador e o fecho da válvula de água de circulação, provocando uma diminuição de caudal no evaporador. O objetivo da simulação de falhas era diminuir a permuta de calor nos permutadores.

O programa diagnostica o estado da instalação através dos limites (crença e plausibilidade) da probabilidade dos acontecimentos das estruturas DS. Numa situação de falha o acontecimento mais provável tem, normalmente, uma massa de

probabilidade base entre 60 e os 70 %. Outros acontecimentos também são considerados, mas com massas de probabilidade mais baixas. O diagnóstico sequencial do mesmo acontecimento é tido em conta, sendo considerado num algoritmo de propagação para ajustar os valores dos limites probabilísticos de acordo com uma situação real de recorrência.

Os elevados e consistentes valores de exatidão obtidos corroboram a capacidade de deteção e diagnóstico de condições de falha do programa desenvolvido. Em eventos relativos à obstrução do condensador, identificou corretamente cerca de 95 %. Com a válvula totalmente fechada, também foi capaz de corretamente diagnosticar a falha. No entanto, para uma válvula menos fechada, não foi totalmente capaz de identificar a falha. Nos dias sem falhas provocadas, o acontecimento predominante é o funcionamento normal da instalação.

As situações verificadas de diagnóstico incorreto podem ser justificadas por diferentes razões. O sistema em estudo é um sistema complexo, logo utilizou-se então um modelo estacionário para o descrever. Condições desfavoráveis para o sistema não são imediatamente detetadas pelos sensores que leem os parâmetros do sistema. Grandes oscilações ao longo do tempo podem ser absorvidas e suavizadas enquanto que em situações de arranque são lidos valores de pico fora das condições normais de funcionamento. A simulação do sistema de refrigeração é feita em regime estacionário, condições transitórias não são consideradas. A avaliação dos parâmetros por parte do programa tem como base a leitura das condições exteriores. Apesar de existirem relações entre essas condições e as condições internas do sistema, não são relações puramente lineares e estão sujeitas a variações. Foram verificados vários instantes onde foi diagnosticada uma fuga de refrigerante no sistema, em situações onde não foram simuladas falhas. No entanto, após a verificação da instalação por parte de um especialista, verificou-se que a instalação apresenta sintomas reais e que possa ter sido detetada antecipadamente uma condição de falha futura de falta de refrigerante.

As variações dos parâmetros são analisadas e processadas para obter o estado de um parâmetro em relação às condições nominais de funcionamento definidas com base no estudo do sistema considerado. Os limites aceitáveis para as respetivas variações fazem parte de um equilíbrio entre falsos positivos - falsos alarmes - e falsos negativos - desprezo de condições de falha. Numa situação prática a existência de demasiados falsos alarmes pode levar à perda de recursos e material em reparações desnecessárias enquanto que o desprezo de condições de falha em demasia pode levar a avarias que poderiam ter sido evitadas.

O algoritmo desenvolvido de propagação de informação ao longo do tempo visa apelar à realidade prática da detecção e diagnóstico de falhas. A detecção do desvio de um determinado parâmetro, origina um diagnóstico sobre uma possível causa para esse desvio. Ao diagnóstico está associada uma determinada falha assim como uma possível probabilidade, que segundo o grau do desvio inicial, pode ser ligeiramente corrigida. A lógica do raciocínio é correta e deve ser aplicada, mas numa série temporal não devem ser descartados os diagnósticos prévios. A consideração da insistência no mesmo diagnóstico leva ao aumento da crença e plausibilidade da probabilidade do mesmo. O algoritmo é construído com base neste princípio.

A DST tem a capacidade de não só considerar informação incompleta ou ambígua na tomada de decisão mas também permite obter valores percentuais de limites de crença e de plausibilidade sobre um ou mais acontecimentos ditados sobre valores quantitativos. O algoritmo de propagação é responsável pela percepção real da evolução de um diagnóstico e permite uma avaliação mais fidedigna do estado da instalação melhorando o processo de decisão.

5.1 **Trabalhos Futuros**

Foram verificadas algumas limitações no programa de detecção e diagnóstico de falhas aplicado a um sistema de refrigeração. A análise de modos de falha pode ser mais aprofundada de modo a obter mais falhas. A consideração de outras falhas além dos modos de falha explorados pode ser estudada. O número de arranques do compressor ou o intervalo entre os mesmos podem ser integrados no programa ou como sintoma de outro modo de falha ou como parâmetro que influencie os valores probabilísticos da crença e plausibilidade dos acontecimentos considerados.

Os conjuntos difusos e o sistema de inferência pode ser melhorado de modo a considerar mais regras de combinação de valores de entrada para obter melhores valores de saída. A combinação de evidências pode ser explorada de modo a considerar mais fontes de informação ou de modo a recorrer a outro tipo cálculo. A formulação das estruturas pode ser melhorada de modo a representar de melhor forma a probabilidade real de cada acontecimento e da interseção entre eles, mantendo essa representação real após a combinação matemática das probabilidades.

A revisão da literatura mostra que a DST pode ser integrada com AI para desenvolver um sistema de apoio à decisão mais avançado. Um algoritmo de ML

pode ser aplicado não só para a modelação e calibração do sistema e das suas constantes, derivadas de conhecimento especialista, mas como para a definição dos acontecimentos e ajuste das massas de probabilidade das estruturas DS.

A aplicação do programa de deteção e diagnóstico de falhas a um sistema de refrigeração cuja monitorização é contínua e *on-line* permite aos utilizadores uma visão não só do diagnóstico de uma ocorrência individualmente, mas como da evolução dos respetivos diagnósticos, de modo a tomar as devidas e apropriadas ações.

Futuramente o programa desenvolvido pode ser aplicado em comparação com um modelo dinâmico do ciclo frigorífico, aplicado a sistemas com compressor *inverter* - motor de frequência variável, com modulação, aplicado a sistemas com vários compressores e a sistemas com controlo pelo retorno, assim como a outros sistemas mecânicos complexos, desde que seja possível a sua modelação e recolha de dados sobre os parâmetros que o descrevem.

A metodologia apresentada tem capacidade para ser adaptada a outras falhas de um sistema de refrigeração, ou para outros sistemas de refrigeração. A metodologia visa também a aplicação da abdução de causas por deteção de sintomas utilizando a DST noutros sistemas mecânicos complexos. Em aplicações militares e de Informação, em ambientes de informação incompleta ou ambígua, a compilação e o processamento de informação são essenciais para detetar anomalias. Pequenos indícios que não dão alarmes podem ser utilizados na combinação de evidências de modo a identificar situações fora do normal através de um raciocínio de abdução.

Bibliografia

- Afgan, N., & Carvalho, M. (1996). Knowledge-based expert system for fouling assessment of industrial heat exchangers. *Applied Thermal Engineering*, 16(3), 203–208.
- Ahmad, N., & Atta, R. (2014). Cost-effective wireless-controlled motor failure prediction for HVAC system in large buildings using demodulated current signature analysis. *Life Science Journal*, 11(10s).
- ASHRAE, P. (2008). *ASHRAE Handbook - HVAC Systems and Equipment*, SI ed.
- ASHRAE, P. (2013). *ASHRAE Handbook - Fundamentals*, SI ed.
- Baptista, D., & Cavique, M. (2022). Chiller fault evaluation using Dempster-Shafer theory. *Interdisciplinary Conference on Mechanics, Computers and Electrics*.
- Beynon, M., Cosker, D., & Marshall, D. (2001). An expert system for multi-criteria decision making using Dempster Shafer theory. *Expert Systems with Applications*, 20(4), 357–367.
- Breuker, M. S. (1997). Evaluation of a Statistical, Rule-Based Fault Detection and Diagnostics Method for Vapor Compression Air Conditioners. *School of Mechanical Engineering*.
- Cavique, M., Gonçalves-Coelho, A., & Mourão, A. (2013). Decision Criteria for the Design of HVAC systems for Datacom Centres Based on Cost and Losses due to the failure of components. *ICAD 2013*.
- Cavique, M., Mourão, A., Seixas, J., & Gonçalves-Coelho, A. (2021). A methodological approach for strategic evaluation-a response to water scarcity emergency. *IOP Conference Series: Materials Science and Engineering*, 1174(1), 012020.
- Cengel, Y. A., Boles, M. A., & Kanoğlu, M. (2011). *Thermodynamics: an engineering approach* (Vol. 5). McGraw-hill New York.
- Chakraborty, D., & Elzarka, H. (2019). Early detection of faults in HVAC systems using an XGBoost model with a dynamic threshold. *Energy and Buildings*, 185, 326–344.
- Cheng, Y.-L., et al. (2000). Uncertainties in fault tree analysis. *Journal of Applied Science and Engineering*, 3(1), 23–29.

- Comstock, M. C., Braun, J. E., & Bernhard, R. (1999). *Development of Analysis Tools for the Evaluation of Fault Detection and Diagnostics in Chillers*. Purdue University.
- Du, Z., Fan, B., Jin, X., & Chi, J. (2014). Fault detection and diagnosis for buildings and HVAC systems using combined neural networks and subtractive clustering analysis. *Building and Environment*, *73*, 1–11.
- Dutta, P. (2015). Uncertainty modeling in risk assessment based on Dempster–Shafer theory of evidence with generalized fuzzy focal elements. *Fuzzy information and engineering*, *7*(1), 15–30.
- Gálvez, A., Diez-Oliván, A., Seneviratne, D., & Galar, D. (2021). Fault detection and estimation for railway hvac systems using a hybrid model-based approach. *Sustainability*, *13*(12), 6828.
- Graham-Jones, P., & Mellor, B. (1995). Expert and knowledge-based systems in failure analysis. *Engineering Failure Analysis*, *2*(2), 137–149.
- Guo, L. (2004). *Software quality and reliability prediction using Dempster-Shafer theory*. West Virginia University.
- Huang, P., Huang, G., & Wang, Y. (2015). HVAC system design under peak load prediction uncertainty using multiple-criterion decision making technique. *Energy and Buildings*, *91*, 26–36.
- Jang, J.-S. R., Sun, C.-T., & Mizutani, E. (1997). Neuro-fuzzy and soft computing - A computational approach to learning and machine intelligence. *IEEE Transactions on automatic control*, *42*(10), 1482–1484.
- Jones, W. P. (2007). *Air Conditioning Engineering*. Routledge.
- Li, T., Zhao, Y., Zhang, C., Luo, J., & Zhang, X. (2021). A knowledge-guided and data-driven method for building HVAC systems fault diagnosis. *Building and Environment*, *198*, 107850.
- Lo, C., Chan, P., Wong, Y.-K., Rad, A. B., & Cheung, K. (2007). Fuzzy-genetic algorithm for automatic fault detection in HVAC systems. *Applied soft computing*, *7*(2), 554–560.
- Mikulak, R. J., McDermott, R., & Beauregard, M. (2017). *The basics of FMEA*. CRC Press.
- Mokarram, M., & Khosravi, M. R. (2021). A cloud computing framework for analysis of agricultural big data based on Dempster-Shafer theory. *The Journal of Supercomputing*, *77*(3), 2545–2565.

- Namburu, S. M., Azam, M. S., Luo, J., Choi, K., & Pattipati, K. R. (2007). Data-driven modeling, fault diagnosis and optimal sensor selection for HVAC chillers. *IEEE transactions on automation science and engineering*, 4(3), 469–473.
- Padmanabh, K., Al-Rubaie, A., Davies, J., Clarke, S. S., & Aljasmi, A. A. A. A. (2021). Fault Prediction in HVAC Chillers by Analysis of Internal System Dynamics. *2021 International Conference on Smart Applications, Communications and Networking (SmartNets)*, 1–6.
- Pappalardo, M. (2006). Fusion of belief in Axiomatic Design. *Proceedings of Fourth International Conference on Axiomatic Design*.
- Reddy, T. A., Braun, J. E., Singhal, A., & Seem, J. (2006). Evaluation and Assessment of Fault Detection And Diagnostic Methods for Centrifugal Chillers-Phase II.
- Sentz, K., & Ferson, S. (2002). Combination of evidence in Dempster-Shafer theory.
- Soliman, A., Rizzoni, G., & Kim, Y. (1999). Diagnosis of an automotive emission control system using fuzzy inference. *Control engineering practice*, 7(2), 209–216.
- Stamatis, D. H. (2003). *Failure mode and effect analysis: FMEA from theory to execution*. Quality Press.
- Wang, X., Qu, H., Liu, P., & Cheng, Y. (2004). A self-learning expert system for diagnosis in traditional Chinese medicine. *Expert systems with applications*, 26(4), 557–566.
- Yager, R. R. (1987). On the Dempster-Shafer framework and new combination rules. *Information sciences*, 41(2), 93–137.
- Yang, C., Chen, Q., Shen, W., & Gunay, B. (2017). Toward failure mode and effect analysis for heating, ventilation and air-conditioning. *2017 IEEE 21st International Conference on Computer Supported Cooperative Work in Design (CSCWD)*, 408–413.
- Yang, C., Gunay, B., Shi, Z., & Shen, W. (2020). Machine learning-based prognostics for central heating and cooling plant equipment health monitoring. *IEEE Transactions on Automation Science and Engineering*, 18(1), 346–355.
- Yang, C., Shen, W., Chen, Q., & Gunay, B. (2018). A practical solution for HVAC prognostics: Failure mode and effects analysis in building maintenance. *Journal of Building Engineering*, 15, 26–32.
- Yen, J. (1989). GERTIS: a Dempster-Shafer approach to diagnosing hierarchical hypotheses. *Communications of the ACM*, 32(5), 573–585.
- Zadeh, L. A. (1965). *Fuzzy Sets*. Information; Control.

Zadeh, L. A. (1986). A simple view of the Dempster-Shafer theory of evidence and its implication for the rule of combination. *AI magazine*, 7(2), 85–85.

Apêndice A - Análise de Modos de Falha e Efeitos

Os métodos de FDD referidos são aplicados a sistemas complexos com diversos modos de falha. Um modelo de FDD foca-se num número limitado de falhas. Uma FMEA é uma técnica para a seleção dos modos de falha a serem aplicados no modelo de previsão de falhas.

FMEA é um grupo de atividades sistemáticas com o objetivo de reconhecer e avaliar potenciais modos de falha de um produto ou de um processo, identificar ações que podem eliminar ou reduzir a probabilidade de falha, e documentação de todo o processo de análise. FMEAs levam tempo e ocupam recursos humanos, mas não requerem processos estatísticos complicados nem algoritmos complexos para ter um impacto significativo na redução de custos de um produto ou processo. FMEAs são baseadas em trabalho de equipa. Estas equipas são constituídas por especialistas de diversas áreas de modo a obter uma panóplia multidisciplinar abrangente. (Stamatis, 2003)

FMEAs previnem defeitos, melhoram a segurança e aumentam a satisfação do cliente. A maioria destas análises são feitas durante o processo de projeto do produto, nas fases de desenvolvimento. Uma FMEA lista todas as possíveis formas de falha de um produto, ou de um processo. Na avaliação de um produto, descobre problemas que podem resultar em falhas de segurança e de operação ou diminuir o tempo de vida do produto. Na avaliação de um processo descobre problemas relacionados com a manufatura de um produto, e como é que afetará a sua segurança e eficiência. FMEAs podem reduzir substancialmente custos através da identificação de melhorias a realizar e aplicar em produtos e processos numa fase inicial de desenvolvimento, onde as alterações são fáceis e baratas. (Stamatis, 2003)

Mikulak et al. (2017) esquematizaram o processo tradicional de uma FMEA de um produto ou de um processo deve seguir nos seguintes dez passos:

1. Revisão do processo

A equipa responsável pela realização da FMEA deve rever um diagrama ou desenho técnico do produto ou um fluxograma detalhado do processo, com o objetivo de conhecer meticulosamente o produto ou processo de modo a poder avaliar os seus modos de falha. É aconselhado que tenham contacto físico com o produto – através de um protótipo – ou com o processo – através do percurso do mesmo. Deve existir um especialista no produto ou processo capaz de responder a questões sobre a sua conceção ou funcionamento.

2. Debate de potenciais modos de falha

Quando a equipa estiver familiarizada com o produto ou processo deve começar a pensar em potenciais modos de falha que possam influenciar a qualidade do mesmo. Um debate de ideias é ideal para expor esses modos de falha. Cada elemento deve trazer uma lista com as suas próprias ideias, mas novas ideias podem derivar da sinergia do debate em equipa. Devido à complexidade de alguns produtos estes debates são organizados em temas gerais, focados em diferentes componentes ou elementos. Depois do debate todas as ideias devem ser organizadas e categorizadas de modo tornar o processo mais fluido e fácil de navegar posteriormente. Estes modos de falha devem ser revistos para eliminar repetição ou ambiguidades, podendo existir a possibilidade de combinação de alguns modos de falha.

3. Listagem de potenciais efeitos dos modos de falha

As ideias do debate depois de organizadas e categorizadas devem ser listadas como potenciais modos de falha. A equipa deve então rever esses modos de falha e identificar os potenciais efeitos de cada um. Para alguns modos de falha poderá existir mais que um potencial efeito. Este processo deve ser detalhado e minucioso porque irá alimentar a lista para a avaliação de risco. Este passo deve ser considerado como uma regra condicional. Se a falha ocorrer, então quais serão as consequências?

4. Atribuição de um valor de severidade a cada efeito

A severidade é a medida da gravidade dos efeitos se a falha ocorrer. Em alguns casos é facilmente determinada por experiência, noutros é necessário estimar a severidade baseada no conhecimento e experiência da equipa especialista. É importante notar que cada falha pode ter vários efeitos, e que cada efeito pode ter valores de severidade diferentes. O valor de severidade é atribuído ao efeito que ocorre da falha e não à falha. É baseada numa escala de um a dez, onde um é a situação menos grave e dez é a situação mais grave, (Figura A.1). É importante definir instruções claras e concisas para a atribuição de valores de severidade. A equipa deve estar familiarizada com a escala, definida anteriormente. Quanto mais pormenorizada, detalhada e descritiva for a escala, mais fácil é chegar a um consenso durante o processo de avaliação.

5. Atribuição de um valor de probabilidade de ocorrência a cada modo de falha

O valor de ocorrência é a medida da probabilidade que uma falha tem de ocorrer ou a frequência de ocorrência de uma falha. O melhor método para

| Effect | Criteria: Severity of Effect on Product (Customer Effect) | Rank |
|--|--|-----------|
| Failure to Meet Safety and/or Regulatory Requirements | Potential failure mode affects safe vehicle operation and/or involves noncompliance with government regulations without warning. | 10 |
| | Potential failure mode affects safe vehicle operation and/or involves noncompliance with government regulations with warning. | 9 |
| Loss or Degradation of Primary Function | Loss of primary function (vehicle inoperable, does not affect safe vehicle operation). | 8 |
| | Degradation of primary function (vehicle operable, but at reduced level of performance). | 7 |
| Loss or Degradation of Secondary Function | Loss of primary function (vehicle inoperable, but comfort/convenience functions inoperable). | 6 |
| | Degradation of primary function (vehicle inoperable, but comfort/convenience functions at reduced level of performance). | 5 |
| Annoyance | Appearance or Audible Noise, vehicle operable, item does not conform and noticed by most customers (>75%). | 4 |
| | Appearance or Audible Noise, vehicle operable, item does not conform and noticed by many customers (50%). | 3 |
| | Appearance or Audible Noise, vehicle operable, item does not conform and noticed by discriminating customers (<25%). | 2 |
| No effect | No discernible effect. | 1 |

FIGURA A.1: Escala de critérios para atribuição de um valor de severidade, extraído de Mikulak et al. (2017)

determinar o valor da ocorrência é utilizando dados do próprio processo, registos de falha ou de manutenção. Quando não é possível obter esses dados, o valor da ocorrência tem de ser estimado. Saber a causa da falha ajuda a estimar o valor da probabilidade de ocorrência do modo de falha ou da frequência a que ocorre. Quando as potenciais causas são determinadas para cada modo de falha, é possível atribuir um valor de ocorrência a cada falha, mesmo sem valores históricos. Igualmente baseada numa escala de um a dez, onde um é a situação menos provável e dez é a situação mais provável, (Figura A.2).

6. Atribuição de um valor de detetabilidade e reparação para cada modo de falha e efeito

O valor de detetabilidade e reparação é a medida da facilidade de deteção e reparação, ou tempo de reparação, de uma falha ou do efeito dessa falha. O processo começa com a identificação dos dispositivos de controlo para deteção de falhas ou dos efeitos das falhas. Se não existem controlos a probabilidade de deteção é baixa, e o valor de detetabilidade é alto. Os dispositivos de controlo devem ser listados para cada modo de falha antes da avaliação dos valores de detetabilidade. Do mesmo modo é baseada numa escala de um a dez, onde um é a situação mais provável de

| Likelihood of Failure | Criteria: Occurrence of Causes – DFMEA (Design life/reliability of item/vehicle) | Incidents per item/vehicle | Rank |
|-----------------------|---|---|-----------|
| Very High | New technology/new design with no history. | ≥100 per thousand ≥1 in 10 | 10 |
| High | Failure is inevitable with new design, new application, or change in duty cycle/operating conditions. | 50 per thousand 1 in 20 | 9 |
| | Failure is likely with new design, new application, or change in duty cycle/operating conditions. | 20 per thousand 1 in 50 | 8 |
| | Failure is uncertain with new design, new application, or change in duty cycle/operating conditions. | 10 per thousand 1 in 100 | 7 |
| Moderate | Frequent failures associated with similar designs or in design simulation and testing. | 2 per thousand 1 in 500 | 6 |
| | Occasional failures associated with similar designs or in design simulation and testing. | 0.5 per thousand 1 in 2,000 | 5 |
| | Isolated failures associated with similar designs or in design simulation and testing. | 0.1 per thousand 1 in 10,000 | 4 |
| Low | Only isolated failures associated with almost identical design or in design simulation and testing. | 0.01 per thousand 1 in 100,000 | 3 |
| | No observed failures associated with almost identical design or in design simulation and testing. | ≤0.001 per thousand 1 in 1,000,000 | 2 |
| Very Low | Failure is eliminated through preventive control | Failure is eliminated through preventive control. | 1 |

FIGURA A.2: Escala de critérios para atribuição de um valor de probabilidade de ocorrência, extraído de Mikulak et al. (2017)

deteção e de fácil reparação e dez é a situação menos provável de deteção e de difícil reparação, Figuras A.3 e A.4.

7. Cálculo do RPN para cada efeito

O Número de Prioridade de Risco - *Risk Priority Number* (RPN) é o produto da multiplicação dos valores de severidade, ocorrência e detetabilidade e reparação. O número total de prioridade de risco é a soma do RPN de todos os efeitos. O RPN total é irrelevante para comparação entre FMEAs diferentes, porque depende da quantidade de itens analisados. No entanto, pode ser importante na comparação antes e depois das alterações feitas ao mesmo produto e processo.

8. Priorização dos modos de falha

Os modos de falha podem ser agora priorizados segundo o seu RPN, por ordem descendente. O princípio de Pareto pode ser aplicado na resolução de problemas. O princípio de Pareto aplicado à FMEA afirma que 80% do RPN total deriva de apenas 20% das potenciais falhas e dos seus efeitos. A equipa deve decidir em que itens trabalhar para minimizar o RPN alterando o produto ou o processo.

| Opportunity for Detection | Criteria: Likelihood of Detection by Design Control | Rank | Likelihood of Detection |
|--|--|------|-------------------------|
| No detection opportunity | No current design control; Cannot detect or is not analyzed. | 10 | Almost Impossible |
| Not likely to detect at any stage | Design analysis/detection controls have a weak detection capability; Virtual Analysis (e.g., CAE, FEA, etc.) is not correlated to expected actual operating conditions. | 9 | Very Remote |
| Post Design Freeze and prior to launch | Product verification/validation after design freeze and prior to launch with pass/fail testing (Subsystem or system testing with acceptance criteria such as ride and handling, shipping evaluation, etc.). | 8 | Remote |
| | Product verification/validation after design freeze and prior to launch with test to failure testing (Subsystem or system testing until failure occurs, testing of system interactions, etc.). | 7 | Very Low |
| | Product verification/validation after design freeze and prior to launch with degradation testing (Subsystem or system testing after durability test, e.g., function check). | 6 | Low |

FIGURA A.3: Escala de critérios para atribuição de um valor de detetabilidade e reparação (1), extraído de Mikulak et al. (2017)

9. Ações para eliminar ou reduzir os modos de falha com alto risco

Idealmente os modos de falha seriam completamente eliminados, mas muitas vezes tal não é possível. Cabe à equipa pensar em formas de reduzir um, dois, ou mesmo os três parâmetros do RPN, severidade, ocorrência e detetabilidade e reparação. Normalmente a abordagem mais fácil é aumentar a capacidade de deteção, reduzindo o valor de detetabilidade, através da implementação de sistemas de controlo e dispositivos de alarme. No entanto esta abordagem não corrige a falha em si, apenas a capacidade de a detetar. Reduzir a severidade é importante, através de medidas que evitem situações em que possam pôr em causa a integridade física dos operadores, mas reduzir a probabilidade de ocorrência é a ação ideal. Ações específicas podem ser tomadas para reduzir o valor da severidade, como a implementação de equipamento pessoal de proteção, a instalação de interruptores de paragem de emergência, e a utilização de materiais que promovam ambientes mais seguros. O valor da ocorrência pode ser reduzido com o aumento de capacidade de processamento complexo através do projeto de protótipos e modificação de equipamentos, o foco contínuo na melhoria de equipas focadas na resolução de problemas e utilização de mecanismos de segurança de engate mecânico para ativação do produto ou processo. O valor da detetabilidade e reparação é reduzido através de medidas como o controlo de processos estatístico, a implementação de medidas de manutenção – corretiva e preventiva – e de calibração, e a implementação de luzes, cores e símbolos

| | | | |
|--|---|---|-----------------|
| Prior to Design Freeze | Product validation (reliability testing, development or validation tests) prior to design freeze using pass/fail testing (e.g., acceptance criteria for performance, function checks, etc.). | 5 | Moderate |
| | Product validation (reliability testing, development or validation tests) prior to design freeze using test to failure (e.g., until leaks, yields, cracks, etc.). | 4 | Moderately High |
| | Product validation (reliability testing, development or validation tests) prior to design freeze using degradation testing (e.g., data trends, before/after values, etc.). | 3 | High |
| Virtual Analysis – Correlated | Design analysis/detection controls have a strong detection capability; Virtual Analysis (e.g., CAE, FEA, etc.) is highly correlated with actual or expected operating conditions prior to design freeze. | 2 | Very High |
| Detection not applicable; Failure Prevention | Failure cause or failure mode cannot occur because it is fully prevented through design solutions (e.g., proven design standard, best practice or common material, etc.). | 1 | Almost Certain |

FIGURA A.4: Escala de critérios para atribuição de um valor de detetabilidade e reparação (2), extraído de Mikulak et al. (2017)

para alarmes.

10. Cálculo do RPN resultante dos modos de falha reavaliados

As ações tomadas segundo o passo anterior levam a alteração dos valores de severidade, ocorrência e detetabilidade e reparação. Após a implementação destas ações é necessário proceder ao cálculo de novos valores para os três parâmetros, de modo a obter um novo RPN. Os modos de falha intervencionados devem diminuir significativamente o seu RPN, se não, as ações tomadas terem sido ineficazes. O RPN total pode ser comparado com a primeira iteração da FMEA para verificar uma redução de 50% ou mais. Não existe uma meta definida para o RPN total, portanto as equipas devem decidir se a FMEA está ou não aceitável e por si completa. Existirá sempre potencial para ocorrência de falhas, no entanto, a equipa deve determinar o risco que está disposta a correr, dependendo da indústria e da gravidade da falha.

Apêndice B - Lógica Difusa

O conhecimento é muitas vezes interpretado com um elevado grau de imprecisão e de forma qualitativa e não quantitativa. A lógica difusa permite resolver o problema da informação ambígua, qualitativa ou imprecisa através de uma ferramenta de cálculo estruturada que lida com valores linguísticos.

O cérebro humano é uma fonte de inteligência natural, capaz de processar informação, maioritariamente incompleta obtida através da perceção a um ritmo incrivelmente rápido. Os neurónios funcionam mais lentamente que portas lógicas eletrónicas, mas são capazes de processar informação visual e auditiva muito mais rápido que os computadores atuais. Inspirados em sistemas nervosos, muitos investigadores exploram redes neuronais artificiais para processamento de informação. O cérebro interpreta informação incompleta e imprecisa fornecida por órgãos percetivos. A lógica difusa proporciona um cálculo sistemático para lidar com informação linguística e realiza computação numérica através de rótulos linguísticos estipulados por funções de pertença. (Jang et al., 1997)

B.1 Conjuntos Difusos

Um conjunto clássico é um conjunto definido com valores de limite nítidos e não ambíguo. Estes conjuntos são ferramentas importantes para a matemática e ciência computacional, mas não refletem a natureza do pensamento humano, que tende para ser abstrato e impreciso. Um conjunto difuso, também designado por conjunto vago, contrário aos conjuntos clássicos, é definido sem valores de limite nítidos. A transição entre a pertença a um conjunto é gradual, e é caracterizada por uma função de pertença. Este conjunto expressa o grau de pertença de um objeto a um conjunto. Logo uma das características destes é permitirem valores entre os valores booleanos 0 e 1, que representam o grau de pertença. – o princípio do terceiro excluído não é aplicado, podendo numa situação pertencer a dois conjuntos ao mesmo tempo. O universo de objetos pode ser composto por objetos discretos, ordenados ou não-ordenados, ou por um espaço contínuo. Para a construção de um conjunto difuso é necessária a identificação do universo de objetos e a especificação das funções de pertença. A especificação destas funções é subjetiva, porque cada individuo percebe e expressa conceitos qualitativos de forma diferente. Um conjunto difuso é caracterizado pela sua função de pertença, como a maior parte dos conjuntos são definidos num universo contínuo, a sua função de pertença pode ser definida matematicamente. (Zadeh, 1965)

Sendo X um espaço de objetos e x um objeto genérico de X , um conjunto difuso A em X é definido com um conjunto de pares ordenados:

$$A = \{(x, \mu_A(x)) \mid x \in X\} \quad (\text{B.1})$$

onde $\mu_A(x)$ é a função de pertença do conjunto difuso A . As funções de pertença permitem o mapeamento dos valores de pertença ou graus de pertença entre 0 e 1, ao longo do universo de X .

A união de dois conjuntos difusos A e B é um conjunto difuso C , escrito como $C = A \cup B$ ou como $C = A$ OR B , cuja função de pertença é:

$$\mu_C(x) = \max(\mu_A(x), \mu_B(x)) = \mu_A(x) \vee \mu_B(x) \quad (\text{B.2})$$

Uma noção mais intuitiva equivalente da definição de união é o conjunto difuso mais pequeno, que contém ambos os conjuntos A e B .

A interseção de dois conjuntos difusos A e B é um conjunto difuso C , escrito como $C = A \cap B$ ou como $C = A$ AND B , cuja função de pertença é:

$$\mu_C(x) = \min(\mu_A(x), \mu_B(x)) = \mu_A(x) \wedge \mu_B(x) \quad (\text{B.3})$$

No caso da interseção, uma noção mais intuitiva é o maior conjunto difuso contido por ambos os conjuntos A e B .

A negação de um conjunto difuso A , \bar{A} ($\neg A$ ou *NOTA*), é definido como:

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (\text{B.4})$$

B.2 Funções de Pertença

Um conjunto difuso é completamente caracterizado pela sua função de pertença. A maioria dos conjuntos pertencem a um universo X de valores contínuos. Uma maneira conveniente e concisa de definir uma função de pertença é através de expressões matemáticas. Existem várias funções características, a uma, duas ou mais dimensões. As funções mais básicas, mas muitas vezes, suficientes para o grau de complexidade do problema correspondente são as funções triangulares, trapezoidais, gaussianas e em forma de sino.

Uma função triangular é especificada por três parâmetros $\{a, b, c\}$ da seguinte forma:

$$\text{triangle}(x; a, b, c) = \begin{cases} 0, & x \leq a. \\ \frac{x-a}{b-a}, & a < x < b. \\ \frac{c-x}{c-b}, & b < x < c. \\ 0, & c \leq x. \end{cases} \quad (\text{B.5})$$

Utilizando a notação para mínimos e máximos, a equação B.5 pode ser reescrita como:

$$\text{triangle}(x; a, b, c) = \max(\min(\frac{x-a}{b-a}, \frac{c-x}{c-b}), 0) \quad (\text{B.6})$$

Os parâmetros $\{a, b, c\}$, com $a \leq b \leq c$ determinam as coordenadas x dos três cantos da função de pertença triangular. Na Figura B.1 é apresentada uma função triangular cujos parâmetros $\{a, b, c\}$ são respetivamente (20,60,80).

Uma função trapezoidal é especificada por quatro parâmetros $\{a, b, c, d\}$ da seguinte forma:

$$\text{trapezoidal}(x; a, b, c, d) = \begin{cases} 0, & x \leq a. \\ \frac{x-a}{b-a}, & a < x < b. \\ 1, & b \leq x \leq c. \\ \frac{d-x}{d-c}, & c < x < d. \\ 0, & d \leq x. \end{cases} \quad (\text{B.7})$$

Utilizando a notação para mínimos e máximos, a equação B.7 pode ser reescrita como:

$$\text{trapezoidal}(x; a, b, c, d) = \max(\min(\frac{x-a}{b-a}, 1, \frac{d-x}{d-c}), 0) \quad (\text{B.8})$$

Os parâmetros $\{a, b, c, d\}$, com $a \leq b \leq c \leq d$ determinam as coordenadas x dos quatro cantos da função de pertença trapezoidal. Na Figura B.1 é apresentada uma função trapezoidal cujos parâmetros $\{a, b, c, d\}$ são respetivamente (10,20,60,95).

Devido à sua simplicidade e eficiência computacional, as funções triangulares e trapezoidais são extensivamente utilizadas, especialmente em implementações on-line. No entanto, devido ao facto das funções serem definidas por segmentos de reta, não são tão suaves como outras funções nos seus cantos.

Uma função gaussiana é especificada por dois parâmetros $\{c, \sigma\}$ da seguinte forma:

$$\text{gaussian}(x; c, \sigma) = e^{-\frac{1}{2}\left(\frac{x-c}{\sigma}\right)^2} \quad (\text{B.9})$$

A função gaussiana é completamente definida pelos dois parâmetros $\{c, \sigma\}$, onde c representa o centro e σ o desvio da função. Na Figura B.1 é apresentada uma função gaussiana cujos parâmetros $\{c, \sigma\}$ são respectivamente (50,20).

Uma função em forma de sino é especificada por três parâmetros $\{a, b, c\}$ da seguinte forma:

$$\text{bell}(x; a, b, c) = \frac{1}{1 + \left|\frac{x-c}{a}\right|^{2b}} \quad (\text{B.10})$$

A função em forma de sino é completamente definida pelos três parâmetros $\{a, b, c\}$, onde b é normalmente positivo, se b for negativo a função é horizontalmente espelhada. Os restantes parâmetros $\{a, c\}$ podem ser ajustados de forma a alterar, respectivamente, a largura e a posição do centro da função. Na Figura B.1 é apresentada uma função em forma de sino cujos parâmetros $\{a, b, c\}$ são respectivamente (20,4,50).

Devido à sua suavidade e notação concisa, as funções gaussianas e em forma de sino têm sido cada vez mais utilizadas, especialmente em probabilidades e estatística. No entanto, estas funções não permitem especificar funções de pertença assimétricas, importantes em certas aplicações.

Uma forma simples de expressar assimetria nas funções de pertença é através de derivações das funções triangulares e trapezoidais. Estas funções são amplamente utilizadas para definir as funções de pertença nos limites inferior e superior do intervalo de valores.

Uma função linear de saturação em forma de Z, para $-\infty$, é especificada por dois parâmetros $\{a, b\}$ da seguinte forma:

$$\text{linzmf}(x; a, b) = \begin{cases} 1, & x < a. \\ \frac{a-x}{a-b}, & a \leq x \leq b. \\ 0, & b > x. \end{cases} \quad (\text{B.11})$$

Quando $a = b$, a equação B.11 pode ser reescrita como:

$$\text{linzmf}(x; a, b) = \begin{cases} 1, & x < a. \\ 0, & a \leq x. \end{cases} \quad (\text{B.12})$$

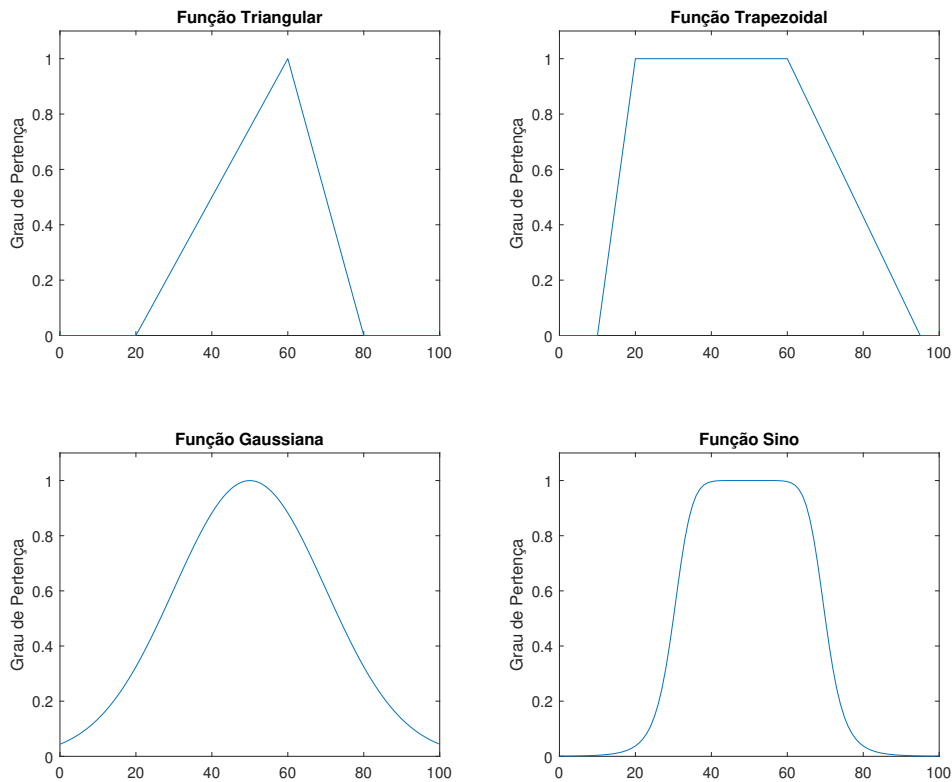


FIGURA B.1: Exemplo das quatro funções de pertença

Os parâmetros $\{a, b\}$, com $a \leq b$ determinam as coordenadas x dos dois cantos da função de pertença de saturação. Na Figura B.2 é apresentada uma função de saturação em forma de Z cujos parâmetros $\{a, b\}$ são respetivamente (40,60).

Uma função linear de saturação em forma de S, para $+\infty$, é especificada por dois parâmetros $\{a, b\}$ da seguinte forma:

$$\text{linsmf}(x; a, b) = \begin{cases} 0, & x < a. \\ \frac{x-a}{b-a}, & a \leq x \leq b. \\ 1, & b > x. \end{cases} \quad (\text{B.13})$$

Quando $a = b$, a equação B.13 pode ser reescrita como:

$$\text{linsmf}(x; a, b) = \begin{cases} 0, & x < a. \\ 1, & a \leq x. \end{cases} \quad (\text{B.14})$$

Os parâmetros $\{a, b\}$, com $a \leq b$ determinam as coordenadas x dos dois

cantos da função de pertença de saturação. Na Figura B.2 é apresentada uma função de saturação em forma de S cujos parâmetros $\{a, b\}$ são respetivamente $(50, 80)$.

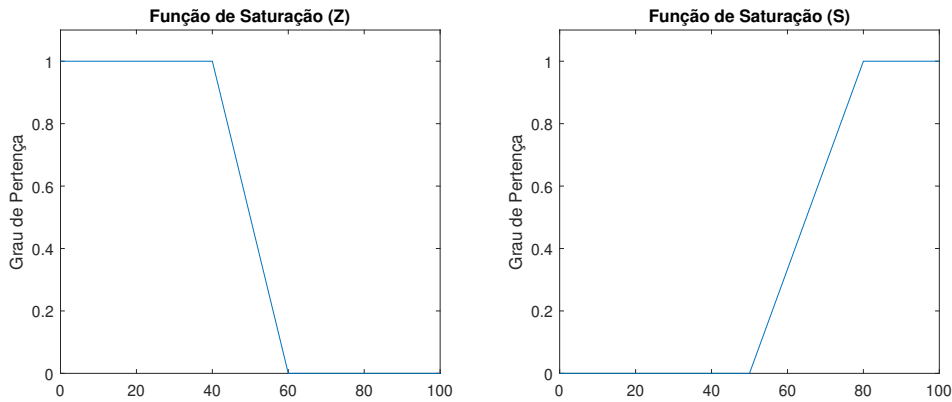


FIGURA B.2: Funções de pertença de saturação

Regras e relações difusas são a estrutura principal de um sistema de inferência difuso, que constitui a ferramenta difusa de modelação mais importante. O conceito de variáveis linguísticas é uma abordagem alternativa para a modelação do pensamento humano. Uma abordagem que, de uma forma aproximada, sumariza e expressa a informação em termos de conjuntos difusos. Uma regra semântica é responsável por definir a função de pertença de cada valor linguístico no universo considerado. Estes valores linguísticos podem ser sujeitos a várias operações para uma definição mais precisa do conhecimento. (Zadeh, 1965)

Os conjuntos difusos podem ser sujeitos a operações complementares de modo a expressar de forma mais precisa o valor quantitativo de uma variável qualitativa linguística complexa.

A operação de concentração a uma função de pertença, Equação B.1, é o resultado da aplicação do termo “muito” ao termo linguístico da função de pertença A , e é definido como o quadrado da função de pertença:

$$\text{CON}(A) = \mu_A(x)^2 \tag{B.15}$$

A operação de dilatação a uma função de pertença, Equação B.1, é o resultado da aplicação do termo “mais ou menos” ao termo linguístico da função de pertença A , e é definido como a raiz da função de pertença:

$$\text{DIL}(A) = \mu_A(x)^{0,5} \tag{B.16}$$

Estas duas operações podem ser combinadas com as operações básicas, como a união, a interseção e a negação, para obter termos linguísticos complexos, como por exemplo, Figura B.3:

- não A e não B = $\neg A \cap \neg B$
- A mas não muito A = $A \cap \neg A^2$
- muito muito B = $(B^2)^2$
- não muito A nem muito B = $\neg A^2 \cap \neg B^2$




FIGURA B.3: Funções de pertença para valores linguísticos compostos

A operação de intensificação de contraste reduz o efeito difuso de uma função de pertença, é definida como o dobro do quadrado da função de pertença e a negação do dobro do quadrado da negação da função de pertença para valores de pertença acima e abaixo, respetivamente, do valor médio de grau de pertença:

$$\text{INT}(A) = \begin{cases} 2A^2, & 0 \leq \mu_A(x) < 0,5. \\ -2(\neg A)^2, & 0,5 \leq \mu_A(x) \leq 1. \end{cases} \quad (\text{B.17})$$

A operação de intensificação de contraste, B.17 pode ser rescrita da seguinte forma:

$$\text{INT}(A) = \begin{cases} 2\mu_A(x)^2, & 0 \leq \mu_A(x) < 0,5. \\ 1 - 2(1 - \mu_A(x))^2, & 0,5 \leq \mu_A(x) \leq 1. \end{cases} \quad (\text{B.18})$$

A operação de diminuição de contraste aumenta o efeito difuso de uma função de pertença, é definida como a raiz de metade da função de pertença e a negação da raiz de metade da negação da função de pertença para valores de pertença acima e abaixo, respetivamente, do valor médio de grau de pertença:

$$\text{DIM}(A) = \begin{cases} (0,5A)^{0,5}, & 0 \leq \mu_A(x) < 0,5. \\ \neg(0,5\neg A)^{0,5}, & 0,5 \leq \mu_A(x) \leq 1. \end{cases} \quad (\text{B.19})$$

A operação de diminuição de contraste, B.19 pode ser rescrita da seguinte forma:

$$\text{DIM}(A) = \begin{cases} (0,5\mu_A(x))^{0,5}, & 0 \leq \mu_A(x) < 0,5. \\ 1 - (0,5(\mu_A(x) - 1))^{0,5}, & 0,5 \leq \mu_A(x) \leq 1. \end{cases} \quad (\text{B.20})$$

Para a função de pertença triangular, Figura B.1 foram aplicadas várias operações de intensificação e diminuição de contraste. A multiplicação das operações é a aplicação contínua das mesmas. É possível verificar o efeito no aumento e diminuição do efeito difuso das respetivas funções de pertença, Figura B.4.

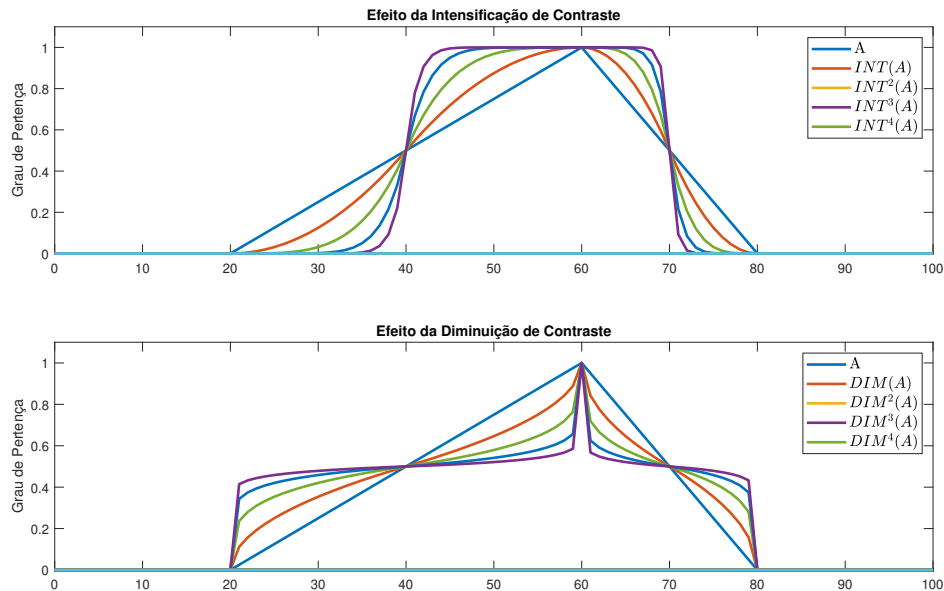


FIGURA B.4: Efeito das operações no contraste das funções de pertença

Apêndice C - Resultados da detecção e diagnóstico de falhas

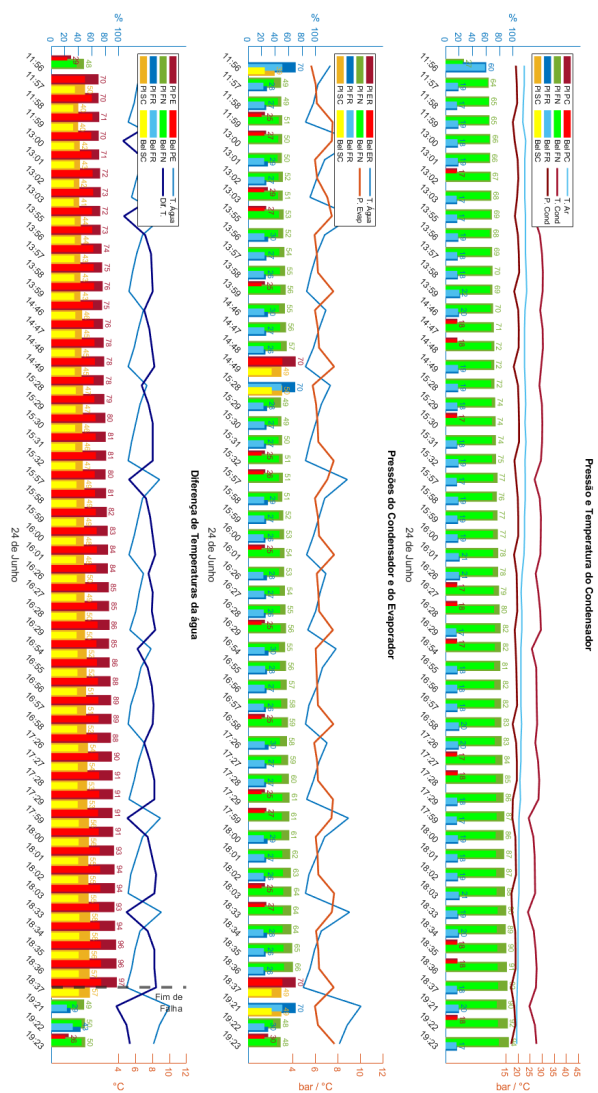


FIGURA C.1: Diagnóstico de falha de dia 24 de junho

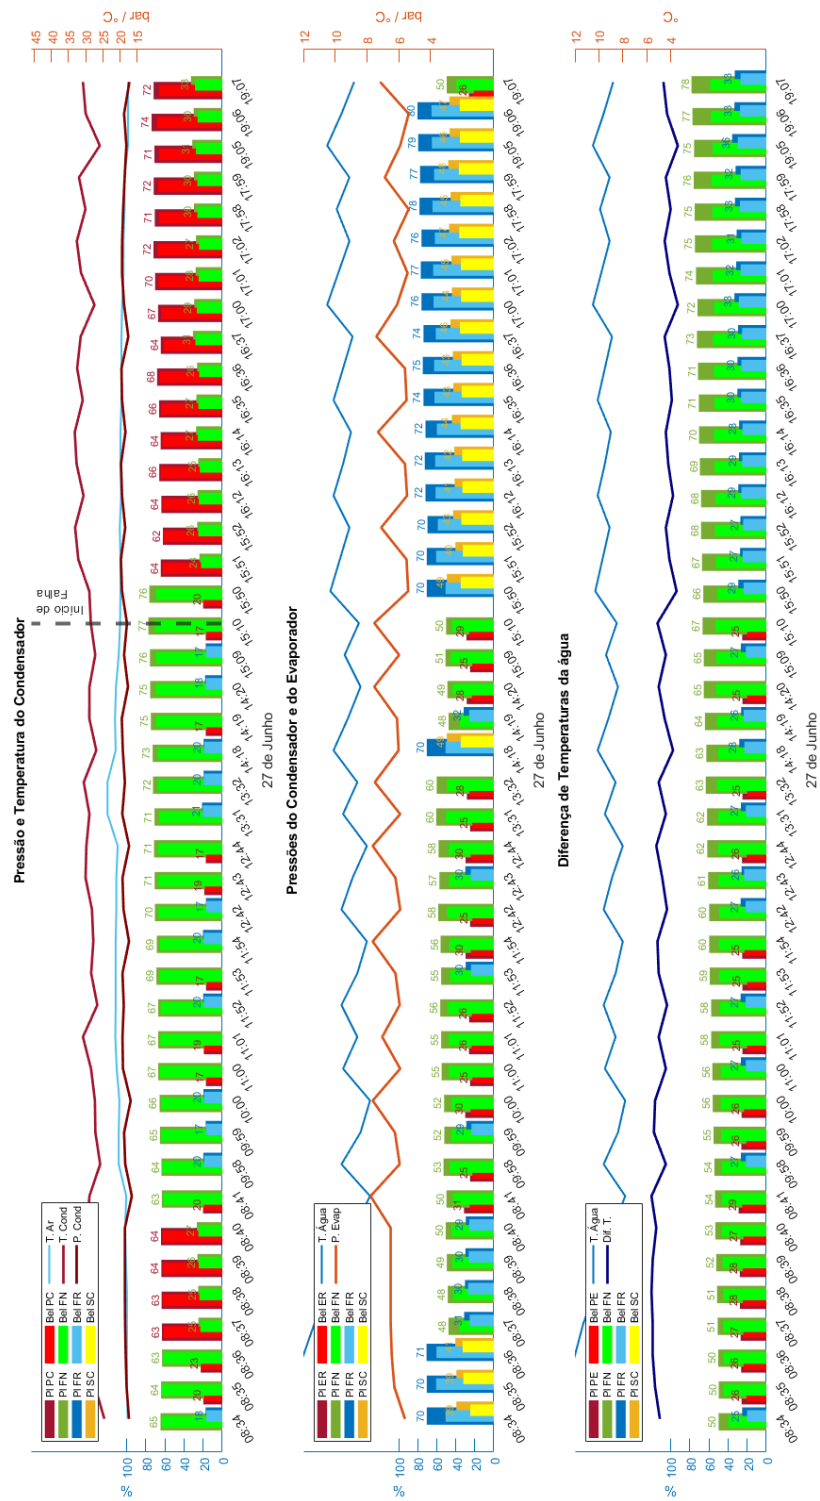


FIGURA C.2: Diagnóstico de falha de dia 27 de junho

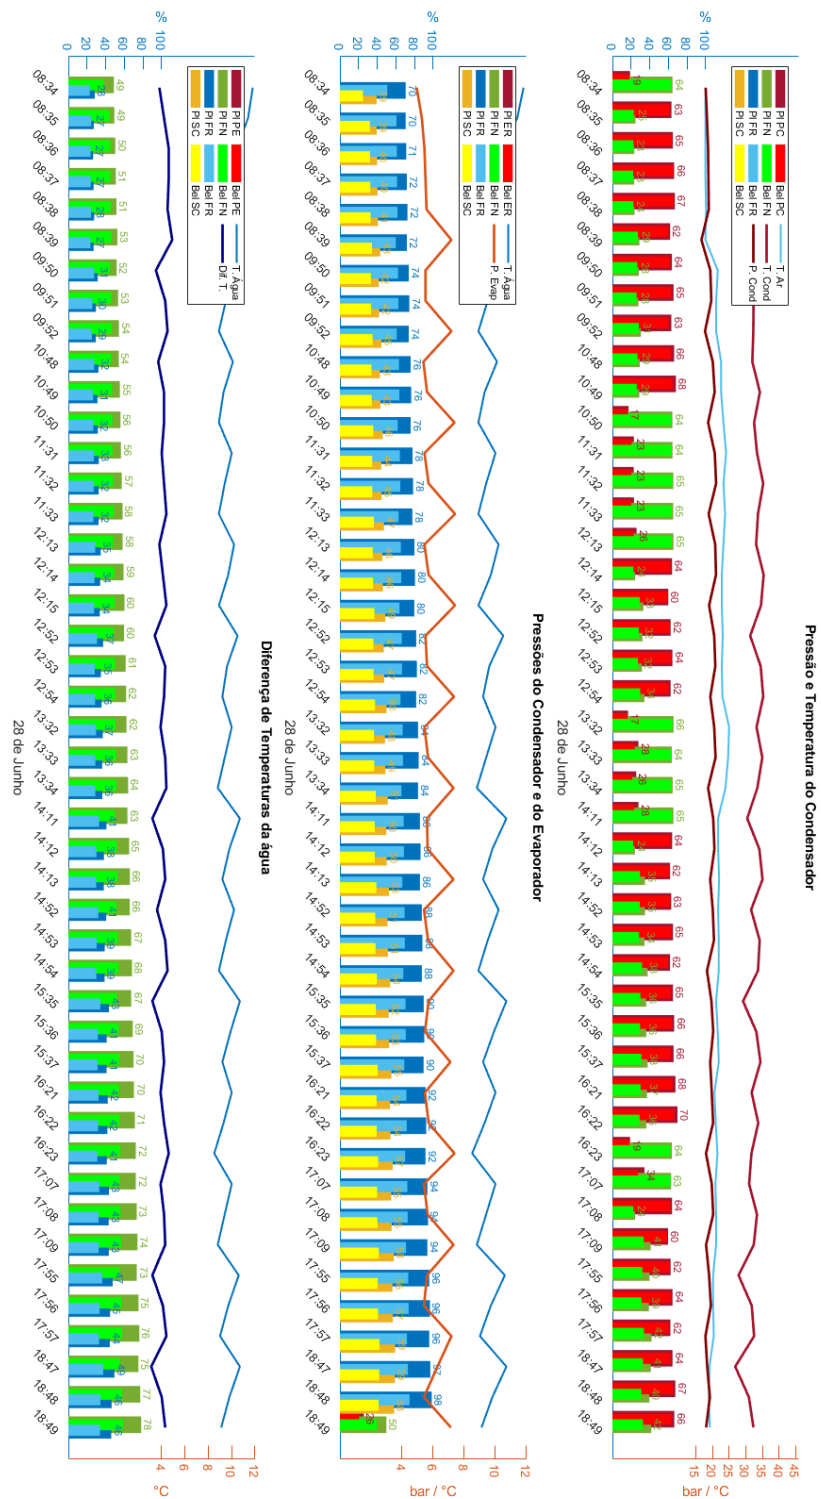


FIGURA C.3: Diagnóstico de falha de dia 28 de junho

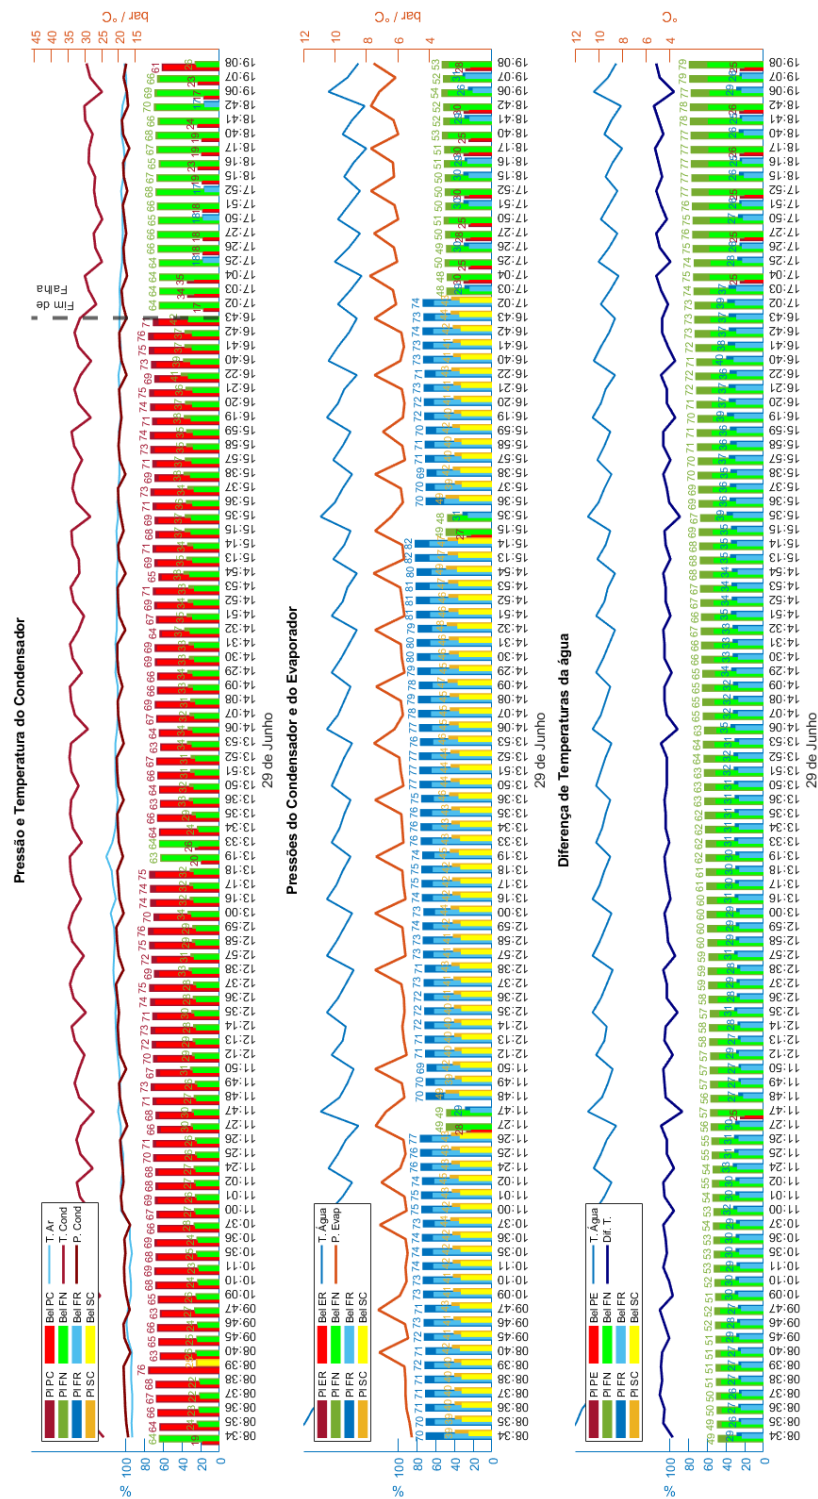


FIGURA C.4: Diagnóstico de falha de dia 29 de junho

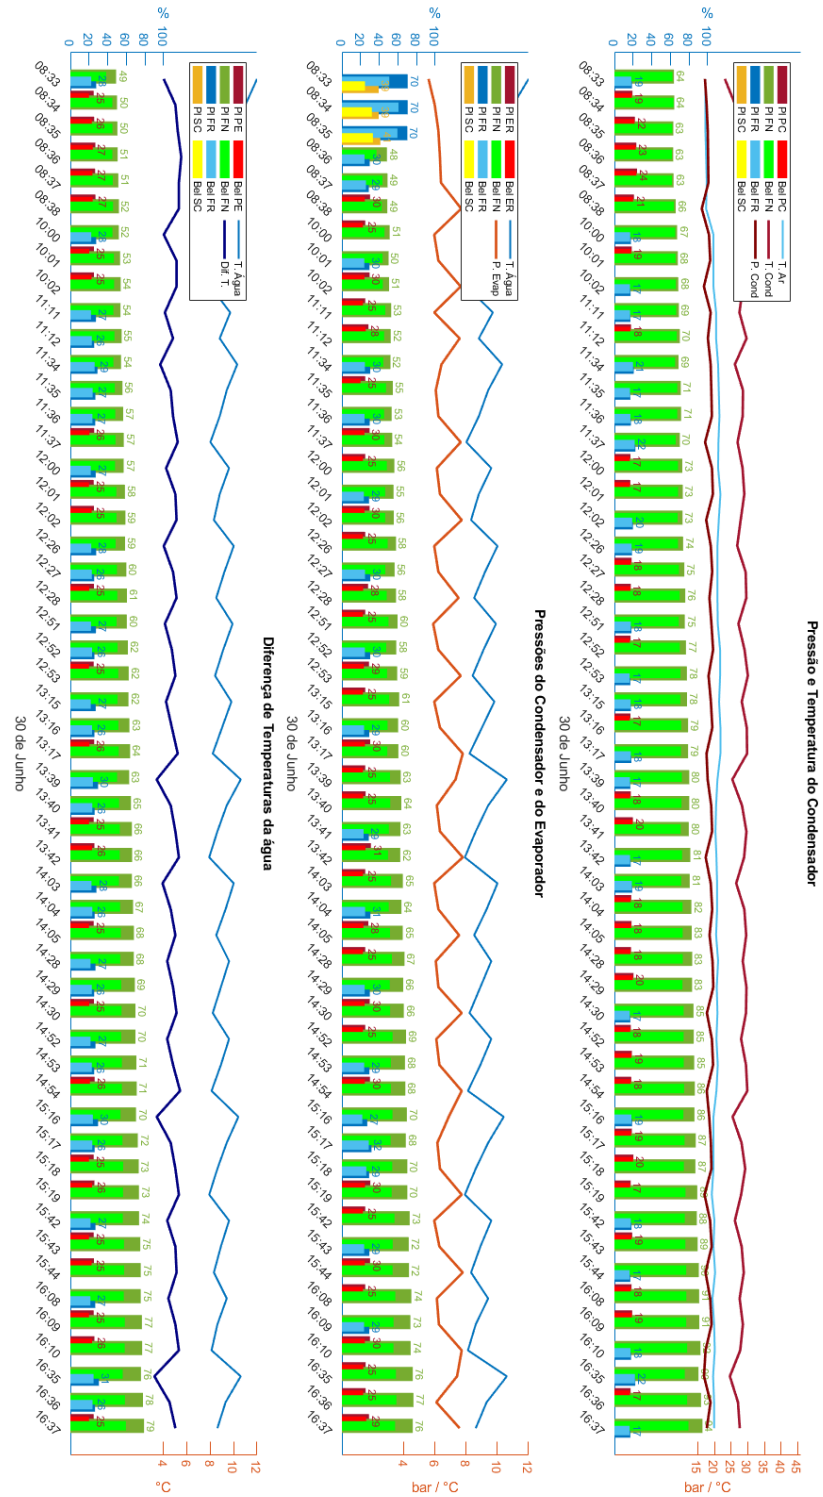


FIGURA C.5: Diagnóstico de falha de dia 30 de junho

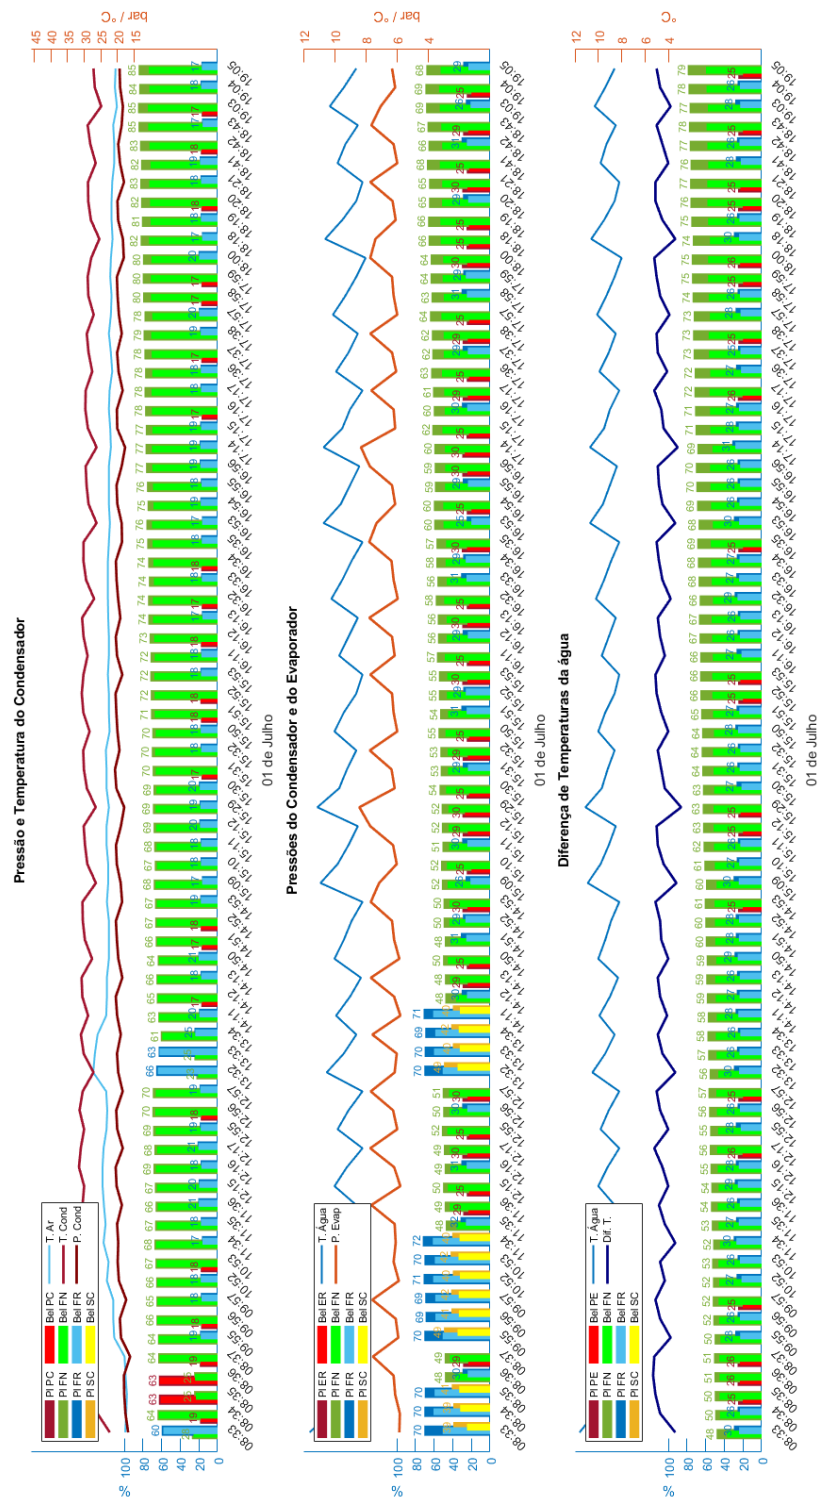


FIGURA C.6: Diagnóstico de falha de dia 1 de julho

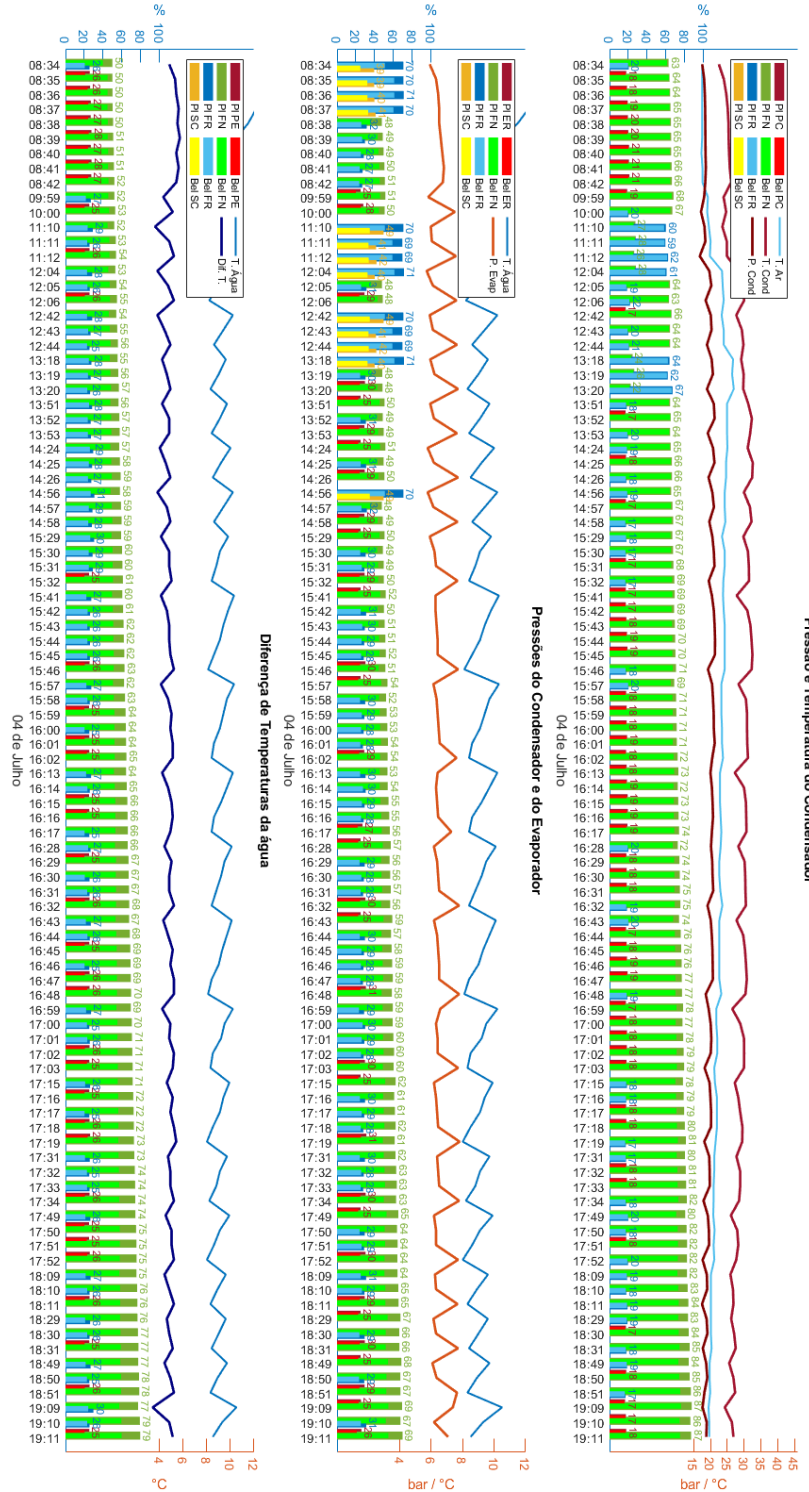


FIGURA C.7: Diagnóstico de falha de dia 4 de julho

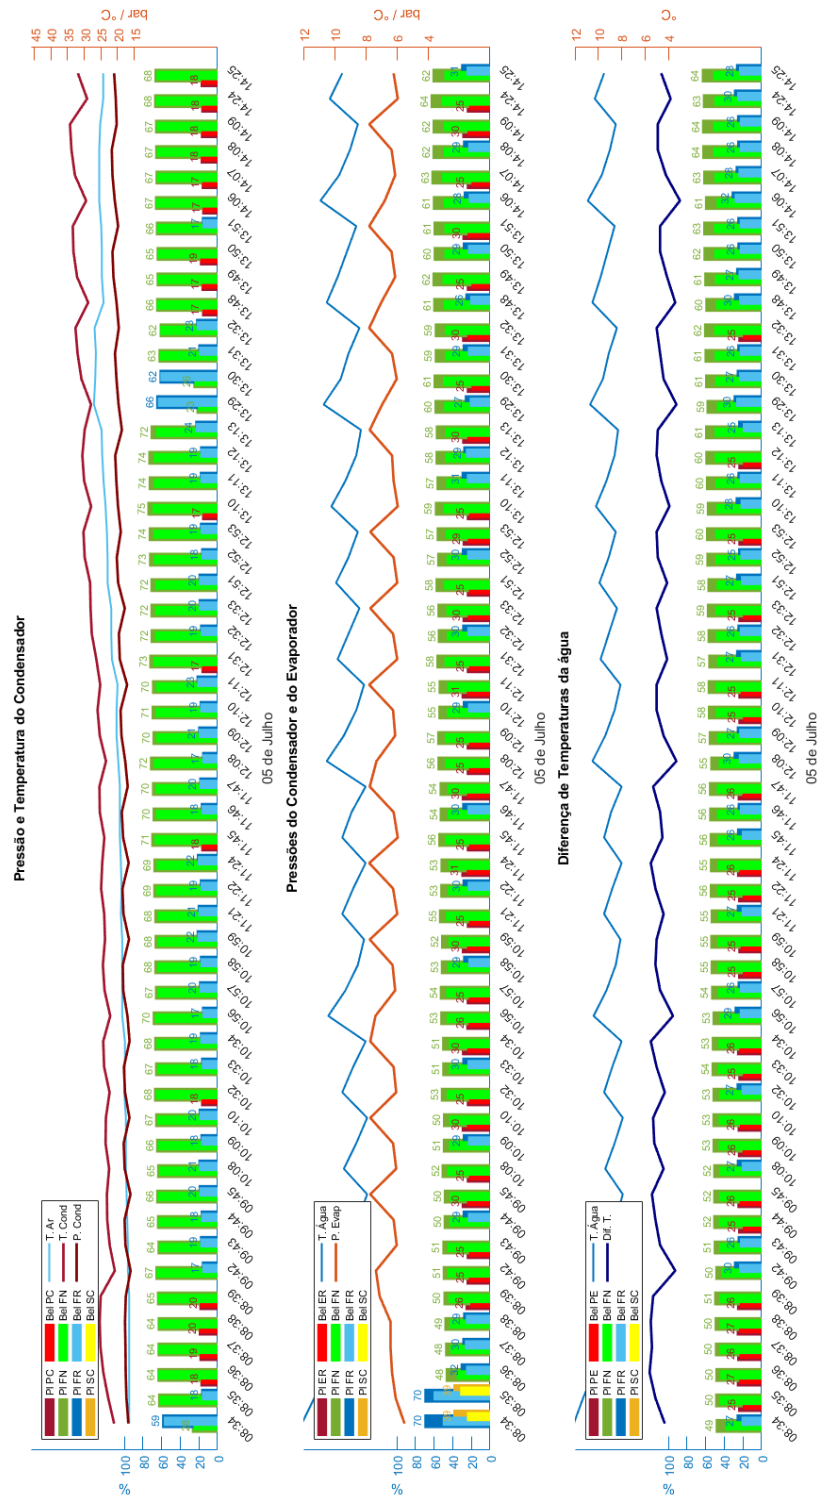


FIGURA C.8: Diagnóstico de falha de dia 5 de julho (1)

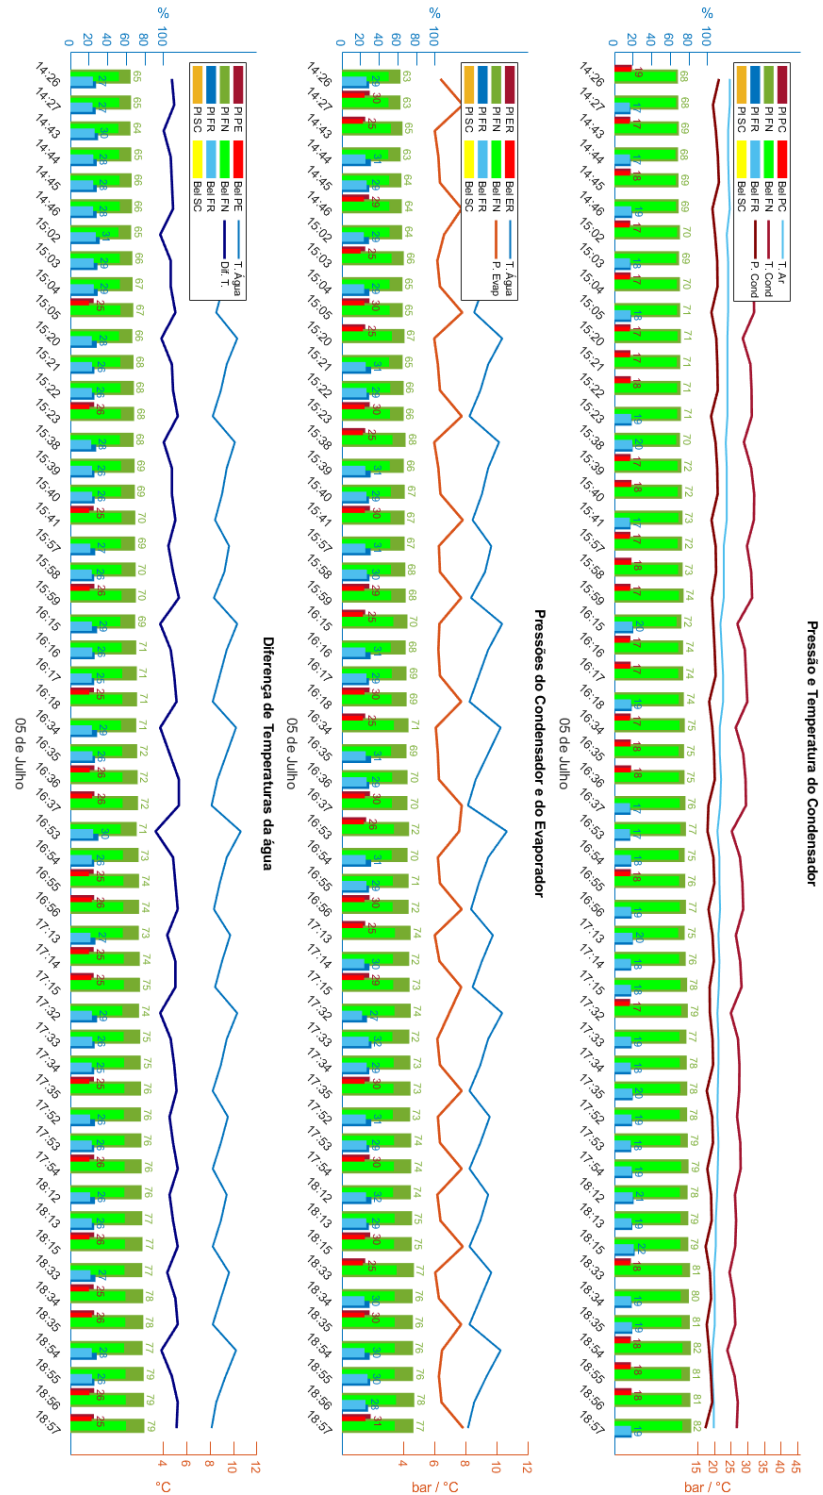


FIGURA C.9: Diagnóstico de falha de dia 5 de julho (2)

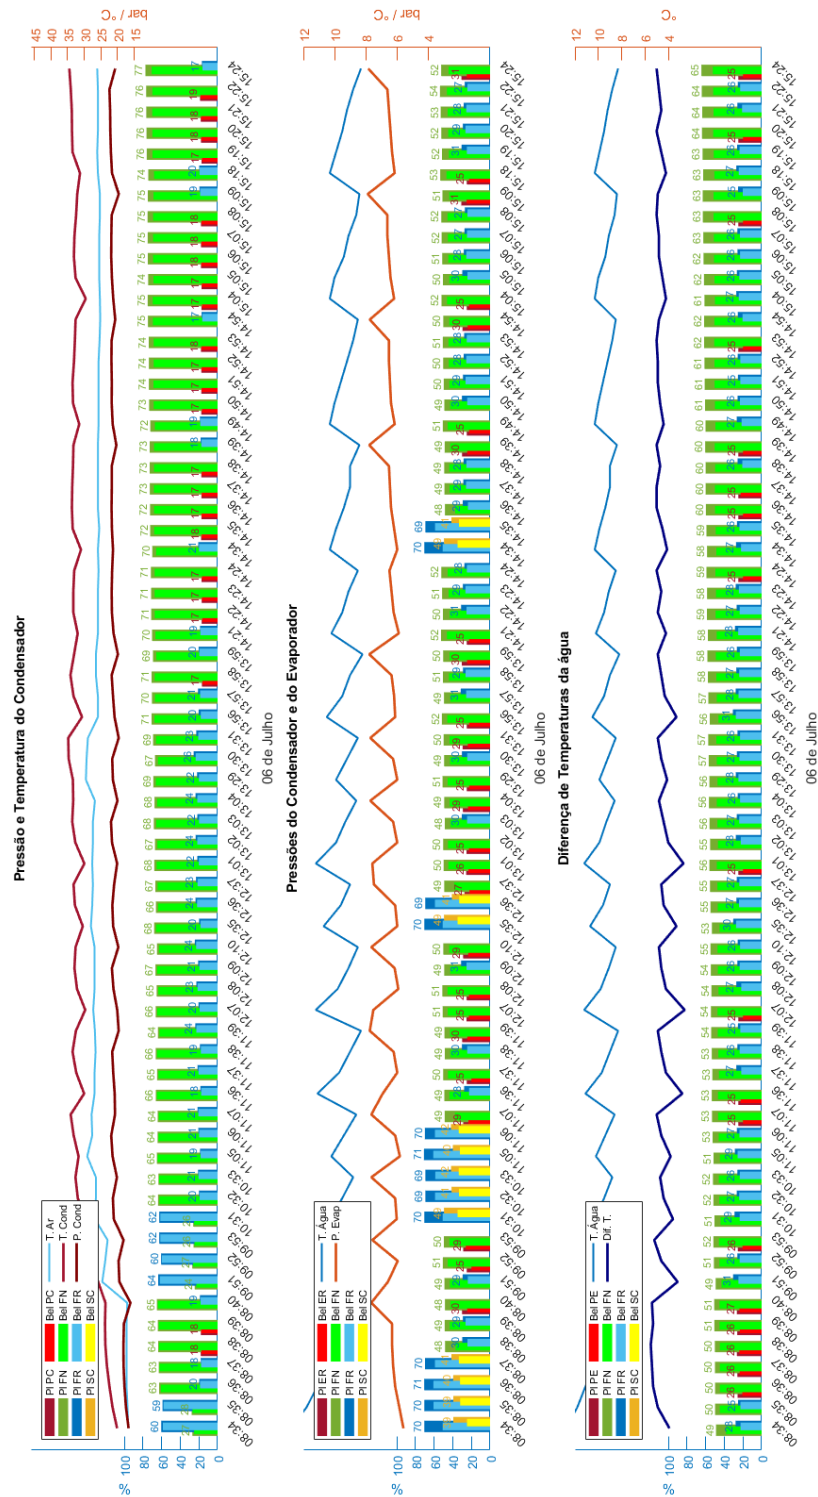


FIGURA C.10: Diagnóstico de falha de dia 6 de julho (1)

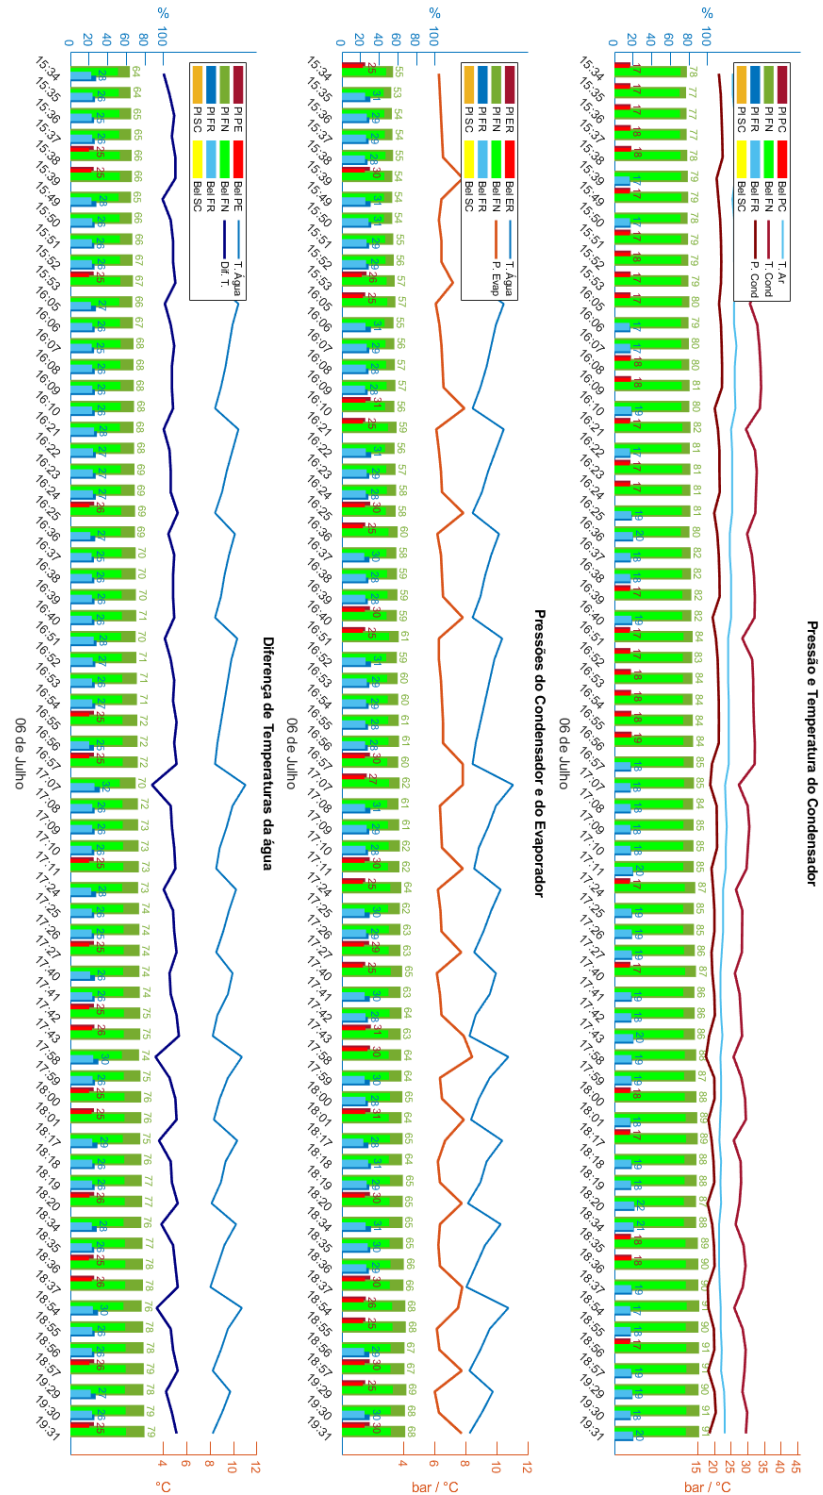


FIGURA C.11: Diagnóstico de falha de dia 6 de julho (2)

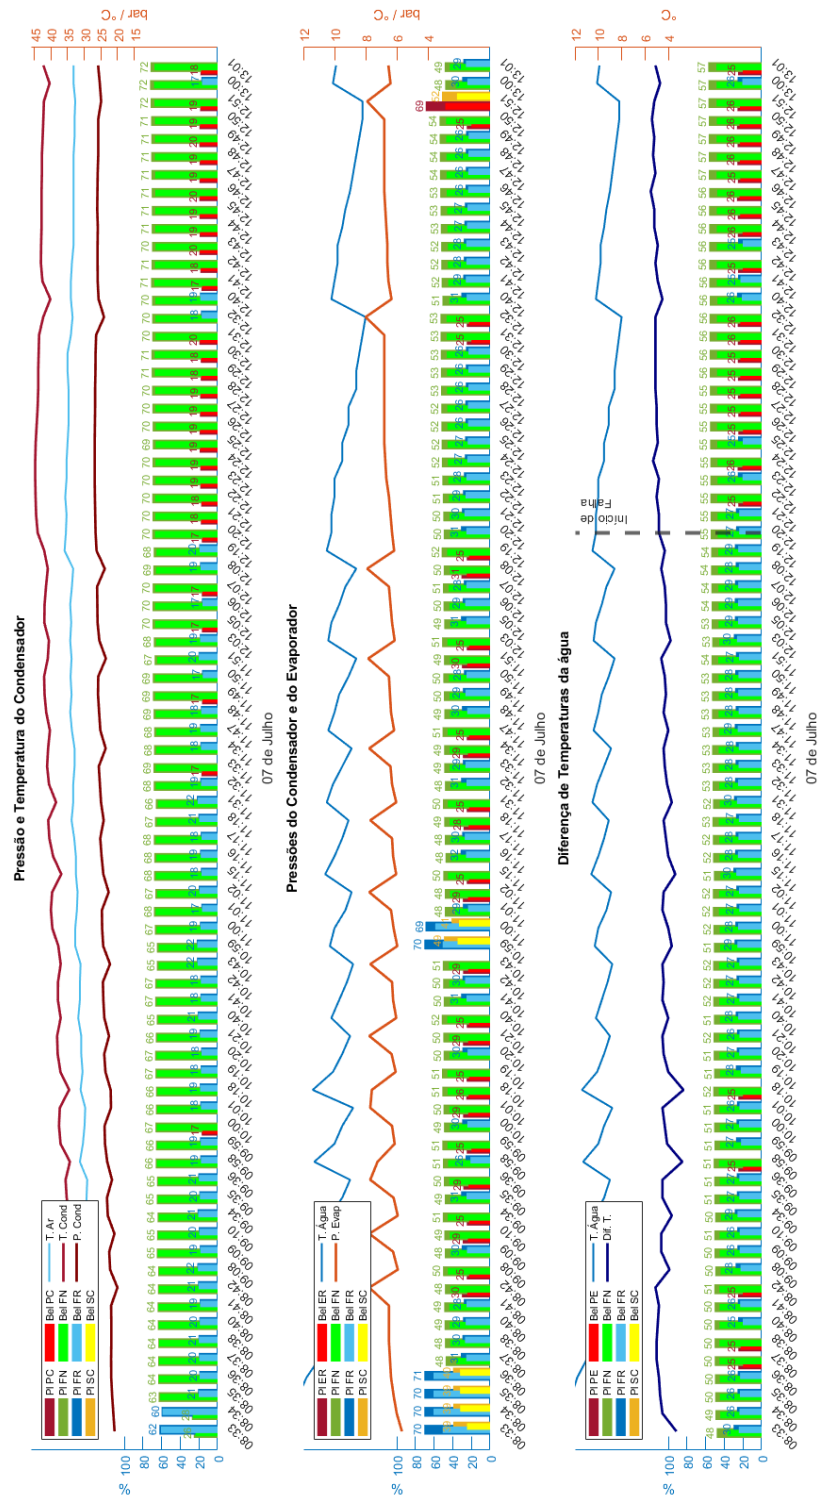


FIGURA C.12: Diagnóstico de falha de dia 7 de julho (1)




FIGURA C.13: Diagnóstico de falha de dia 7 de julho (2)

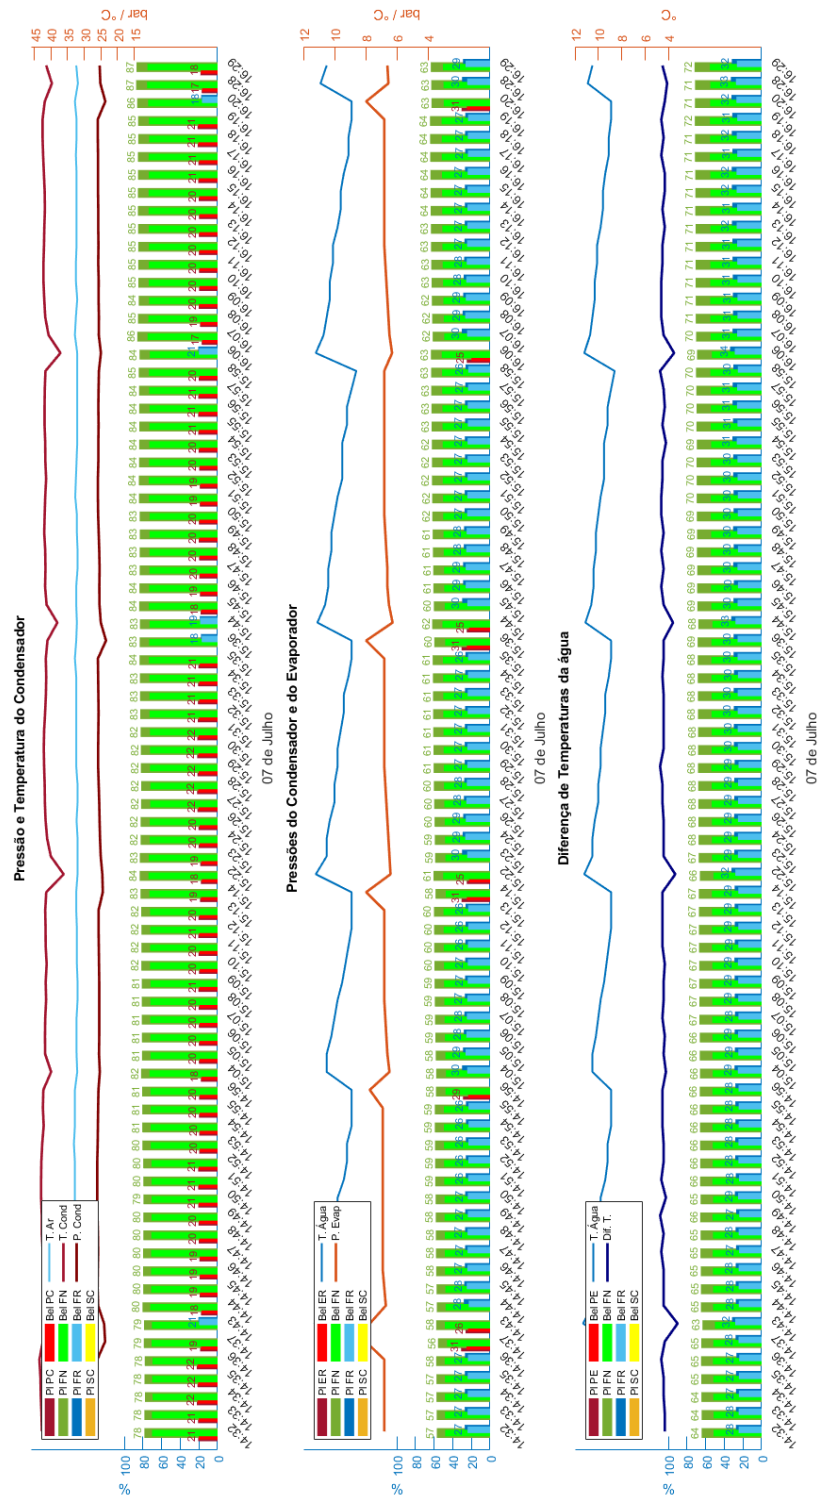


FIGURA C.14: Diagnóstico de falha de dia 7 de julho (3)




FIGURA C.15: Diagnóstico de falha de dia 7 de julho (4)

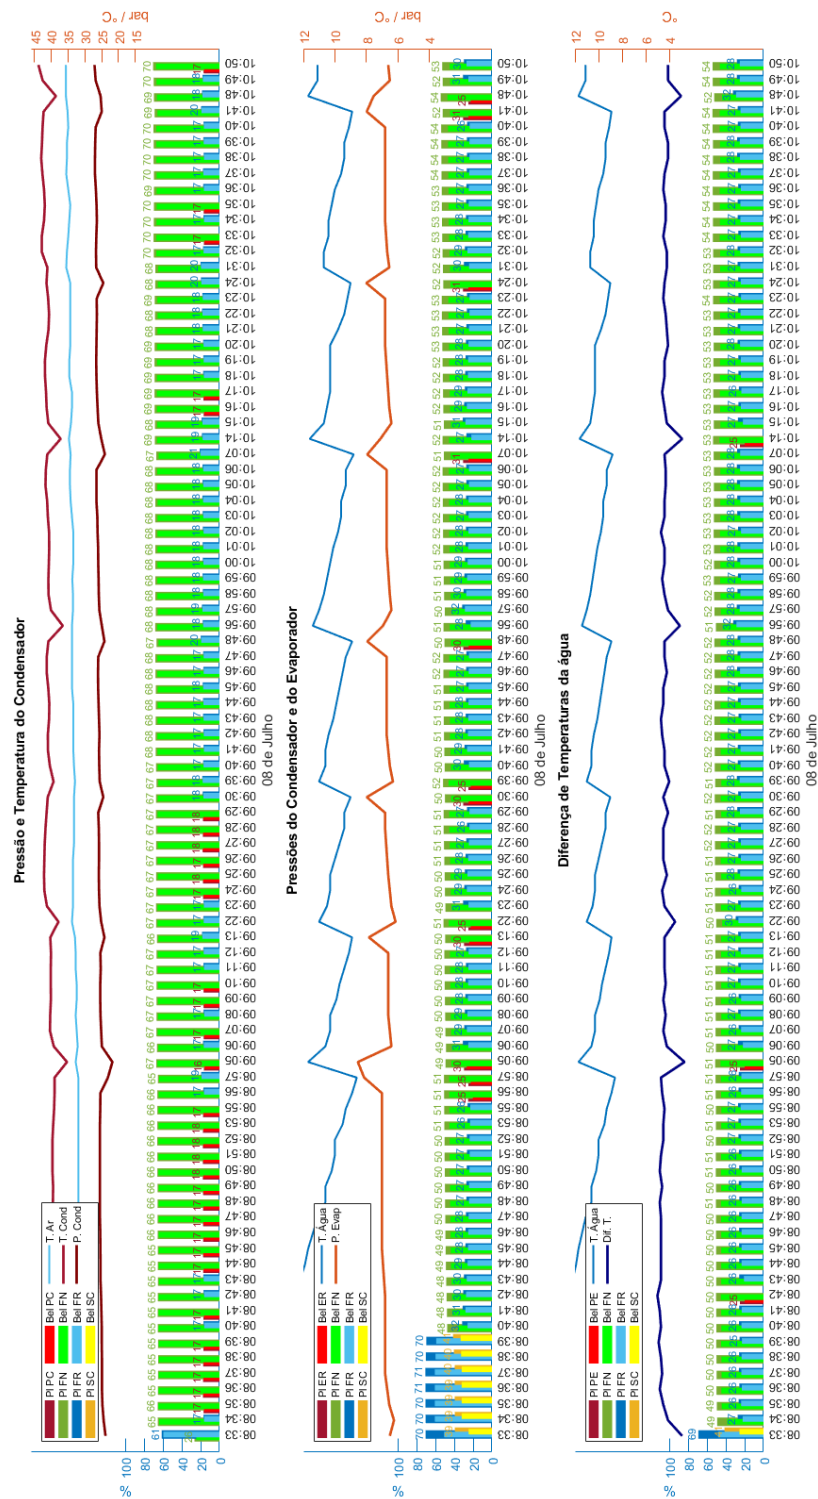


FIGURA C.16: Diagnóstico de falha de dia 8 de julho (1)




FIGURA C.17: Diagnóstico de falha de dia 8 de julho (2)




FIGURA C.18: Diagnóstico de falha de dia 8 de julho (3)




FIGURA C.20: Diagnóstico de falha de dia 8 de julho (5)




FIGURA C.21: Diagnóstico de falha de dia 8 de julho (6)

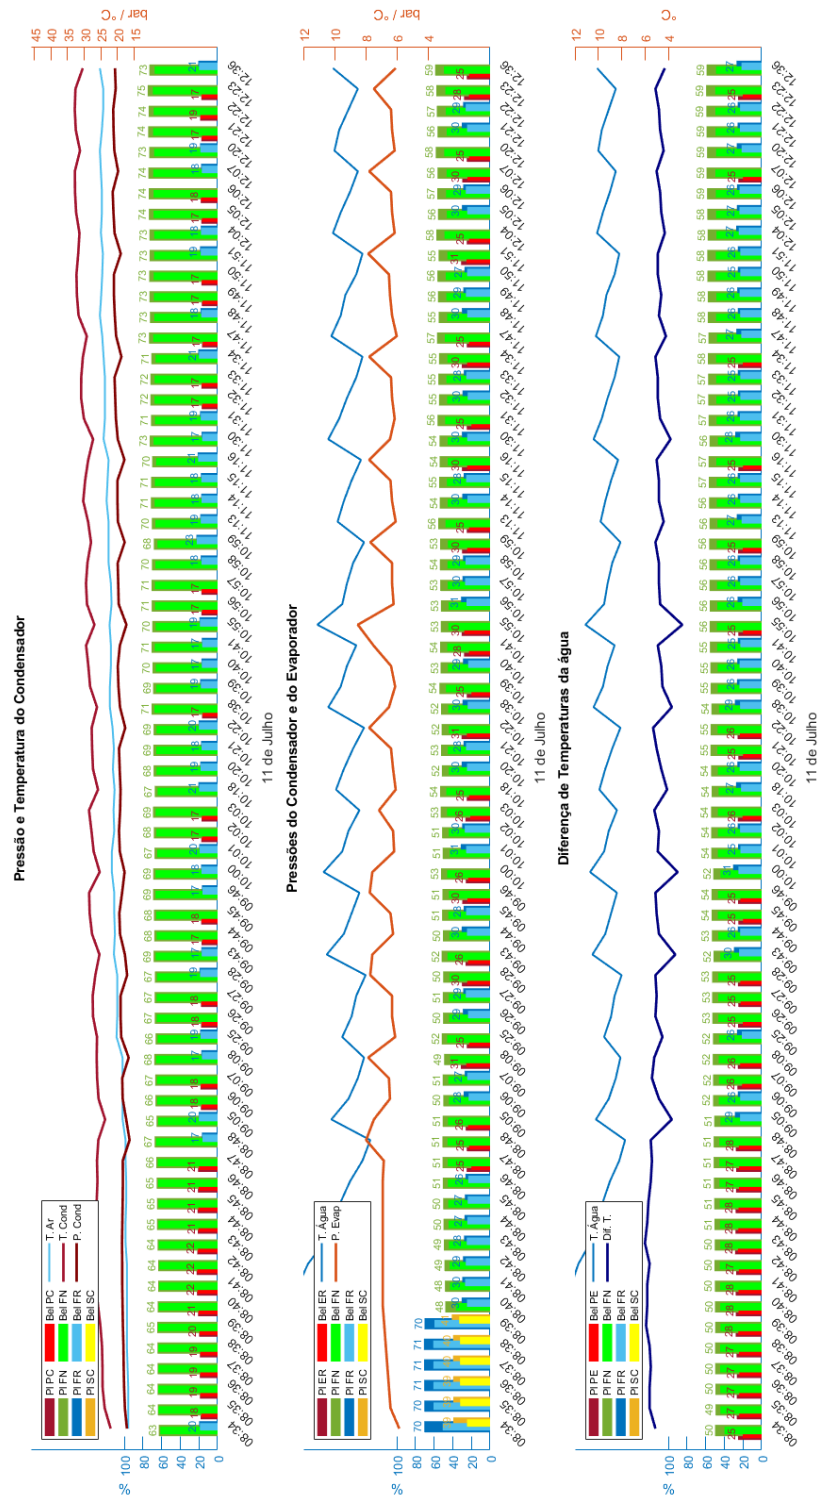


FIGURA C.22: Diagnóstico de falha de dia 11 de julho (1)

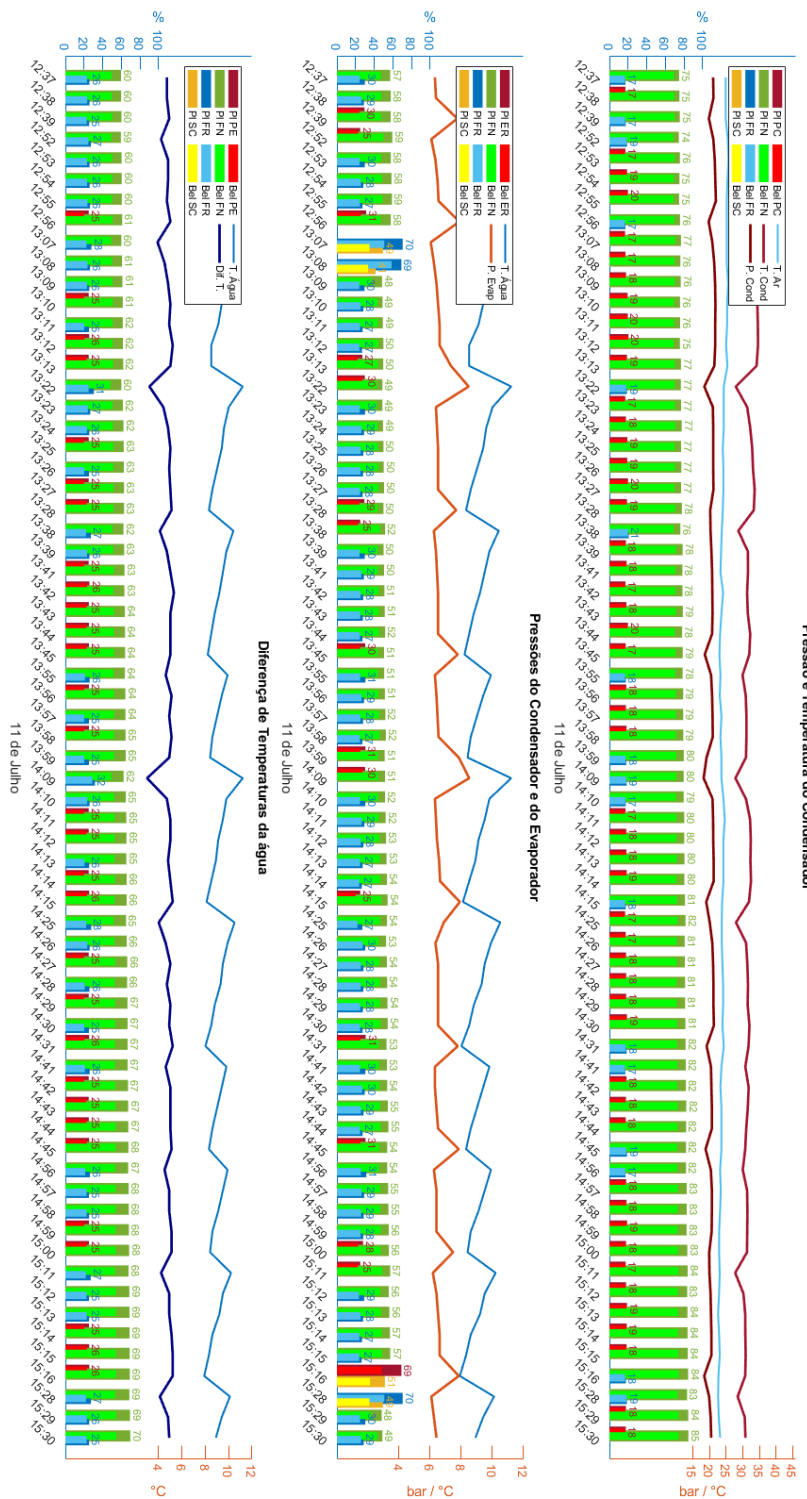


FIGURA C.23: Diagnóstico de falha de dia 11 de julho (2)

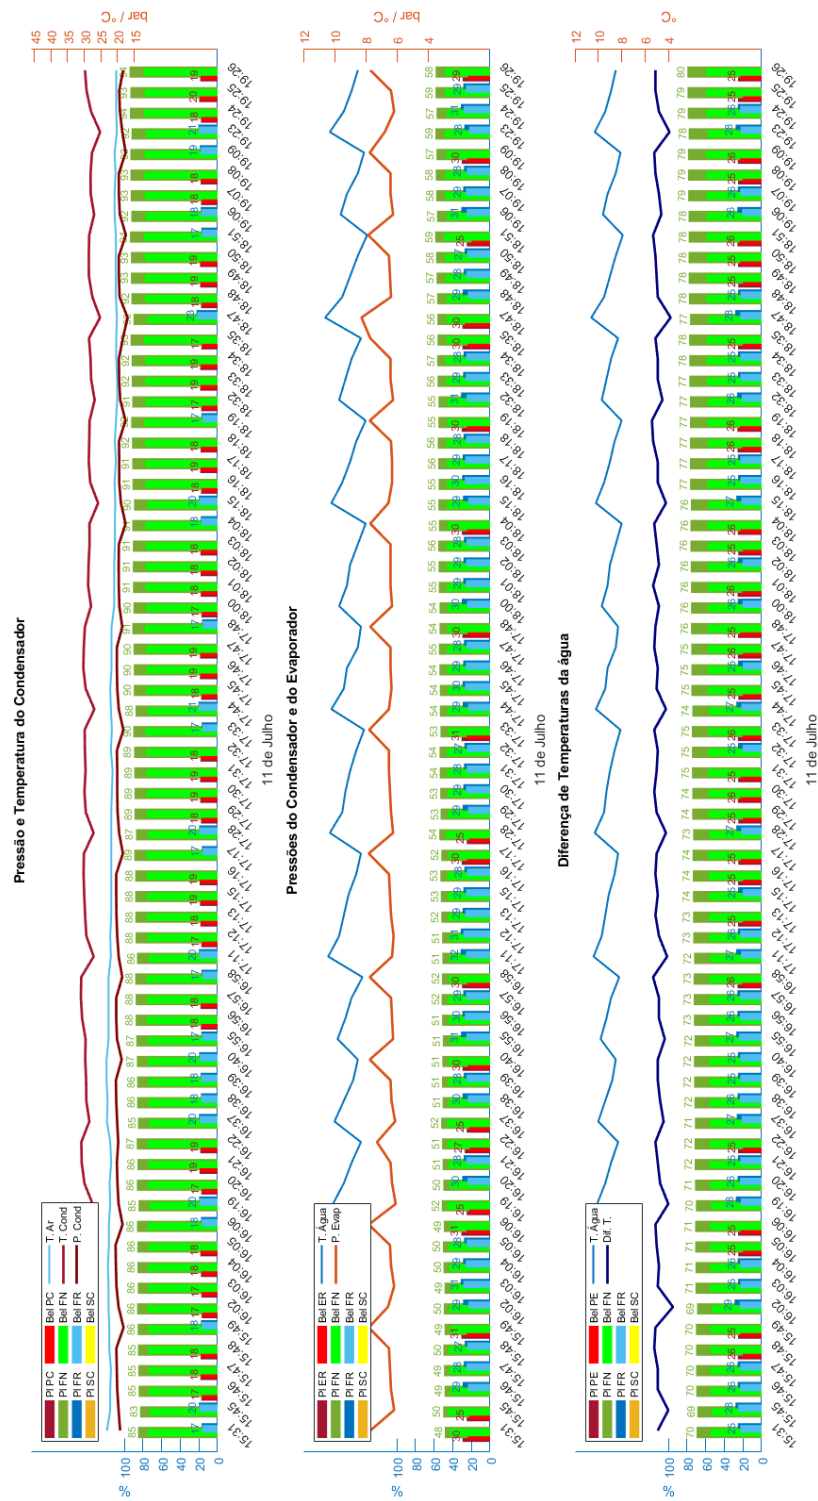


FIGURA C.24: Diagnóstico de falha de dia 11 de julho (3)




FIGURA C.25: Diagnóstico de falha de dia 12 de julho (1)




FIGURA C.26: Diagnóstico de falha de dia 12 de julho (2)

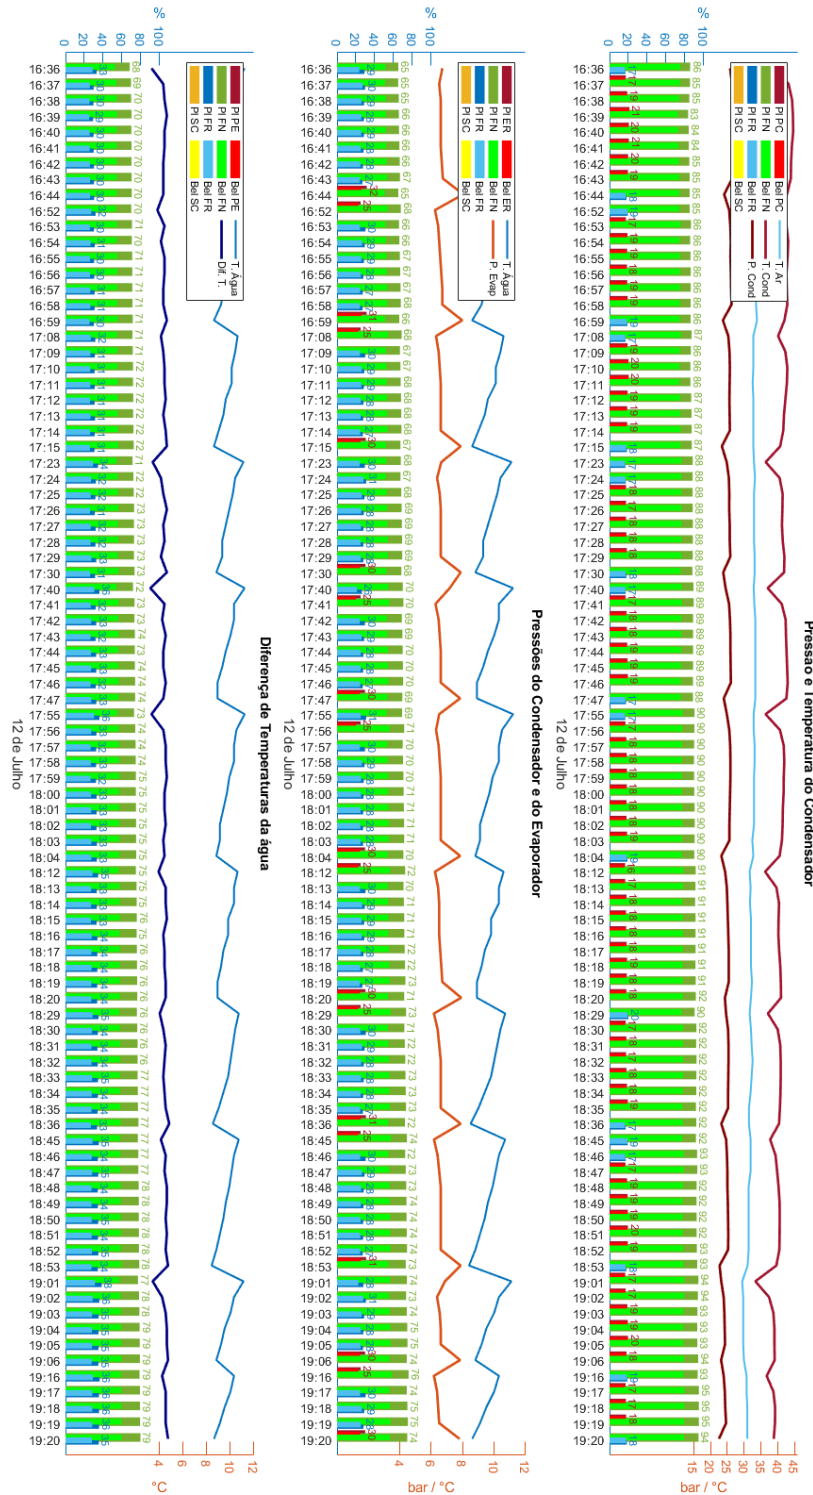


FIGURA C.27: Diagnóstico de falha de dia 12 de julho (3)

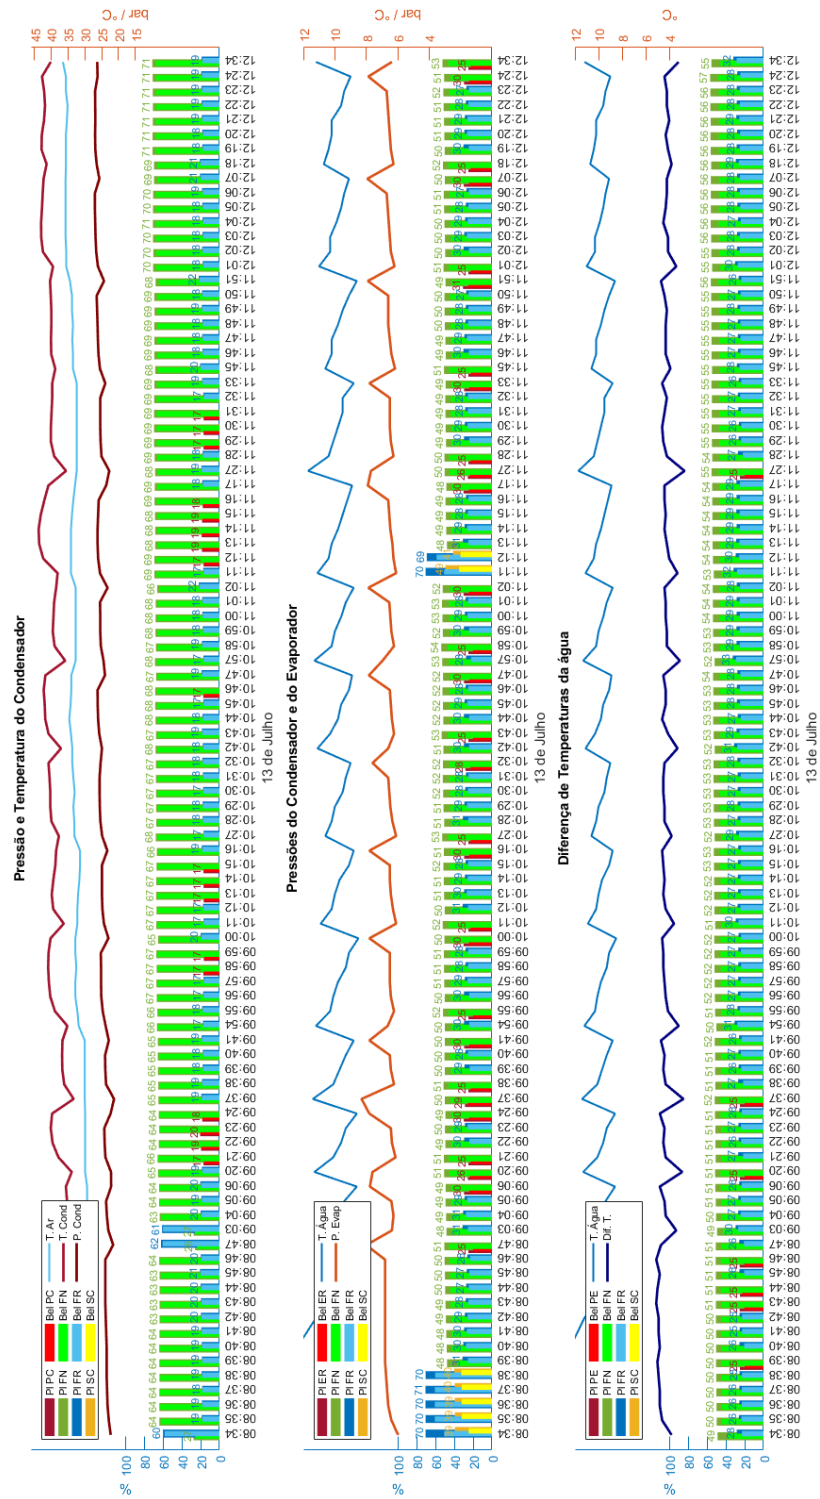


FIGURA C.28: Diagnóstico de falha de dia 13 de julho (1)




FIGURA C.29: Diagnóstico de falha de dia 13 de julho (2)




FIGURA C.30: Diagnóstico de falha de dia 13 de julho (3)




FIGURA C.31: Diagnóstico de falha de dia 13 de julho (4)

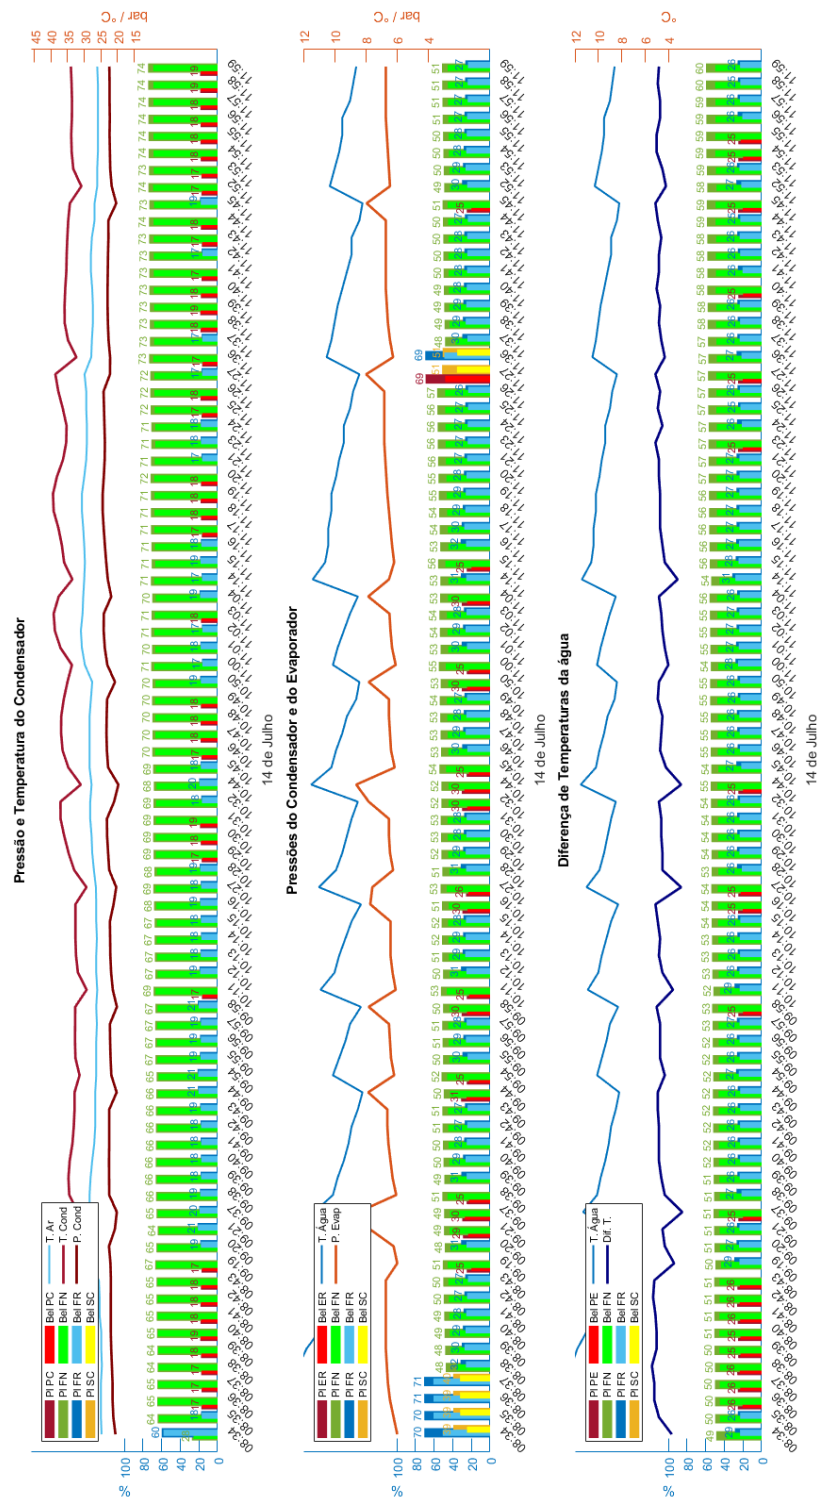


FIGURA C.32: Diagnóstico de falha de dia 14 de julho (1)

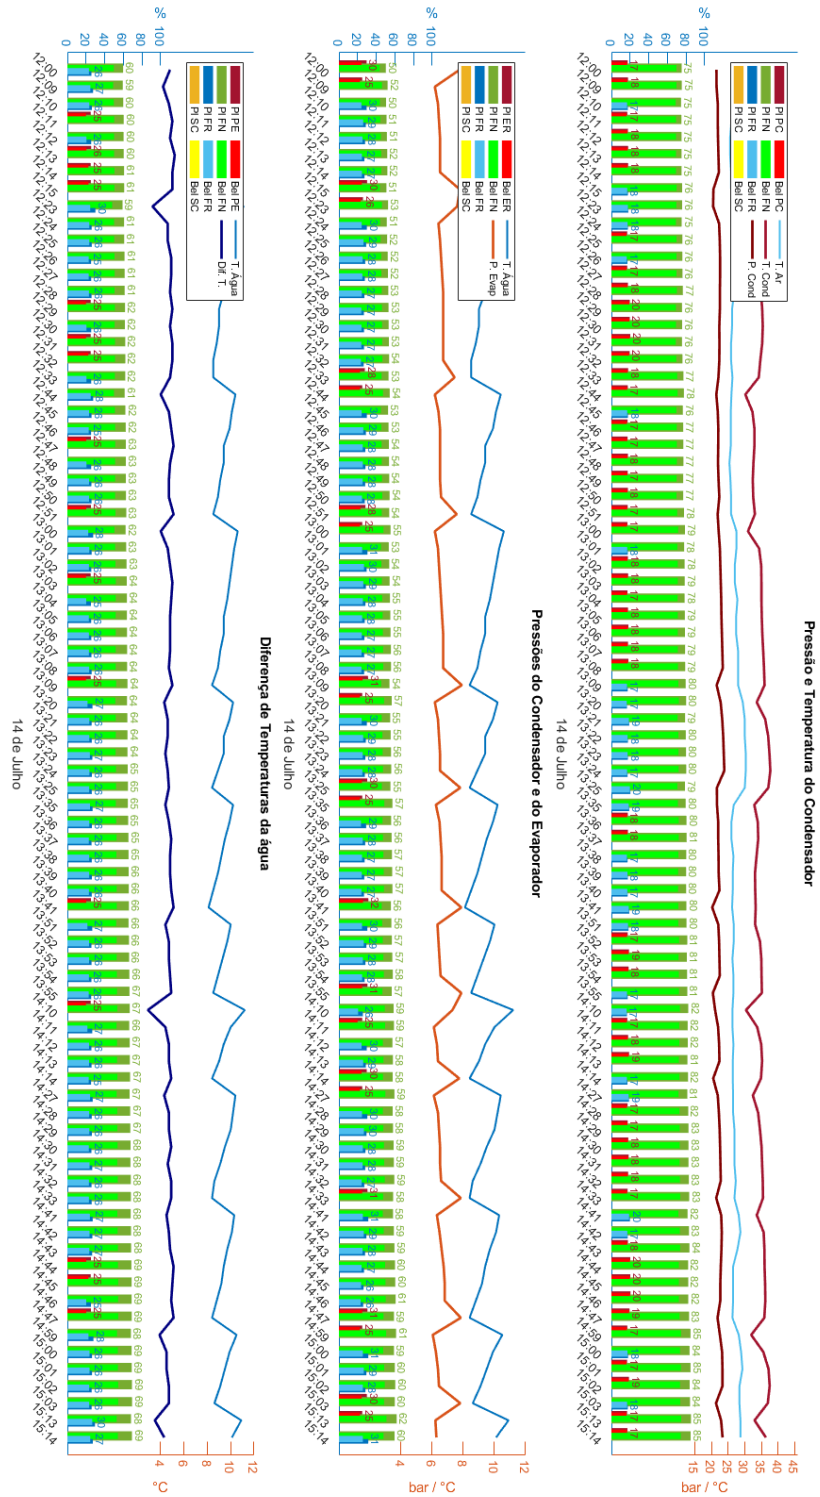


FIGURA C.33: Diagnóstico de falha de dia 14 de julho (2)

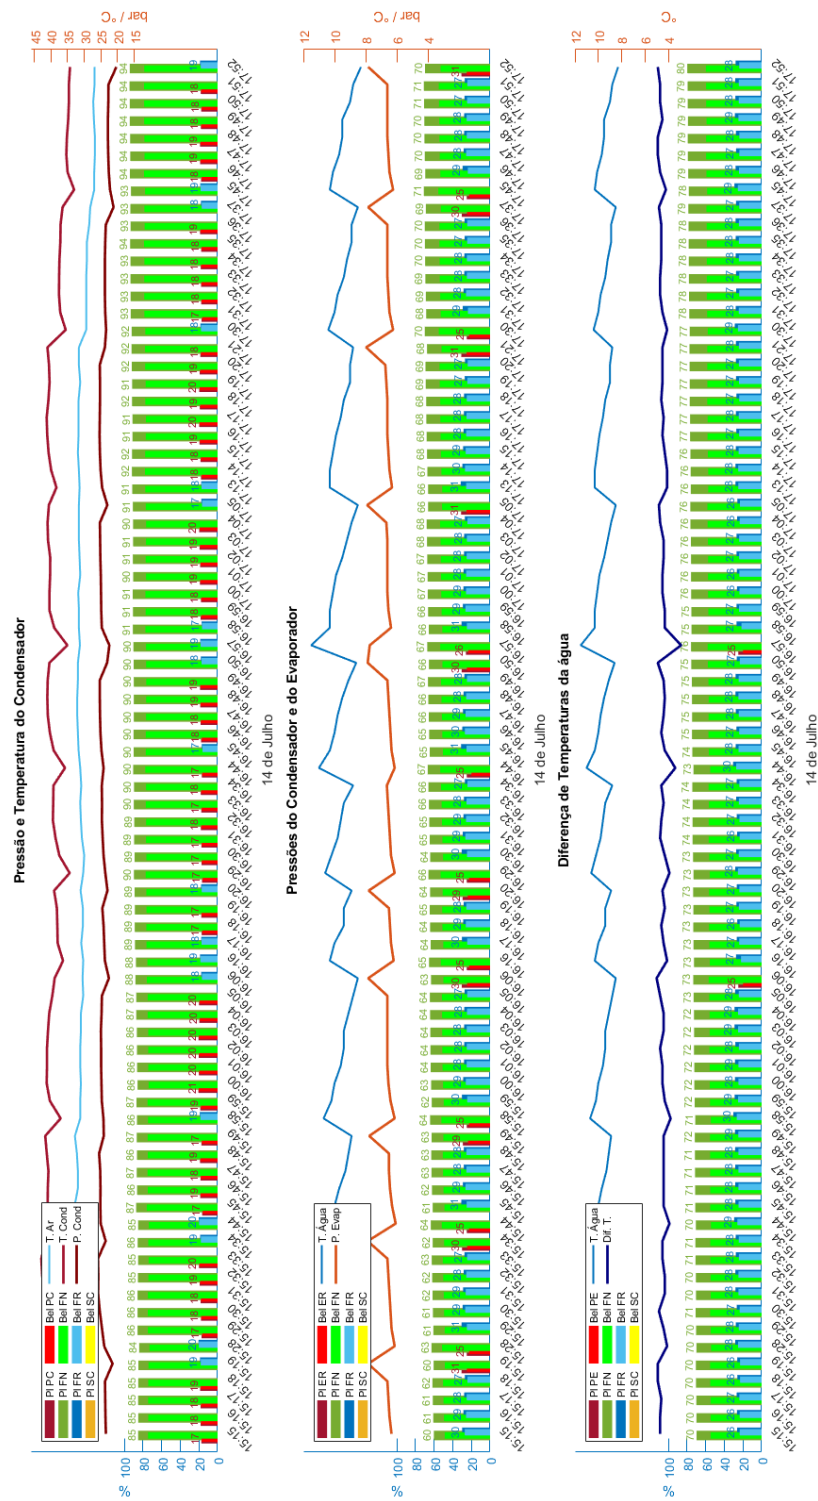


FIGURA C.34: Diagnóstico de falha de dia 14 de julho (3)

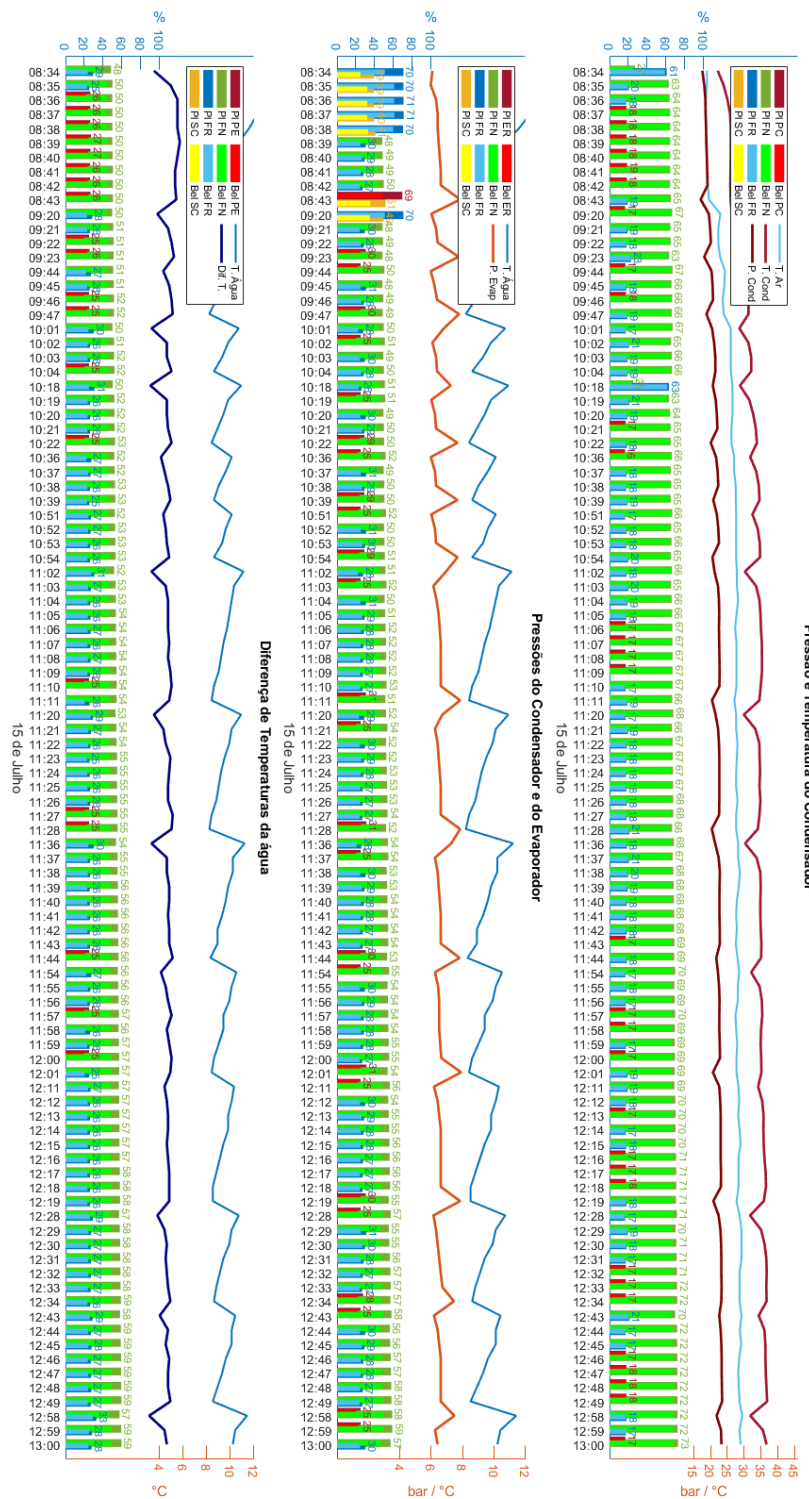


FIGURA C.35: Diagnóstico de falha de dia 15 de julho (1)

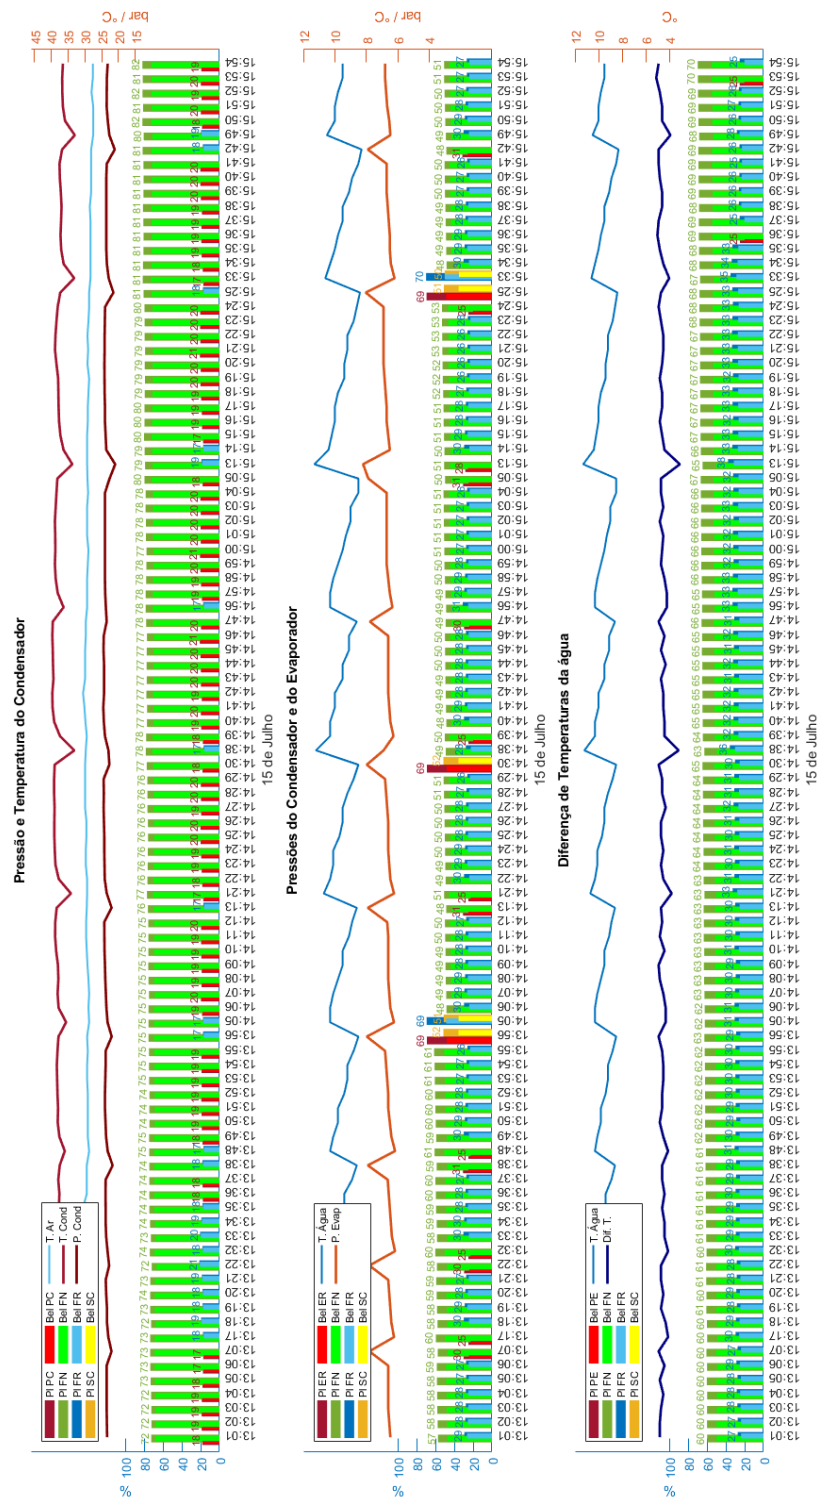


FIGURA C.36: Diagnóstico de falha de dia 15 de julho (2)




FIGURA C.37: Diagnóstico de falha de dia 15 de julho (3)

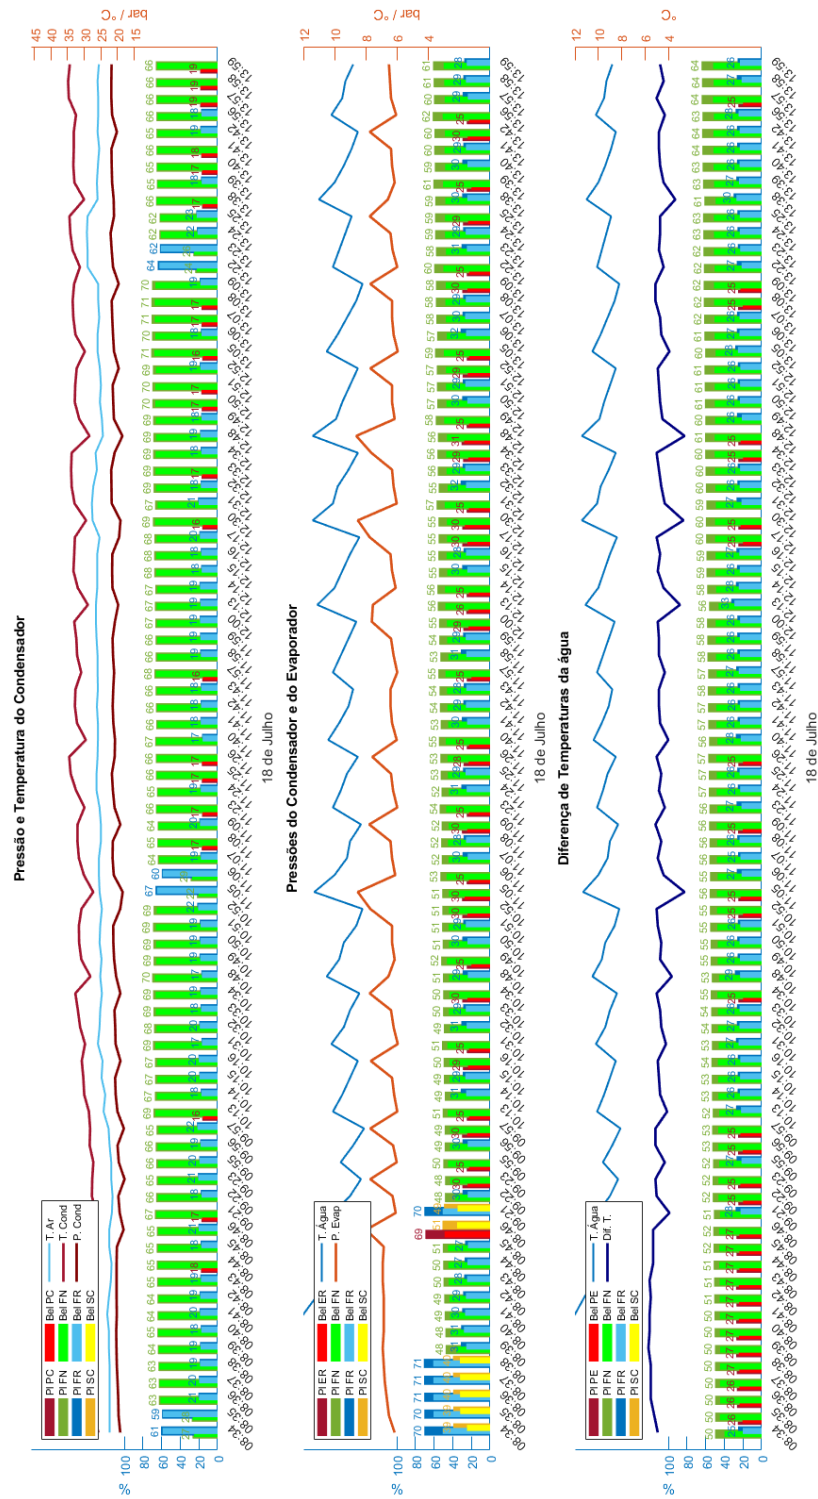


FIGURA C.38: Diagnóstico de falha de dia 18 de julho (1)

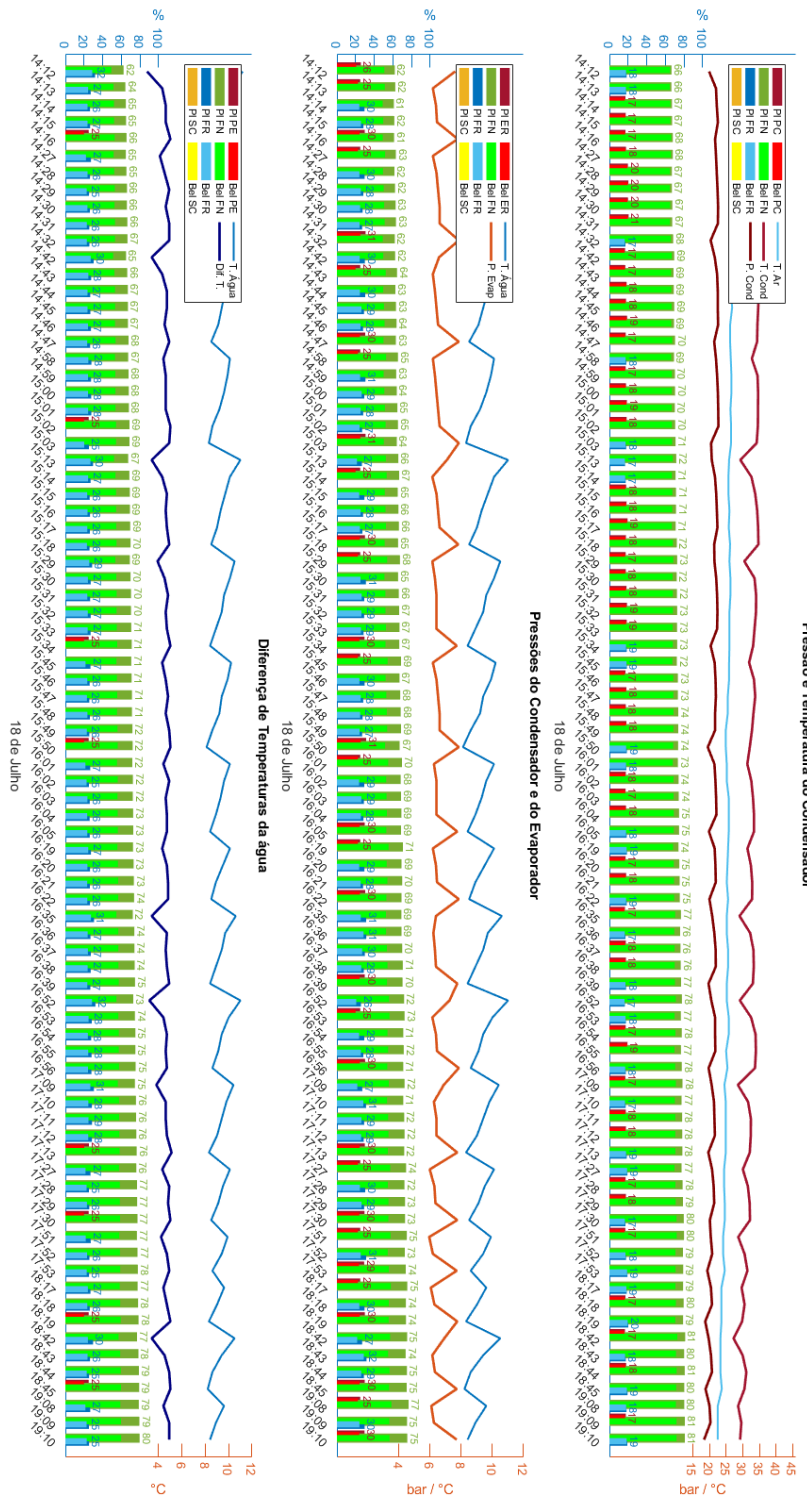


FIGURA C.39: Diagnóstico de falha de dia 18 de julho (2)

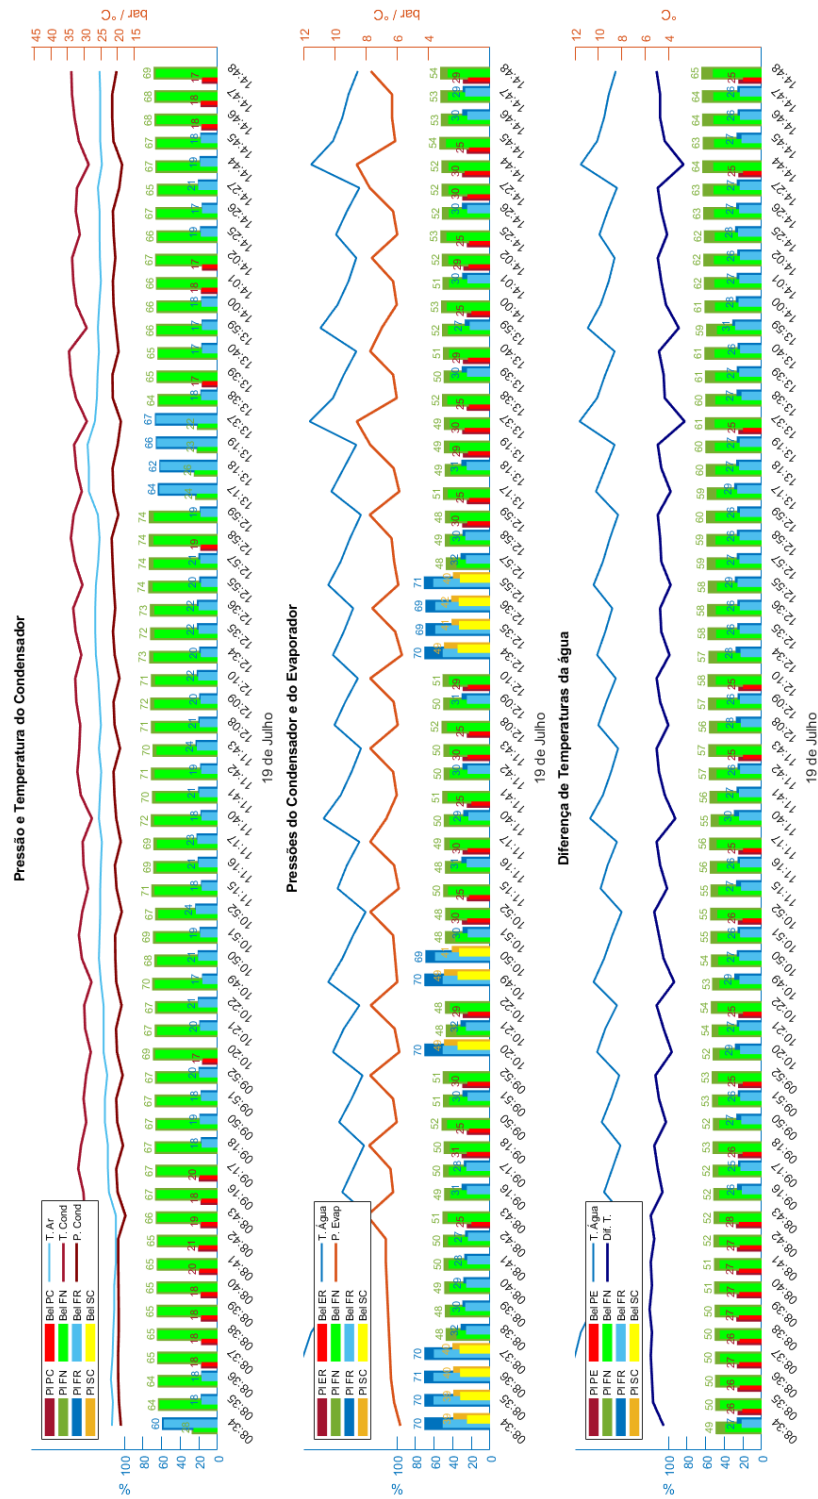


FIGURA C.40: Diagnóstico de falha de dia 19 de julho (1)

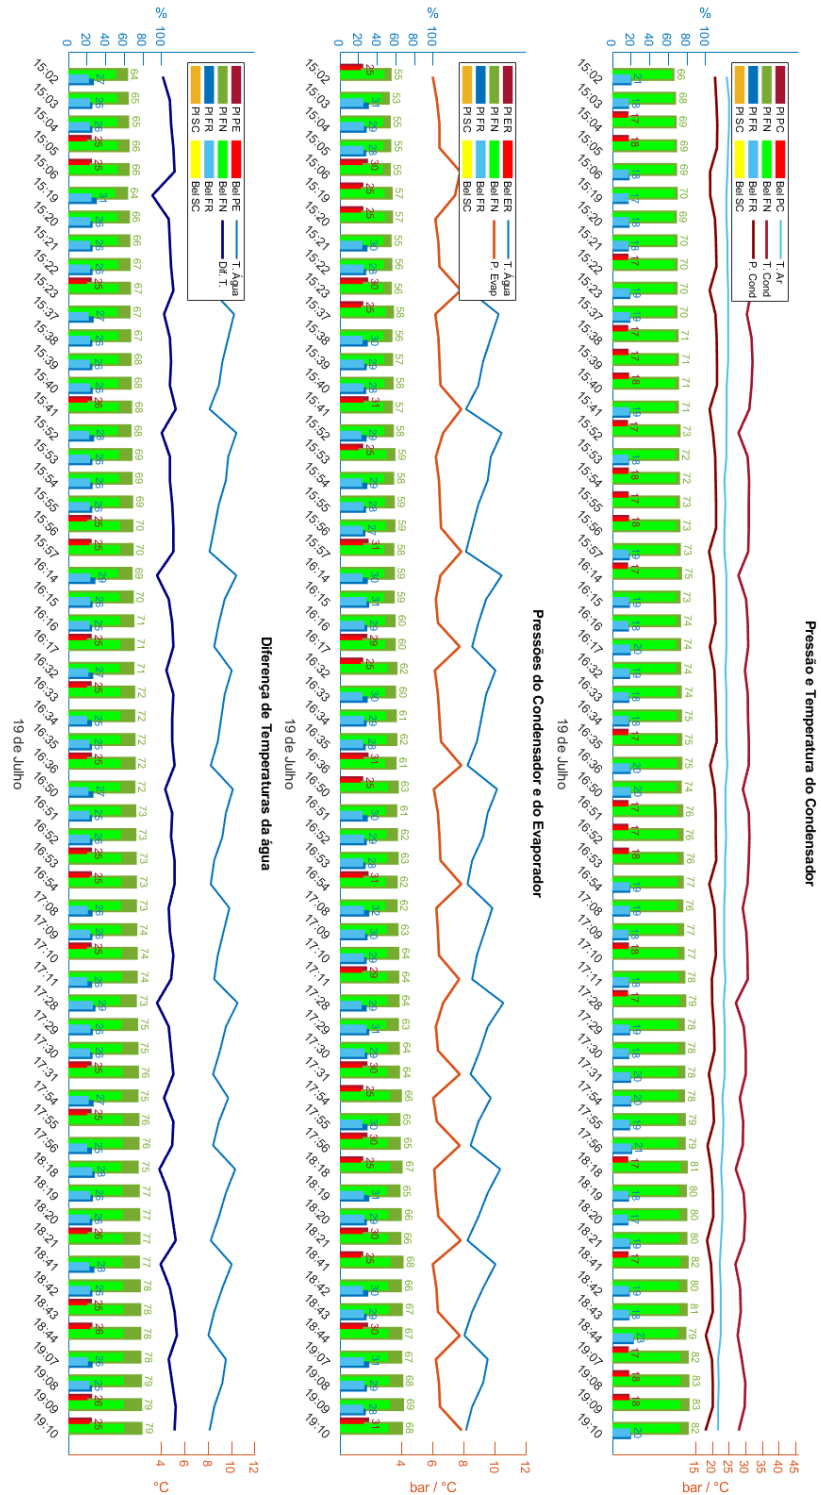


FIGURA C.41: Diagnóstico de falha de dia 19 de julho (2)

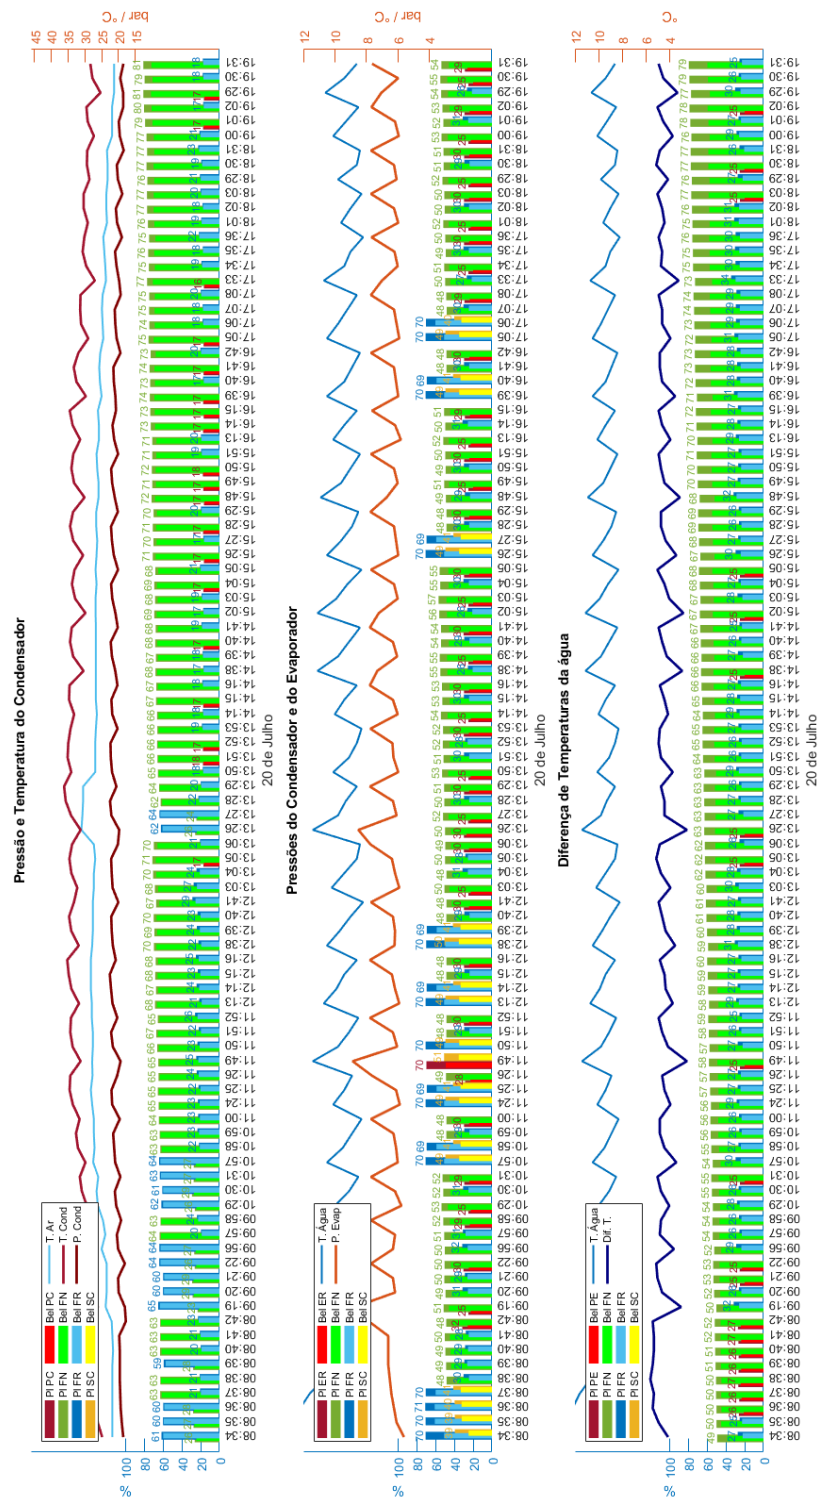


FIGURA C.42: Diagnóstico de falha de dia 20 de julho

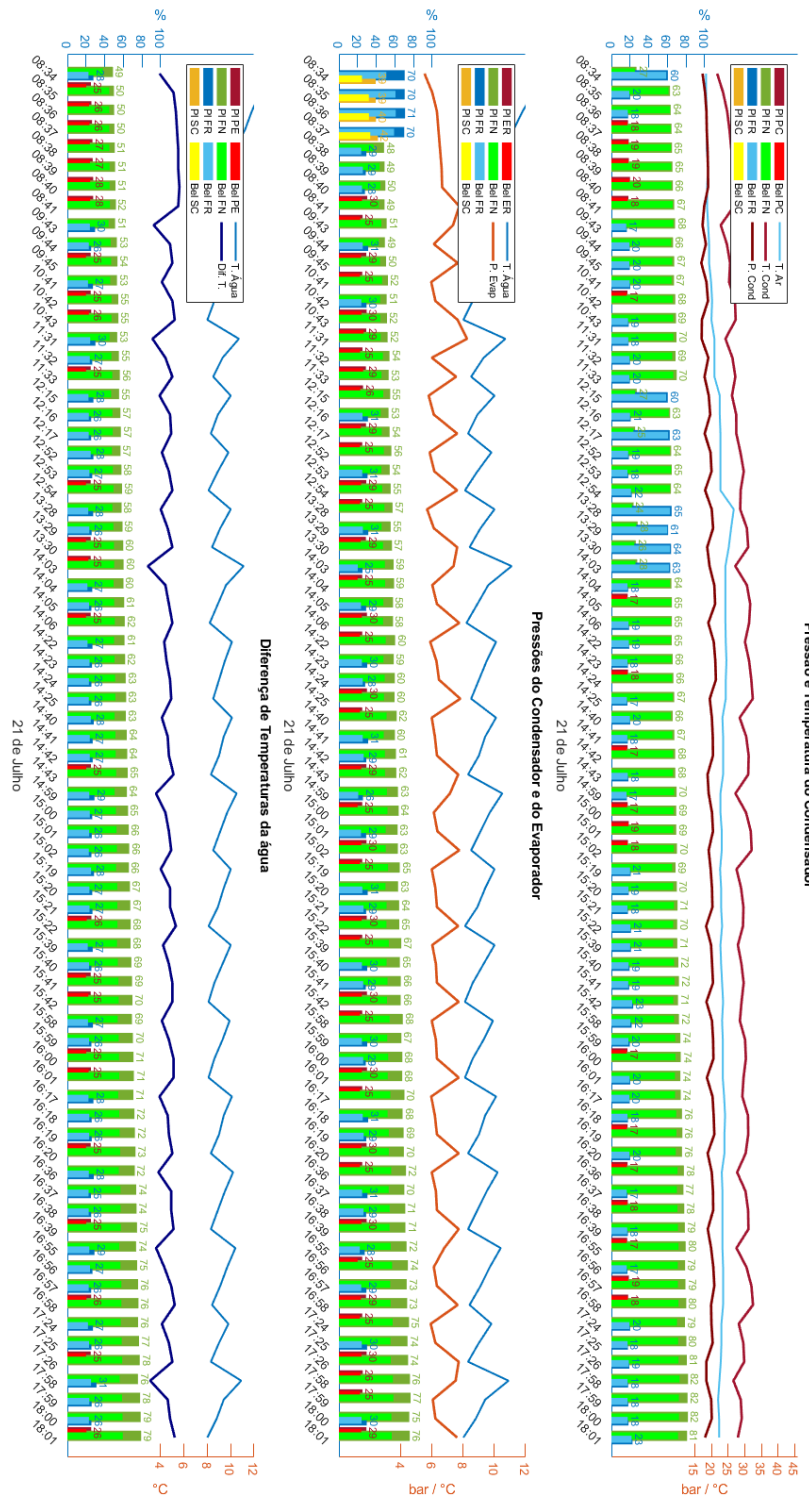


FIGURA C.43: Diagnóstico de falha de dia 21 de julho

Apêndice D - Programa de detecção e de diagnóstico de falhas

```
1
2 %% INICIALIZATION
3 prompt0 = "Portugues (1), English (2)? ";
4 language = input(prompt0);
5
6 if language == 2
7     prompt1 = "Pick the month (06/07): ";
8     month = input(prompt1, "s");
9
10    if strcmp(month, '06')
11        prompt2 = "Pick the day (24/27/28/29/30): ";
12        month2='June';
13    elseif strcmp(month, '07')
14        prompt2 = "Pick the day
15(01/04/05/06/07/08/11/12/13/14/15/18/19/20/21): ";
16        month2='July';
17    end
18
19    day = input(prompt2, "s");
20
21    if strcmp(day, '01')
22        s4='st';
23    elseif strcmp(day, '02')
24        s4='nd';
25    elseif strcmp(day, '03')
26        s4='rd';
27    else
28        s4='th';
29    end
30    stringdate=month2+" "+day+s4;
31 else
32    prompt1 = "Escolher o mes (06/07): ";
33    month = input(prompt1, "s");
34
35    if strcmp(month, '06')
36        prompt2 = "Escolher o dia (24/27/28/29/30): ";
37        month2='Junho';
38    elseif strcmp(month, '07')
39        prompt2 = "Escolher o dia
(01/04/05/06/07/08/11/12/13/14/15/18/19/20/21): ";
        month2='Julho';
```

```

40     end
41
42     day = input(prompt2, "s");
43     stringdate=day+" de "+month2;
44 end
45
46 s1='AERNET_';
47 s2='_';
48 s3='.xlsx';
49 filename=strcat(s1,month,s2,day,s3);
50
51 SfailPC = 0;
52 EfailPC = 0;
53 SfailPE = 0;
54 EfailPE = 0;
55 m1PC = 0;
56 m2PC = 0;
57 m1PE = 0;
58 m2PE = 0;
59
60 if strcmp(month,'06') && strcmp(day,'24')
61     EfailPE = 50+1;
62     m1PE=1;
63     m2PE=EfailPE-1;
64 elseif strcmp(month,'06') && strcmp(day,'27')
65     SfailPC = 26+1;
66     m1PC=SfailPC-1;
67     m2PC=1;
68 elseif strcmp(month,'06') && strcmp(day,'28')
69     m1PC=1;
70     m2PC=1;
71 elseif strcmp(month,'06') && strcmp(day,'29')
72     EfailPC = 80+1;
73     m1PC=1;
74     m2PC=EfailPC-1;
75 elseif strcmp(month,'07') && strcmp(day,'07')
76     SfailPE = 51+1;
77     EfailPE = 143;
78     SfailPC = 258;
79     EfailPC = 307;
80     m1PE=SfailPE-1;
81     m2PE=EfailPE;
82     m1PC=SfailPC;
83     m2PC=EfailPC;
84 end

```

```

85
86 %% DATA AQUISITION
87
88 T = readtable(filename, "ReadVariableNames", false);
89
90 %% DATA PRE-PROCESSING
91
92 % Parameter Selection
93 T = T(:, [1 2 3 4 6 7 8 20 24 31 114]);
94 T.Properties.VariableNames = ["Hora", "T. Agua In", "T. Agua Out", "T.
    Cond", "T. Ar", "P. Cond", "P. Evap", "SetPoint", "Compressor", "Frio", "
    On/Off"];
95
96 % Moving Average of n Values
97 n = 3;
98 T(:, "T. Cond")=array2table(movmean(table2array(T(:, "T. Cond")),n));
99 T(:, "P. Cond")=array2table(movmean(table2array(T(:, "P. Cond")),n));
100 T(:, "P. Evap")=array2table(movmean(table2array(T(:, "P. Evap")),n));
101
102 % System Condition Check
103 T = Filter(T);
104 Hora = T("Hora");
105 S = length(Hora);
106
107 %% DATA PROCESSING
108
109 % Set Variables
110 diff_Cond = 10;
111 diff_Evap = -10;
112 var_P_Cond = 5;
113 var_P_Evap = 5;
114 corr_T_Cond = 2;
115
116 % Value Calculation
117 T("T. Condensacao")=T(:, "T. Ar"} + diff_Cond;
118 T("Dif. T. Cond")=T(:, "T. Cond"} - T(:, "T. Condensacao"} + corr_T_Cond
    ;
119 T("T. Evaporacao")=T(:, "T. Agua Out"} + diff_Evap;
120 T("Dif. T.")=T(:, "T. Agua In"} - T(:, "T. Agua Out"});
121
122 [T("P. Cond - P1"), T("P. Cond - P2"), T("P. Cond - P3"), T("P. Cond -
    P4"), T("P. Cond - P5")] = CalcLimits(T(:, "T. Condensacao"},
    var_P_Cond);

```

```

123 [T.( "P. Evap - P1" ),T.( "P. Evap - P2" ),T.( "P. Evap - P3" ),T.( "P. Evap -
      P4" ),T.( "P. Evap - P5" )]=CalcLimits(T{:}, "T. Evaporacao" },
      var_P_Evap);
124
125 %% FUZZY INFERENCE SYSTEM
126
127 n_cond = 4;
128 X = zeros(S,n_cond);
129
130 % Define Condition
131 for i=1:size(T,1)
132     X(i,1)=FuzzyFunction(T{i, "P. Cond" },T{i, "P. Cond - P1" },T{i, "P.
      Cond - P2" },T{i, "P. Cond - P3" },T{i, "P. Cond - P4" },T{i, "P. Cond -
      P5" });
133     X(i,2)=FuzzyFunction(T{i, "Dif. T. Cond" },-6,-3,0,3,6);
134     X(i,3)=FuzzyFunction(T{i, "P. Evap" },T{i, "P. Evap - P1" },T{i, "P.
      Evap - P2" },T{i, "P. Evap - P3" },T{i, "P. Evap - P4" },T{i, "P. Evap -
      P5" });
135     X(i,4)=FuzzyFunction(T{i, "Dif. T. " },2,3,5,7,8);
136 end
137
138 X = array2table(X);
139 X.Properties.VariableNames = ["P. Cond", "T. Cond", "P. Evap", "Dif. T. "];
140
141 % Eliminate Outliers
142 X = DelOutliers(X,S);
143
144 E = array2table(zeros(S,n_cond));
145 E.Properties.VariableNames = ["P. Cond", "T. Cond", "P. Evap", "Dif. T. "];
146
147 % Check Condition
148 E = CheckState(E,X.( "P. Cond" ),-0.05,0.05,1);
149 E = CheckState(E,X.( "T. Cond" ),-0.05,0.05,2);
150 E = CheckState(E,X.( "P. Evap" ),-0.05,0.05,3);
151 E = CheckState(E,X.( "Dif. T. " ),-0.05,0.05,4);
152
153 %% DEMPSTER-SHAFER ENGINE
154
155 A=struct;
156
157 %Import Structs
158 M=struct;
159 for i=1:S
160     M(i).struct = CreatingStruct(X{i, "P. Cond" },X{i, "T. Cond" },X{i, "P.
      Evap" },X{i, "Dif. T. " });

```

```

161 end
162
163 % Select Structs
164 for i=1:S
165     A1(i)=M(i).struct(E{i,"P. Cond"});
166     A2(i)=M(i).struct(E{i,"T. Cond"});
167     B(i)=M(i).struct(E{i,"P. Evap"});
168     C(i)=M(i).struct(E{i,"Dif. T."});
169 end
170
171 E("Hora")=T("Hora");
172 E=E(:,["Hora","P. Cond","T. Cond","P. Evap","Dif. T."]);
173 E = TableConditions(E);
174
175 % Normalization
176 for i=1:S
177     A1(i).set = Normalize(A1(i).set);
178     A2(i).set = Normalize(A2(i).set);
179     B(i).set = Normalize(B(i).set);
180     C(i).set = Normalize(C(i).set);
181 end
182
183 % Combine Structs
184 for i=1:S
185     A(i).set = Combine2Structs(A1(i).set,A2(i).set);
186     A(i).set = Normalize(A(i).set);
187
188 end
189
190 % Order Struct
191 for i=1:S
192     A(i).set = OrderStruct(A(i).set);
193     B(i).set = OrderStruct(B(i).set);
194     C(i).set = OrderStruct(C(i).set);
195 end
196
197 % Calculate Belief and Plasuibility
198 for i=1:S
199     A(i).set = SetBel_Pl(A(i).set);
200     B(i).set = SetBel_Pl(B(i).set);
201     C(i).set = SetBel_Pl(C(i).set);
202 end
203
204 % Filter Struct
205 for i=1:S

```

```

206     A(i).set = FilterStruct(A(i).set);
207     B(i).set = FilterStruct(B(i).set);
208     C(i).set = FilterStruct(C(i).set);
209 end
210
211 % Propagation Algoritm
212 k11=0;
213 k21=0;
214 k31=0;
215 k12=0;
216 k22=0;
217 k32=0;
218 for i=2:S
219     [A(i).set ,k11 ,k12] = Propagation(A(i).set ,A(i-1).set ,k11 ,k12 ,S);
220     [B(i).set ,k21 ,k22] = Propagation(B(i).set ,B(i-1).set ,k21 ,k22 ,S);
221     [C(i).set ,k31 ,k32] = Propagation(C(i).set ,C(i-1).set ,k31 ,k32 ,S);
222 end
223
224 %% RESULTS
225
226 Eval_A = Evaluation(A,m1PC,m2PC, "PC");
227 Eval_B = Evaluation(B,0,0, "PE");
228 Eval_C = Evaluation(C,m1PE,m2PE, "PE");
229
230 if language == 2
231     title1 = 'Condenser Pressure and Temperature';
232     title2 = 'Evaporator Pressure';
233     title3 = 'Water Temperature Difference';
234 else
235     title1 = 'Pressao e Temperatura do Condensador';
236     title2 = 'Pressao do Evaporador';
237     title3 = 'Diferenca de Temperaturas da agua';
238 end
239
240 figure (1)
241 ploteval = PlotEval(Eval_A,Eval_B,Eval_C,stringdate ,title1 ,title2 ,
242     title3 ,language);
243
244 if S > 500
245     L = ceil(S/6);
246     Hora1=Hora(1:L);
247     Hora2=Hora(L+1:2*L);
248     Hora3=Hora(2*L+1:3*L);
249     Hora4=Hora(3*L+1:4*L);

```

```

250     Hora5=Hora(4*L+1:5*L);
251     Hora6=Hora(5*L+1:S);
252
253     T1=T(1:L,:);
254     T2=T(L+1:2*L,:);
255     T3=T(2*L+1:3*L,:);
256     T4=T(3*L+1:4*L,:);
257     T5=T(4*L+1:5*L,:);
258     T6=T(5*L+1:S,:);
259
260     A1=A(1:L);
261     A2=A(L+1:2*L);
262     A3=A(2*L+1:3*L);
263     A4=A(3*L+1:4*L);
264     A5=A(4*L+1:5*L);
265     A6=A(5*L+1:S);
266
267     B1=B(1:L);
268     B2=B(L+1:2*L);
269     B3=B(2*L+1:3*L);
270     B4=B(3*L+1:4*L);
271     B5=B(4*L+1:5*L);
272     B6=B(5*L+1:S);
273
274     C1=C(1:L);
275     C2=C(L+1:2*L);
276     C3=C(2*L+1:3*L);
277     C4=C(3*L+1:4*L);
278     C5=C(4*L+1:5*L);
279     C6=C(5*L+1:S);
280
281     figure (2)
282     subplot (3,1,1)
283     [b111,b112] = PlotBarGraph(T1,A1,Hora1,"PC",stringdate,title1,
SfailPC,EfailPC,1,L,language);
284     subplot (3,1,2)
285     [b121,b122] = PlotBarGraph(T1,B1,Hora1,"ER",stringdate,title2
,0,0,1,L,language);
286     subplot (3,1,3)
287     [b131,b132] = PlotBarGraph(T1,C1,Hora1,"PE",stringdate,title3,
SfailPE,EfailPE,1,L,language);
288
289     figure (3)
290     subplot (3,1,1)

```

```

291 [b211 , b212] = PlotBarGraph(T2,A2,Hora2, "PC", stringdate , title1 ,
SfailPC , EfailPC , L, 2*L, language );
292 subplot (3,1,2)
293 [b221 , b222] = PlotBarGraph(T2,B2,Hora2, "ER", stringdate , title2 , 0,0,L
, 2*L, language );
294 subplot (3,1,3)
295 [b231 , b232] = PlotBarGraph(T2,C2,Hora2, "PE", stringdate , title3 ,
SfailPE , EfailPE , L, 2*L, language );
296
297 figure (4)
298 subplot (3,1,1)
299 [b311 , b312] = PlotBarGraph(T3,A3,Hora3, "PC", stringdate , title1 ,
SfailPC , EfailPC , 2*L, 3*L, language );
300 subplot (3,1,2)
301 [b321 , b322] = PlotBarGraph(T3,B3,Hora3, "ER", stringdate , title2 , 0,0,2
*L, 3*L, language );
302 subplot (3,1,3)
303 [b331 , b332] = PlotBarGraph(T3,C3,Hora3, "PE", stringdate , title3 ,
SfailPE , EfailPE , 2*L, 3*L, language );
304
305 figure (5)
306 subplot (3,1,1)
307 [b411 , b412] = PlotBarGraph(T4,A4,Hora4, "PC", stringdate , title1 ,
SfailPC , EfailPC , 3*L, 4*L, language );
308 subplot (3,1,2)
309 [b421 , b422] = PlotBarGraph(T4,B4,Hora4, "ER", stringdate , title2 , 0,0,3
*L, 4*L, language );
310 subplot (3,1,3)
311 [b431 , b432] = PlotBarGraph(T4,C4,Hora4, "PE", stringdate , title3 ,
SfailPE , EfailPE , 3*L, 4*L, language );
312
313 figure (6)
314 subplot (3,1,1)
315 [b511 , b512] = PlotBarGraph(T5,A5,Hora5, "PC", stringdate , title1 ,
SfailPC , EfailPC , 4*L, 5*L, language );
316 subplot (3,1,2)
317 [b521 , b522] = PlotBarGraph(T5,B5,Hora5, "ER", stringdate , title2 , 0,0,4
*L, 5*L, language );
318 subplot (3,1,3)
319 [b531 , b532] = PlotBarGraph(T5,C5,Hora5, "PE", stringdate , title3 ,
SfailPE , EfailPE , 4*L, 5*L, language );
320
321 figure (7)
322 subplot (3,1,1)

```

```

323     [b611 , b612] = PlotBarGraph(T6,A6,Hora6 , "PC" , stringdate , title1 ,
SfailPC , EfailPC , 5 *L , S , language ) ;
324     subplot ( 3 , 1 , 2)
325     [b621 , b622] = PlotBarGraph(T6,B6,Hora6 , "ER" , stringdate , title2 , 0 , 0 , 5
*L , S , language ) ;
326     subplot ( 3 , 1 , 3)
327     [b631 , b632] = PlotBarGraph(T6,C6,Hora6 , "PE" , stringdate , title3 ,
SfailPE , EfailPE , 5 *L , S , language ) ;
328
329 elseif S > 400
330
331     L = ceil (S/5) ;
332     Hora1=Hora (1:L) ;
333     Hora2=Hora(L+1:2*L) ;
334     Hora3=Hora(2*L+1:3*L) ;
335     Hora4=Hora(3*L+1:4*L) ;
336     Hora5=Hora(4*L+1:S) ;
337
338     T1=T(1:L , : ) ;
339     T2=T(L+1:2*L , : ) ;
340     T3=T(2*L+1:3*L , : ) ;
341     T4=T(3*L+1:4*L , : ) ;
342     T5=T(4*L+1:S , : ) ;
343
344     A1=A(1:L) ;
345     A2=A(L+1:2*L) ;
346     A3=A(2*L+1:3*L) ;
347     A4=A(3*L+1:4*L) ;
348     A5=A(4*L+1:S) ;
349
350     B1=B(1:L) ;
351     B2=B(L+1:2*L) ;
352     B3=B(2*L+1:3*L) ;
353     B4=B(3*L+1:4*L) ;
354     B5=B(4*L+1:S) ;
355
356     C1=C(1:L) ;
357     C2=C(L+1:2*L) ;
358     C3=C(2*L+1:3*L) ;
359     C4=C(3*L+1:4*L) ;
360     C5=C(4*L+1:S) ;
361
362     figure (2)
363     subplot (3 , 1 , 1)

```

```

364 [b111, b112] = PlotBarGraph(T1, A1, Hora1, "PC", stringdate, title1,
SfailPC, EfailPC, 1, L, language);
365 subplot(3, 1, 2)
366 [b121, b122] = PlotBarGraph(T1, B1, Hora1, "ER", stringdate, title2
, 0, 0, 1, L, language);
367 subplot(3, 1, 3)
368 [b131, b132] = PlotBarGraph(T1, C1, Hora1, "PE", stringdate, title3,
SfailPE, EfailPE, 1, L, language);
369
370 figure(3)
371 subplot(3, 1, 1)
372 [b211, b212] = PlotBarGraph(T2, A2, Hora2, "PC", stringdate, title1,
SfailPC, EfailPC, L, 2*L, language);
373 subplot(3, 1, 2)
374 [b221, b222] = PlotBarGraph(T2, B2, Hora2, "ER", stringdate, title2, 0, 0, L
, 2*L, language);
375 subplot(3, 1, 3)
376 [b231, b232] = PlotBarGraph(T2, C2, Hora2, "PE", stringdate, title3,
SfailPE, EfailPE, L, 2*L, language);
377
378 figure(4)
379 subplot(3, 1, 1)
380 [b311, b312] = PlotBarGraph(T3, A3, Hora3, "PC", stringdate, title1,
SfailPC, EfailPC, 2*L, 3*L, language);
381 subplot(3, 1, 2)
382 [b321, b322] = PlotBarGraph(T3, B3, Hora3, "ER", stringdate, title2, 0, 0, 2
*L, 3*L, language);
383 subplot(3, 1, 3)
384 [b331, b332] = PlotBarGraph(T3, C3, Hora3, "PE", stringdate, title3,
SfailPE, EfailPE, 2*L, 3*L, language);
385
386 figure(5)
387 subplot(3, 1, 1)
388 [b411, b412] = PlotBarGraph(T4, A4, Hora4, "PC", stringdate, title1,
SfailPC, EfailPC, 3*L, 4*L, language);
389 subplot(3, 1, 2)
390 [b421, b422] = PlotBarGraph(T4, B4, Hora4, "ER", stringdate, title2, 0, 0, 3
*L, 4*L, language);
391 subplot(3, 1, 3)
392 [b431, b432] = PlotBarGraph(T4, C4, Hora4, "PE", stringdate, title3,
SfailPE, EfailPE, 3*L, 4*L, language);
393
394 figure(6)
395 subplot(3, 1, 1)

```

```

396     [b511, b512] = PlotBarGraph(T5, A5, Hora5, "PC", stringdate, title1,
SfailPC, EfailPC, 4*L, S, language);
397     subplot(3, 1, 2)
398     [b521, b522] = PlotBarGraph(T5, B5, Hora5, "ER", stringdate, title2, 0, 0, 4
*L, S, language);
399     subplot(3, 1, 3)
400     [b531, b532] = PlotBarGraph(T5, C5, Hora5, "PE", stringdate, title3,
SfailPE, EfailPE, 4*L, S, language);
401
402 elseif S > 300
403
404     L = ceil(S/4);
405     Hora1=Hora(1:L);
406     Hora2=Hora(L+1:2*L);
407     Hora3=Hora(2*L+1:3*L);
408     Hora4=Hora(3*L+1:S);
409
410     T1=T(1:L,:);
411     T2=T(L+1:2*L,:);
412     T3=T(2*L+1:3*L,:);
413     T4=T(3*L+1:S,:);
414
415     A1=A(1:L);
416     A2=A(L+1:2*L);
417     A3=A(2*L+1:3*L);
418     A4=A(3*L+1:S);
419
420     B1=B(1:L);
421     B2=B(L+1:2*L);
422     B3=B(2*L+1:3*L);
423     B4=B(3*L+1:S);
424
425     C1=C(1:L);
426     C2=C(L+1:2*L);
427     C3=C(2*L+1:3*L);
428     C4=C(3*L+1:S);
429
430     figure (2)
431     subplot(3, 1, 1)
432     [b111, b112] = PlotBarGraph(T1, A1, Hora1, "PC", stringdate, title1,
SfailPC, EfailPC, 1, L, language);
433     subplot(3, 1, 2)
434     [b121, b122] = PlotBarGraph(T1, B1, Hora1, "ER", stringdate, title2
, 0, 0, 1, L, language);
435     subplot(3, 1, 3)

```

```

436     [b131, b132] = PlotBarGraph(T1, C1, Hora1, "PE", stringdate, title3,
SfailPE, EfailPE, 1, L, language);
437
438     figure (3)
439     subplot (3, 1, 1)
440     [b211, b212] = PlotBarGraph(T2, A2, Hora2, "PC", stringdate, title1,
SfailPC, EfailPC, L, 2*L, language);
441     subplot (3, 1, 2)
442     [b221, b222] = PlotBarGraph(T2, B2, Hora2, "ER", stringdate, title2, 0, 0, L
, 2*L, language);
443     subplot (3, 1, 3)
444     [b231, b232] = PlotBarGraph(T2, C2, Hora2, "PE", stringdate, title3,
SfailPE, EfailPE, L, 2*L, language);
445
446     figure (4)
447     subplot (3, 1, 1)
448     [b311, b312] = PlotBarGraph(T3, A3, Hora3, "PC", stringdate, title1,
SfailPC, EfailPC, 2*L, 3*L, language);
449     subplot (3, 1, 2)
450     [b321, b322] = PlotBarGraph(T3, B3, Hora3, "ER", stringdate, title2, 0, 0, 2
*L, 3*L, language);
451     subplot (3, 1, 3)
452     [b331, b332] = PlotBarGraph(T3, C3, Hora3, "PE", stringdate, title3,
SfailPE, EfailPE, 2*L, 3*L, language);
453
454     figure (5)
455     subplot (3, 1, 1)
456     [b411, b412] = PlotBarGraph(T4, A4, Hora4, "PC", stringdate, title1,
SfailPC, EfailPC, 3*L, S, language);
457     subplot (3, 1, 2)
458     [b421, b422] = PlotBarGraph(T4, B4, Hora4, "ER", stringdate, title2, 0, 0, 3
*L, S, language);
459     subplot (3, 1, 3)
460     [b431, b432] = PlotBarGraph(T4, C4, Hora4, "PE", stringdate, title3,
SfailPE, EfailPE, 3*L, S, language);
461
462     elseif S > 200
463
464         L = ceil(S/3);
465         Hora1=Hora(1:L);
466         Hora2=Hora(L+1:2*L);
467         Hora3=Hora(2*L+1:S);
468
469         T1=T(1:L, :);
470         T2=T(L+1:2*L, :);

```

```

471     T3=T(2*L+1:S, :);
472
473     A1=A(1:L);
474     A2=A(L+1:2*L);
475     A3=A(2*L+1:S);
476
477     B1=B(1:L);
478     B2=B(L+1:2*L);
479     B3=B(2*L+1:S);
480
481     C1=C(1:L);
482     C2=C(L+1:2*L);
483     C3=C(2*L+1:S);
484
485     figure (2)
486     subplot (3,1,1)
487     [b111, b112] = PlotBarGraph(T1,A1,Hora1, "PC", stringdate, title1,
SfailPC, EfailPC, 1, L, language);
488     subplot (3,1,2)
489     [b121, b122] = PlotBarGraph(T1,B1,Hora1, "ER", stringdate, title2
,0,0,1, L, language);
490     subplot (3,1,3)
491     [b131, b132] = PlotBarGraph(T1,C1,Hora1, "PE", stringdate, title3,
SfailPE, EfailPE, 1, L, language);
492
493     figure (3)
494     subplot (3,1,1)
495     [b211, b212] = PlotBarGraph(T2,A2,Hora2, "PC", stringdate, title1,
SfailPC, EfailPC, L, 2*L, language);
496     subplot (3,1,2)
497     [b221, b222] = PlotBarGraph(T2,B2,Hora2, "ER", stringdate, title2, 0,0,L
,2*L, language);
498     subplot (3,1,3)
499     [b231, b232] = PlotBarGraph(T2,C2,Hora2, "PE", stringdate, title3,
SfailPE, EfailPE, L, 2*L, language);
500
501     figure (4)
502     subplot (3,1,1)
503     [b311, b312] = PlotBarGraph(T3,A3,Hora3, "PC", stringdate, title1,
SfailPC, EfailPC, 2*L, S, language);
504     subplot (3,1,2)
505     [b321, b322] = PlotBarGraph(T3,B3,Hora3, "ER", stringdate, title2, 0,0,2
*L, S, language);
506     subplot (3,1,3)

```

```

507     [b331,b332] = PlotBarGraph(T3,C3,Hora3,"PE",stringdate,title3,
SfailPE,EfailPE,2*L,S,language);
508
509 elseif S > 100
510
511     L = ceil(S/2);
512     Hora1=Hora(1:L);
513     Hora2=Hora(L+1:S);
514
515     T1=T(1:L,:);
516     T2=T(L+1:S,:);
517
518     A1=A(1:L);
519     A2=A(L+1:S);
520
521     B1=B(1:L);
522     B2=B(L+1:S);
523
524     C1=C(1:L);
525     C2=C(L+1:S);
526
527     figure (2)
528     subplot (3,1,1)
529     [b111,b112] = PlotBarGraph(T1,A1,Hora1,"PC",stringdate,title1,
SfailPC,EfailPC,1,L,language);
530     subplot (3,1,2)
531     [b121,b122] = PlotBarGraph(T1,B1,Hora1,"ER",stringdate,title2
,0,0,1,L,language);
532     subplot (3,1,3)
533     [b131,b132] = PlotBarGraph(T1,C1,Hora1,"PE",stringdate,title3,
SfailPE,EfailPE,1,L,language);
534
535     figure (3)
536     subplot (3,1,1)
537     [b211,b212] = PlotBarGraph(T2,A2,Hora2,"PC",stringdate,title1,
SfailPC,EfailPC,L,S,language);
538     subplot (3,1,2)
539     [b221,b222] = PlotBarGraph(T2,B2,Hora2,"ER",stringdate,title2,0,0,L
,S,language);
540     subplot (3,1,3)
541     [b231,b232] = PlotBarGraph(T2,C2,Hora2,"PE",stringdate,title3,
SfailPE,EfailPE,L,S,language);
542
543 else
544

```

```
545 figure (3)
546 subplot (3,1,1)
547 [b11,b12] = PlotBarGraph(T,A,Hora, "PC",stringdate ,title1 ,SfailPC ,
EfailPC ,1 ,S, language );
548 subplot (3,1,2)
549 [b21,b22] = PlotBarGraph(T,B,Hora, "ER",stringdate ,title2 ,0,0,1 ,S,
language );
550 subplot (3,1,3)
551 [b31,b32] = PlotBarGraph(T,C,Hora, "PE",stringdate ,title3 ,SfailPE ,
EfailPE ,1 ,S, language );
552
553 end
```

```
1
2 function T = Filter (T)
3
4     T = T(T.( "On/Off" )==1,:); % Instalacao Desligada
5     T(:, "On/Off" ) = [];
6     T = T(T.( "SetPoint" )==T.( "Frio" ),:); % Instalacao em Modo de
Aquecimento
7     T(:, [ "SetPoint" , "Frio" ]) = [];
8
9     for i=size (T,1):-1:2
10        if T{i, "Compressor" }==0 % Compressor OFF
11            T(i,:) = [];
12        elseif T{i, "Compressor" }==100 && T{i-1, "Compressor" }==0 %
Arranque do Compressor
13            T(i,:) = [];
14        end
15    end
16    T(1,:) = [];
17    T(:, "Compressor" ) = [];
18
19 end
```

```
1
2 function [P1,P2,P3,P4,P5] = CalcLimits(a, var)
3
4     % Calcula os limites inferior e superior com base numa variancia de
5     % temperatura e atraves da interpolacao de uma funcao polinomial de
6     % 2 grau
```

```

7      % Valores de pressao relativa para o [R410a]
8      P=[6.99 8.35 9.87 11.57 13.46 15.56 17.88 20.43 23.24 26.32 29.70
9      33.39 37.41];
10
11     % Temperatura
12     T=0:5:60;
13
14     % Regressao Polinomial de 2 grau
15     p=polyfit(T,P,2);
16
17     % Calculo dos limites
18     P1=polyval(p,a-(var+1));
19     P2=polyval(p,a-(var));
20     P3=polyval(p,a);
21     P4=polyval(p,a+(var));
22     P5=polyval(p,a+(var+1));
23 end

```

```

1
2 function [X] = FuzzyFunction(V,v1,v2,v3,v4,v5)
3
4     fis = mamfis('Name', "FuzzyInferenceSystem");
5
6     fis = addInput(fis,[-20 50], 'Name', "FuzzyInput");
7
8     fis = addMF(fis, "FuzzyInput", "linzmf", [v1 v2], 'Name', "MB");
9     fis = addMF(fis, "FuzzyInput", "trimf", [v1 v2 v3], 'Name', "B");
10    fis = addMF(fis, "FuzzyInput", "trimf", [v2 v3 v4], 'Name', "N");
11    fis = addMF(fis, "FuzzyInput", "trimf", [v3 v4 v5], 'Name', "A");
12    fis = addMF(fis, "FuzzyInput", "linsmf", [v4 v5], 'Name', "MA");
13
14    fis = addOutput(fis, [-0.1 0.1], 'Name', "FuzzyOutput");
15
16    fis = addMF(fis, "FuzzyOutput", "linzmf", [-0.08 -0.06], 'Name', "MB");
17    fis = addMF(fis, "FuzzyOutput", "trapmf", [-0.08 -0.06 -0.04 -0.02], '
18    Name', "B");
19    fis = addMF(fis, "FuzzyOutput", "trapmf", [-0.04 -0.02 0.02 0.04], '
20    Name', "N");
21    fis = addMF(fis, "FuzzyOutput", "trapmf", [0.02 0.04 0.06 0.08], 'Name'
22    , "A");
23    fis = addMF(fis, "FuzzyOutput", "linsmf", [0.06 0.08], 'Name', "MA");
24
25    rule1 = "FuzzyInput==MB => FuzzyOutput==MB";

```

```

23 rule2 = "FuzzyInput==B => FuzzyOutput=B";
24 rule3 = "FuzzyInput==N => FuzzyOutput=N";
25 rule4 = "FuzzyInput==A => FuzzyOutput=A";
26 rule5 = "FuzzyInput==MA => FuzzyOutput=MA";
27 rules = [rule1 rule2 rule3 rule4 rule5];
28
29 fis = addRule(fis , rules);
30
31 X = round( evalfis ( fis ,V) ,3);
32
33 end

```

```

1
2 function X = DelOutliers(X,S)
3
4     for i=1:4
5         for j=2:S-1
6             if abs(X{j , i}) > 0.05 && abs(X{j+1,i}) < 0.05 && abs(X{j-1,i})
7                 < 0.05
8                     X{j , i}=0;
9                     elseif abs(X{j , i}) < 0.05 && X{j+1,i} > 0.05 && X{j-1,i} > 0.05
10                    X{j , i}=0.051;
11                    elseif abs(X{j , i}) < 0.05 && X{j+1,i} < -0.05 && X{j-1,i} < -0.05
12                    X{j , i}=-0.051;
13                end
14            end
15        end
16    end

```

```

1
2 function V = CheckState(V,X,inf_X,sup_X,id)
3
4     % Verifica o estado de um parametro para cada condicao
5     % Altera os valores do vetor conforme
6
7     fault_id=3*id-3;
8     V.(id) = V.(id) + fault_id;
9     V.(id) = V.(id) + (X < sup_X);
10    V.(id) = V.(id) + (X < inf_X);
11    V.(id) = V.(id) + 1;
12 end

```

```

1
2 function mainset = CreatingStruct(x1,x2,x3,x4)
3
4 %% Pressao de Condensacao
5 % Alta
6 mainset(1).set(1).foc="PC";
7 mainset(1).set(1).mass=0.425+x1;
8 mainset(1).set(2).foc="FN";
9 mainset(1).set(2).mass=0.05-abs(x1);
10 mainset(1).set(3).foc="FR";
11 mainset(1).set(3).mass=0.025-x1;
12 mainset(1).set(4).foc="SC";
13 mainset(1).set(4).mass=0.25;
14 mainset(1).set(5).foc=["PC","SC"];
15 mainset(1).set(5).mass=0.1;
16 mainset(1).set(6).foc=["PC","FN"];
17 mainset(1).set(6).mass=0.1;
18 mainset(1).set(7).foc=["FN","SC"];
19 mainset(1).set(7).mass=0.05;
20
21 % Normal
22 mainset(2).set(1).foc="PC";
23 mainset(2).set(1).mass=0.2+x1;
24 mainset(2).set(2).foc="FN";
25 mainset(2).set(2).mass=0.4-abs(x1);
26 mainset(2).set(3).foc="FR";
27 mainset(2).set(3).mass=0.2-x1;
28 mainset(2).set(4).foc=["FN","PC"];
29 mainset(2).set(4).mass=0.05;
30 mainset(2).set(5).foc=["FN","FR"];
31 mainset(2).set(5).mass=0.05;
32 mainset(2).set(6).foc="SC";
33 mainset(2).set(6).mass=0.1;
34
35 % Baixa
36 mainset(3).set(1).foc="PC";
37 mainset(3).set(1).mass=0.025+x1;
38 mainset(3).set(2).foc="FN";
39 mainset(3).set(2).mass=0.05-abs(x1);
40 mainset(3).set(3).foc="FR";
41 mainset(3).set(3).mass=0.425-x1;
42 mainset(3).set(4).foc="SC";
43 mainset(3).set(4).mass=0.25;
44 mainset(3).set(5).foc=["FR","SC"];

```

```

45     mainset(3).set(5).mass=0.1;
46     mainset(3).set(6).foc=["FR", "FN"];
47     mainset(3).set(6).mass=0.1;
48     mainset(3).set(7).foc=["FN", "SC"];
49     mainset(3).set(7).mass=0.05;
50
51     %% Temperatura de Condensacao
52     % Alta
53     mainset(4).set(1).foc="PC";
54     mainset(4).set(1).mass=0.425+x2;
55     mainset(4).set(2).foc="FN";
56     mainset(4).set(2).mass=0.05-abs(x2);
57     mainset(4).set(3).foc="FR";
58     mainset(4).set(3).mass=0.025-x2;
59     mainset(4).set(4).foc="SC";
60     mainset(4).set(4).mass=0.25;
61     mainset(4).set(5).foc=["PC", "SC"];
62     mainset(4).set(5).mass=0.1;
63     mainset(4).set(6).foc=["PC", "FN"];
64     mainset(4).set(6).mass=0.1;
65     mainset(4).set(7).foc=["FN", "SC"];
66     mainset(4).set(7).mass=0.05;
67
68     % Normal
69     mainset(5).set(1).foc="PC";
70     mainset(5).set(1).mass=0.2+x2;
71     mainset(5).set(2).foc="FN";
72     mainset(5).set(2).mass=0.4-abs(x2);
73     mainset(5).set(3).foc="FR";
74     mainset(5).set(3).mass=0.2-x2;
75     mainset(5).set(4).foc=["FN", "PC"];
76     mainset(5).set(4).mass=0.05;
77     mainset(5).set(5).foc=["FN", "FR"];
78     mainset(5).set(5).mass=0.05;
79     mainset(5).set(6).foc="SC";
80     mainset(5).set(6).mass=0.1;
81
82     % Baixa
83     mainset(6).set(1).foc="PC";
84     mainset(6).set(1).mass=0.025+x2;
85     mainset(6).set(2).foc="FN";
86     mainset(6).set(2).mass=0.05-abs(x2);
87     mainset(6).set(3).foc="FR";
88     mainset(6).set(3).mass=0.425-x2;
89     mainset(6).set(4).foc="SC";

```

```

90     mainset(6).set(4).mass=0.25;
91     mainset(6).set(5).foc=["FR","SC"];
92     mainset(6).set(5).mass=0.1;
93     mainset(6).set(6).foc=["FR","FN"];
94     mainset(6).set(6).mass=0.1;
95     mainset(6).set(7).foc=["FN","SC"];
96     mainset(6).set(7).mass=0.05;
97
98     %% Pressao de Evaporacao
99     % Alta
100    mainset(7).set(1).foc="ER";
101    mainset(7).set(1).mass=0.425+x3;
102    mainset(7).set(2).foc="FN";
103    mainset(7).set(2).mass=0.05-abs(x3);
104    mainset(7).set(3).foc="FR";
105    mainset(7).set(3).mass=0.025-x3;
106    mainset(7).set(4).foc="SC";
107    mainset(7).set(4).mass=0.25;
108    mainset(7).set(5).foc=["ER","SC"];
109    mainset(7).set(5).mass=0.1;
110    mainset(7).set(6).foc=["ER","FN"];
111    mainset(7).set(6).mass=0.1;
112    mainset(7).set(7).foc=["FN","SC"];
113    mainset(7).set(7).mass=0.05;
114
115    % Normal
116    mainset(8).set(1).foc="ER";
117    mainset(8).set(1).mass=0.2+x3;
118    mainset(8).set(2).foc="FN";
119    mainset(8).set(2).mass=0.4-abs(x3);
120    mainset(8).set(3).foc="FR";
121    mainset(8).set(3).mass=0.2-x3;
122    mainset(8).set(4).foc=["FN","ER"];
123    mainset(8).set(4).mass=0.05;
124    mainset(8).set(5).foc=["FN","FR"];
125    mainset(8).set(5).mass=0.05;
126    mainset(8).set(6).foc="SC";
127    mainset(8).set(6).mass=0.1;
128
129    % Baixa
130    mainset(9).set(1).foc="ER";
131    mainset(9).set(1).mass=0.025+x3;
132    mainset(9).set(2).foc="FN";
133    mainset(9).set(2).mass=0.05-abs(x3);
134    mainset(9).set(3).foc="FR";

```

```

135     mainset(9).set(3).mass=0.425-x3;
136     mainset(9).set(4).foc="SC";
137     mainset(9).set(4).mass=0.25;
138     mainset(9).set(5).foc=["FR","SC"];
139     mainset(9).set(5).mass=0.1;
140     mainset(9).set(6).foc=["FR","FN"];
141     mainset(9).set(6).mass=0.1;
142     mainset(9).set(7).foc=["FN","SC"];
143     mainset(9).set(7).mass=0.05;
144
145     %% Diferença de Temperaturas
146     % Alta
147     mainset(10).set(1).foc="PE";
148     mainset(10).set(1).mass=0.425+x4;
149     mainset(10).set(2).foc="FN";
150     mainset(10).set(2).mass=0.05-abs(x4);
151     mainset(10).set(3).foc="FR";
152     mainset(10).set(3).mass=0.025-x4;
153     mainset(10).set(4).foc="SC";
154     mainset(10).set(4).mass=0.25;
155     mainset(10).set(5).foc=["PE","SC"];
156     mainset(10).set(5).mass=0.1;
157     mainset(10).set(6).foc=["PE","FN"];
158     mainset(10).set(6).mass=0.1;
159     mainset(10).set(7).foc=["FN","SC"];
160     mainset(10).set(7).mass=0.05;
161
162     % Normal
163     mainset(11).set(1).foc="PE";
164     mainset(11).set(1).mass=0.2+x4;
165     mainset(11).set(2).foc="FN";
166     mainset(11).set(2).mass=0.4-abs(x4);
167     mainset(11).set(3).foc="FR";
168     mainset(11).set(3).mass=0.2-x4;
169     mainset(11).set(4).foc=["FN","PE"];
170     mainset(11).set(4).mass=0.05;
171     mainset(11).set(5).foc=["FN","FR"];
172     mainset(11).set(5).mass=0.05;
173     mainset(11).set(6).foc="SC";
174     mainset(11).set(6).mass=0.1;
175
176     % Baixa
177     mainset(12).set(1).foc="PE";
178     mainset(12).set(1).mass=0.025+x4;
179     mainset(12).set(2).foc="FN";

```

```

180     mainset(12).set(2).mass=0.05-abs(x4);
181     mainset(12).set(3).foc="FR";
182     mainset(12).set(3).mass=0.425-x4;
183     mainset(12).set(4).foc="SC";
184     mainset(12).set(4).mass=0.25;
185     mainset(12).set(5).foc=["FR","SC"];
186     mainset(12).set(5).mass=0.1;
187     mainset(12).set(6).foc=["FR","FN"];
188     mainset(12).set(6).mass=0.1;
189     mainset(12).set(7).foc=["FN","SC"];
190     mainset(12).set(7).mass=0.05;
191
192 end

```

```

1
2 function V = TableConditions(V)
3
4     % Transforma os identificadores de estado em strings
5
6     N = ["Alta","Normal","Baixa"];
7     V("P. Cond")=N(V("P. Cond"))';
8     V("T. Cond")=N(V("T. Cond")-3)';
9     V("P. Evap")=N(V("P. Evap")-6)';
10    V("Dif. T.")=N(V("Dif. T.")-9)';
11
12 end

```

```

1
2 function struct = Normalize(struct)
3
4     k=0;
5     n=0;
6
7     for i=1:size(struct,2)
8         if struct(i).mass <= 0
9             struct(i).mass = 0;
10        else
11            k=k+struct(i).mass;
12            n=n+1;
13        end
14    end
15    for i=1:size(struct,2)

```

```
16     if struct(i).mass ~= 0
17         struct(i).mass = struct(i).mass + (1-k)/n;
18     end
19 end
20 end
```

```
1
2 function [Comb1x2,Ktot] = Combine2Structs(struct1 , struct2)
3
4     % Combinacao linear de dois sets
5     LinearComb1x2 = LinearCombination(struct1 , struct2);
6
7     % Soma dos elementos focais de interesecao nula
8     [Ktot , nillindex] = SumFocNull(LinearComb1x2);
9
10    % Remocao dos elementos focais vazios
11    LinearComb1x2 = DelRowStruct(LinearComb1x2 , nillindex);
12
13    % Soma de elementos focais iguais
14    LinearComb1x2 = SumEqualFoc(LinearComb1x2);
15
16    % Correcao das massas de probabilidade
17    Comb1x2 = CorrMass(LinearComb1x2 , Ktot);
18
19 end
```

```
1
2 function [LinearCombXY] = LinearCombination(structX , structY)
3
4     % Combinacao linear dos elementos das duas estruturas
5
6     LinearCombXY=struct;
7     n=0;
8
9     for i=1:length(structX)
10         for j=1:length(structY)
11             n=n+1;
12             LinearCombXY(n).foc=intersect(structX(i).foc , structY(j).foc
13             );
14             LinearCombXY(n).mass=structX(i).mass*structY(j).mass;
15         end
16     end
17 end
```

```
16 end
```

```
1
2 function [Ktot, nillindex] = SumFocNil(struct)
3
4     % Soma das massas dos elementos focais vazios
5
6     kmass=0;
7     r=0;
8     nillindex=zeros;
9     for i=1:length(struct)
10         if isempty(struct(i).foc)
11             kmass=kmass+struct(i).mass;
12             r=r+1;
13             nillindex(r)=i;
14         end
15     end
16     Ktot=1-kmass;
17 end
```

```
1
2 function struct = DelRowStruct(struct, Dellindex)
3
4     % Eliminacao de linhas de uma estrutura
5
6     for i=1:length(Dellindex)
7         if Dellindex(i)>0
8             struct(Dellindex(i))=[];
9             Dellindex=Dellindex - 1;
10        end
11    end
12 end
```

```
1
2 function struct = SumEqualFoc(struct)
3
4     % Soma de massas de elementos focais iguais
5
6     r=1;
7     k=length(struct);
```

```

8   Dellindex=zeros(1,k);
9   for i=1:k-1
10      for j=i+1:k
11         if isequal(struct(i).foc,struct(j).foc) && ~isempty(struct(
12            i).foc)
13            struct(i).mass=struct(i).mass+struct(j).mass;
14            struct(j).foc=[];
15            Dellindex(r)=j;
16            r=r+1; %Linhas a eliminar em Delindex
17         end
18      end
19   end
20   % Eliminacao de linhas iguais
21   if all(Dellindex==zeros(1,k))
22      return
23   end
24
25   Dellindex=sort(Dellindex);
26   Dellindex=nonzeros(Dellindex);
27   struct = DelRowStruct(struct,Dellindex);
28
29 end

```

```

1
2 function struct = CorrMass(struct,Ktot)
3
4   % Correcao das massas atraves de K, devido aos elementos vazios
5
6   % Divisao das massas por 1-k (1-interseccao vazia)
7   for i=1:length(struct)
8      struct(i).mass=(struct(i).mass)/Ktot;
9   end
10 end

```

```

1
2 function struct = OrderStruct(struct)
3
4   struct=struct2table(struct);
5   struct=sortrows(struct,'mass','descend');
6   struct=table2struct(struct);
7

```

```
8 end
```

```
1
2 function struct = SetBel_Pl(struct)
3
4     % Funcao para acrescentar os valores de crenca e plausibilidade a
5     estrutura
6
7     Bel=Belief(struct);
8     Pl=Plausibility(struct);
9
10    for i=1:length(struct)
11        struct(i).Bel=Bel(i);
12        struct(i).Pl=Pl(i);
13    end
end
```

```
1
2 function [Bel] = Belief(struct)
3
4     % A Bel para cada acontecimento e igual a soma das massas cuja
5     uniao dos
6     % foc e igual ao proprio foc
7
8     L=length(struct);
9     Bel=zeros(1,L);
10
11    for i=1:L
12        for j=1:L
13            U=union(struct(i).foc , struct(j).foc );
14            if isequal(struct(i).foc ,U)
15                Bel(i)=Bel(i)+struct(j).mass;
16            else
17                Bel(i)=Bel(i);
18            end
19        end
20    end
end
```

```
1
```

```
2 function [Pl] = Plausibility(struct)
3
4     % A Pl para cada acontecimento e igual a soma das massas cuja
intersecao
5     % dos foc nao e vazia.
6
7     L=length(struct);
8     Pl=zeros(1,L);
9
10    for i=1:L
11        for j=1:L
12            I=intersect(struct(i).foc,struct(j).foc);
13            if ~isempty(I)
14                Pl(i)=Pl(i)+struct(j).mass;
15            else
16                Pl(i)=Pl(i);
17            end
18        end
19    end
20 end
```

```
1
2 function struct = FilterStruct(struct)
3
4     % Filtra elementos conjuntos
5
6     for i=length(struct):-1:1
7         if length(struct(i).foc) ~= 1
8             struct(i) = [];
9         end
10    end
11 end
```

```
1
2 function [struct1,k1,k2] = Propagation(struct1,struct0,k1,k2,S)
3
4     if isequal(struct1(1).foc,struct0(1).foc)
5         if struct1(1).Pl + k1 > 1
6             struct1(1).Pl = 1;
7             struct1(1).Bel = 0.9;
8         if isequal(struct1(2).foc,struct0(2).foc)
9             struct1(2).Pl = struct1(2).Pl + k2;
```

```

10         struct1(2).Bel = (struct1(2).Pl + struct1(2).Bel)/2;
11         k2 = k2 + 0.2/S;
12     else
13         k2 = 0;
14     end
15 else
16     struct1(1).Pl = struct1(1).Pl + k1;
17     struct1(1).Bel = (struct1(1).Pl + struct1(1).Bel)/2;
18     k1 = k1 + 0.3/S;
19     if isequal(struct1(2).foc , struct0(2).foc)
20         struct1(2).Pl = struct1(2).Pl + k2;
21         struct1(2).Bel = (struct1(2).Pl + struct1(2).Bel)/2;
22         k2 = k2 + 0.2/S;
23     else
24         k2 = 0;
25     end
26 end
27 else
28     k1 = 0;
29     for i=1:length(struct1)
30         if isequal(struct1(i).foc , "SC")
31             for j=1:length(struct0)
32                 if isequal(struct0(j).foc , "SC")
33                     if struct1(i).Pl + 0.1 > 1 || struct1(i).Bel +
0.1 > 0.9
34                         struct1(i).Pl = 1;
35                         struct1(i).Bel = 0.9;
36                     else
37                         struct1(i).Pl = struct1(i).Pl + 0.1;
38                         struct1(i).Bel = struct1(i).Bel + 0.1;
39                     end
40                 end
41             end
42         end
43     end
44 end
45 end

```

```

1
2 function [Eval] = Evaluation(struct ,m1,m2, string)
3
4     acur = 0;
5
6     if m1 == 0 && m2 == 0

```

```

7     for i=1:length(struct)
8         if strcmp(struct(i).set(1).foc,"FN")
9             acur = acur + 1;
10        end
11    end
12    Eval=acur/length(struct);
13    return
14 end

15
16 if m1 == 1 && m2 == 1
17     for i=1:length(struct)
18         if strcmp(struct(i).set(1).foc,string)
19             acur = acur + 1;
20         end
21     end
22     Eval=acur/length(struct);
23     return
24 end

25
26 if m1 == 1
27     for i=m1:m2
28         if strcmp(struct(i).set(1).foc,string)
29             acur = acur + 1;
30         end
31     end
32     for i=m2+1:length(struct)
33         if strcmp(struct(i).set(1).foc,"FN")
34             acur = acur + 1;
35         end
36     end
37     Eval=acur/length(struct);
38     return
39 elseif m2 == 1
40     for i=1:m1
41         if strcmp(struct(i).set(1).foc,"FN")
42             acur = acur + 1;
43         end
44     end
45     for i=m1+1:length(struct)
46         if strcmp(struct(i).set(1).foc,string)
47             acur = acur + 1;
48         end
49     end
50     Eval=acur/length(struct);
51 else

```

```

52     for i=1:m1
53         if strcmp(struct(i).set(1).foc, "FN")
54             acur = acur + 1;
55         end
56     end
57     for i=m1+1:m2
58         if strcmp(struct(i).set(1).foc, string)
59             acur = acur + 1;
60         end
61     end
62     for i=m2+1:length(struct)
63         if strcmp(struct(i).set(1).foc, "FN")
64             acur = acur + 1;
65         end
66     end
67     Eval=acur/length(struct);
68 end
69 end

```

```

1
2 function [b,b2] = PlotBarGraph(T,struct,Hora,stringfail,stringdate,
3     stringtitle,Sfailid1,Efailid1,mark1,mark2,language)
4
5     Plausi=zeros(size(struct,2),4);
6     Belief=zeros(size(struct,2),4);
7
8     for i=1:size(struct,2)
9         for j=1:2
10            if isequal(struct(i).set(j).foc, stringfail)
11                Plausi(i,1)=struct(i).set(j).Pl;
12                Belief(i,1)=struct(i).set(j).Bel;
13            elseif isequal(struct(i).set(j).foc, "FN")
14                Plausi(i,2)=struct(i).set(j).Pl;
15                Belief(i,2)=struct(i).set(j).Bel;
16            elseif isequal(struct(i).set(j).foc, "FR")
17                Plausi(i,3)=struct(i).set(j).Pl;
18                Belief(i,3)=struct(i).set(j).Bel;
19            elseif isequal(struct(i).set(j).foc, "SC")
20                Plausi(i,4)=struct(i).set(j).Pl;
21                Belief(i,4)=struct(i).set(j).Bel;
22            end
23        end
24    end

```

```

25     Plausi=Plausi*100;
26     Belief=(Belief*100);
27
28     Hora=split(Hora);
29     Hora(:,1)=[];
30     Hora=split(Hora, ".");
31     Hora(:,3)=[];
32     Hora=join(Hora, ":");
33     Hora=categorical(Hora);
34
35     hold on
36     yyaxis left
37     b = bar(Hora, Plausi, 3, 'grouped');
38     b(1).FaceColor='#A2142F';
39     b(2).FaceColor='#77AC30';
40     b(3).FaceColor='#0072BD';
41     b(4).FaceColor='#EDB120';
42
43     b2 = bar(Hora, Belief, 2, 'grouped');
44     b2(1).FaceColor='#FF0000';
45     b2(2).FaceColor='#00FF00';
46     b2(3).FaceColor='#4DBEEE';
47     b2(4).FaceColor='#FFFF00';
48
49
50     xtips1 = b(1).XEndPoints;
51     ytips1 = b(1).YEndPoints;
52     labels1 = string(round(b(1).YData,0));
53     labels1(labels1=="0")=NaN;
54     labels1(labels1=="100")=NaN;
55     text(xtips1, ytips1, labels1, 'HorizontalAlignment', 'center', '
VerticalAlignment', 'bottom', 'Color', '#A2142F', 'FontSize', 8)
56
57     xtips2 = b(2).XEndPoints;
58     ytips2 = b(2).YEndPoints;
59     labels2 = string(round(b(2).YData,0));
60     labels2(labels2=="0")=NaN;
61     labels2(labels2=="100")=NaN;
62     text(xtips2, ytips2, labels2, 'HorizontalAlignment', 'center', '
VerticalAlignment', 'bottom', 'Color', '#77AC30', 'FontSize', 8)
63
64     xtips3 = b(3).XEndPoints;
65     ytips3 = b(3).YEndPoints;
66     labels3 = string(round(b(3).YData,0));
67     labels3(labels3=="0")=NaN;

```

```

68 labels3(labels3=="100")=NaN;
69 text(xtips3, ytips3, labels3, 'HorizontalAlignment', 'center', '
VerticalAlignment', 'bottom', 'Color', '#0072BD', 'FontSize', 8)
70
71 xtips4 = b(4).XEndPoints;
72 ytips4 = b(4).YEndPoints;
73 labels4 = string(round(b(4).YData,0));
74 labels4(labels4=="0")=NaN;
75 labels4(labels4=="100")=NaN;
76 text(xtips4, ytips4, labels4, 'HorizontalAlignment', 'center', '
VerticalAlignment', 'bottom', 'Color', '#EDB120', 'FontSize', 8)
77
78 if language == 1
79     if Sfailid1 > mark1 && Sfailid1 < mark2
80         xline(Sfailid1-mark1, '—', {'Início de', 'Falha'}, '
HandleVisibility', 'off', 'LineWidth', 3);
81     end
82
83     if Efailid1 > mark1 && Efailid1 < mark2
84         xline(Efailid1-mark1, '—', {'Fim de', 'Falha'}, '
HandleVisibility', 'off', 'LineWidth', 3);
85     end
86 else
87     if Sfailid1 > mark1 && Sfailid1 < mark2
88         xline(Sfailid1-mark1, '—', {'Start of', 'Failure'}, '
HandleVisibility', 'off', 'LineWidth', 3);
89     end
90
91     if Efailid1 > mark1 && Efailid1 < mark2
92         xline(Efailid1-mark1, '—', {'End of', 'Failure'}, '
HandleVisibility', 'off', 'LineWidth', 3);
93     end
94 end
95
96 xlabel(stringdate)
97 ylabel('%')
98 ylim([0 200])
99 yticks([0 20 40 60 80 100])
100 title(stringtitle)
101
102 yyaxis right
103
104 if isequal(stringfail, 'PE')
105     ylabel([char(176) 'C'])
106 else

```

```

107     ylabel(['bar / ' char(176) 'C'])
108 end
109
110 if language == 1
111     tar="T. Ar";
112     tcond="T. Cond";
113     pcond="P. Cond";
114     tag="T. Agua";
115     pevap="P. Evap";
116     dift="Dif. T.";
117 else
118     tar="Air T.";
119     tcond="Cond T.";
120     pcond="Cond P.";
121     tag="Water T.";
122     pevap="Evap P.";
123     dift="T. Diff";
124 end
125
126 if strcmp("PC",stringfail)
127     p=plot(Hora,T.("T. Ar"),Hora,T.("T. Cond"),Hora,T.("P. Cond"));
128     p(1).Color='#0072BD';
129     p(1).LineStyle='-';
130     p(1).LineWidth=1;
131     p(2).Color='#D95319';
132     p(2).LineStyle='-';
133     p(2).LineWidth=1.5;
134     p(3).Color='#A2142F';
135     p(3).LineStyle='-';
136     p(3).LineWidth=2;
137
138     if language == 1
139         lgd = legend('Pl '+stringfail+', 'Pl FN', 'Pl FR', 'Pl SC', '
Bel '+stringfail+', 'Bel FN', 'Bel FR', 'Bel SC',tar ,tcond ,pcond);
140     else
141         lgd = legend('Pl '+stringfail+', 'Pl NF', 'Pl RL', 'Pl SC', '
Bel '+stringfail+', 'Bel NF', 'Bel RL', 'Bel SC',tar ,tcond ,pcond);
142     end
143     lgd.NumColumns = 3;
144     lgd.Location = 'northwest';
145     lgd.FontSize = 8;
146     ylim([-10 46])
147     yticks(15:5:45)
148
149 elseif strcmp("ER",stringfail)

```

```

150     p=plot(Hora,T.("T. Agua Out"),Hora,T.("P. Evap"),LineWidth=2);
151     p(1).Color='#0072BD';
152     p(1).LineStyle='-';
153     p(1).LineWidth=1;
154     p(2).Color='#D95319';
155     p(2).LineStyle='-';
156     p(2).LineWidth=2;
157
158     if language == 1
159         lgd = legend('Pl '+stringfail+' ','Pl FN','Pl FR','Pl SC','
Bel '+stringfail+' ','Bel FN','Bel FR','Bel SC',tag,pevap);
160     else
161         lgd = legend('Pl '+stringfail+' ','Pl NF','Pl RL','Pl SC','
Bel '+stringfail+' ','Bel NF','Bel RL','Bel SC',tag,pevap);
162     end
163     lgd.NumColumns = 3;
164     lgd.Location = 'northwest';
165     lgd.FontSize = 8;
166     ylim([0 12])
167     yticks(4:2:12)
168
169     else
170     p=plot(Hora,T.("T. Agua Out"),Hora,T.("Dif. T."),LineWidth=2);
171     p(1).Color='#0072BD';
172     p(1).LineStyle='-';
173     p(1).LineWidth=1;
174     p(2).Color='#D95319';
175     p(2).LineStyle='-';
176     p(2).LineWidth=2;
177
178     if language == 1
179         lgd = legend('Pl '+stringfail+' ','Pl FN','Pl FR','Pl SC','
Bel '+stringfail+' ','Bel FN','Bel FR','Bel SC',tag,dift);
180     else
181         stringfail="WF";
182         lgd = legend('Pl '+stringfail+' ','Pl NF','Pl RL','Pl SC','
Bel '+stringfail+' ','Bel NF','Bel RL','Bel SC',tag,dift);
183     end
184     lgd.NumColumns = 3;
185     lgd.Location = 'northwest';
186     lgd.FontSize = 8;
187     ylim([-4 12])
188     yticks(4:2:12)
189
190     end

```

191

192 **end**

Anexo I - Parâmetros recolhidos do sistema *AER- NET*

| Parâmetros AERNET | | |
|---|----------|---------|
| Descrição | Variável | Unidade |
| <i>Timestamp</i> | | s |
| <i>Water input temperature</i> | tiA | °C |
| <i>Water output temperature</i> | tuA | °C |
| <i>Coil temperature</i> | tSb | °C |
| <i>Force gas temperature</i> | tGP | °C |
| <i>Outside air temperature</i> | tAE | °C |
| <i>Delivery pressure</i> | AP | bar |
| <i>Suction pressure</i> | bP | bar |
| <i>CP times</i> | CP | |
| <i>Primary cp operation hours (thousands)</i> | HCO | |
| <i>Primary cp operation hours (units)</i> | HCO | |
| <i>Auxiliary cp operation hours (thousands)</i> | HC1 | |
| <i>Auxiliary cp operation hours (units)</i> | HC1 | |
| <i>Primary cp pickup current (thousands)</i> | SPO | |
| <i>Primary cp pickup current (units)</i> | SPO | |
| <i>Auxiliary cp pickup current (thousands)</i> | SP1 | |
| <i>Auxiliary cp pickup current (units)</i> | SP1 | |
| <i>Setting currently in use</i> | Set | °C |
| <i>Percentage thermostat required power</i> | tEr | % |
| <i>DCP pressure setting</i> | dCP | bar |
| <i>DCP pressure differential</i> | dCP | bar |
| <i>Machine delivery power</i> | Po | 0/1 |
| <i>Pressure drop</i> | PrF | bar |
| <i>Summer Setpoint</i> | StF | °C |
| <i>Cooling band</i> | bnF | °C |
| <i>Winter Setpoint</i> | StC | °C |
| <i>Heating band</i> | bnC | °C |
| <i>Correction set</i> | Cst | 0/1 |
| <i>Machine type</i> | | |
| <i>Digital relays output status</i> | | 0/1 |
| <i>Commands enabling status</i> | PAN | 0/1 |

Parâmetros AERNET (continuação)

| Descrição | Variável | Unidade |
|---|----------|---------|
| <i>Ambient thermostat enabling (ID3)</i> | trA | 0/1 |
| <i>DHW DI status</i> | TWS | 0/1 |
| <i>ON/OFF remote DI status</i> | IA | 0/1 |
| <i>DI Season status</i> | C/F | 0/1 |
| <i>DI Ambient thermostat status</i> | TRA | 0/1 |
| <i>Alarm summary</i> | | 0/1 |
| <i>Prealarm summary</i> | | 0/1 |
| <i>MV1-2 / MPOC</i> | | 0/1 |
| <i>MPOE</i> | | 0/1 |
| <i>RA / RE</i> | | 0/1 |
| <i>CP</i> | | 0/1 |
| <i>CPA / RCV</i> | | 0/1 |
| <i>VIC / VSBP</i> | | 0/1 |
| <i>VCG</i> | | 0/1 |
| <i>AE</i> | | 0/1 |
| <i>RCR/BOILER</i> | | 0/1 |
| <i>Machine Status</i> | | 0/1 |
| <i>Electric heater/boiler</i> | rin | 0/1 |
| <i>Compressor circuit breaker</i> | 1 | 0/1 |
| <i>Fan circuit breaker</i> | 2 | 0/1 |
| <i>High pressure switch</i> | 3 | 0/1 |
| <i>Flowswitch alarm</i> | 4 | 0/1 |
| <i>Low pressure switch</i> | 5 | 0/1 |
| <i>NTC1 probe absent</i> | 6 | 0/1 |
| <i>NTC2 probe absent</i> | 7 | 0/1 |
| <i>Antifreeze</i> | 8 | 0/1 |
| <i>NTC4 probe absent</i> | 9 | 0/1 |
| <i>Discharge gas high temperature</i> | 10 | 0/1 |
| <i>Discharge compressor transducer absent</i> | 11 | 0/1 |
| <i>High pressure</i> | 12 | 0/1 |
| <i>NTC3 probe absent</i> | 13 | 0/1 |
| <i>Suction transducer absent</i> | 14 | 0/1 |
| <i>Low pressure</i> | 15 | 0/1 |
| <i>Low performance</i> | 16 | 0/1 |
| <i>Pump circuit breaker</i> | 17 | 0/1 |

Parâmetros AERNET (continuação)

| Descrição | Variável | Unidade |
|---|----------|---------|
| <i>High pressure partialization</i> | 18 | 0/1 |
| <i>Low pressure partialization</i> | 19 | 0/1 |
| <i>Discharge temperature partialization</i> | 20 | 0/1 |
| <i>Reverse cycle valve fault</i> | 54 | 0/1 |
| <i>Inlet water high temperature</i> | 55 | 0/1 |
| <i>Low pressure limit. Unit exaust.</i> | 207 | 0/1 |
| <i>Compressor circuit breaker P-A</i> | 101 | 0/1 |
| <i>Fan circuit breaker P-A</i> | 102 | 0/1 |
| <i>High pressure switch P-A</i> | 103 | 0/1 |
| <i>Flowswitch alarm P-A</i> | 104 | 0/1 |
| <i>Low pressure switch P-A</i> | 105 | 0/1 |
| <i>NTC1 probe absent P-A</i> | 106 | 0/1 |
| <i>NTC2 probe absent P-A</i> | 107 | 0/1 |
| <i>Antifreeze P-A</i> | 108 | 0/1 |
| <i>NTC4 probe absent P-A</i> | 109 | 0/1 |
| <i>Discharge gas high T P-A</i> | 110 | 0/1 |
| <i>Discharge compressor transducer absent P-A</i> | 111 | 0/1 |
| <i>High pressure P-A</i> | 112 | 0/1 |
| <i>NTC3 probe absent P-A</i> | 113 | 0/1 |
| <i>Suction transducer absent P-A</i> | 114 | 0/1 |
| <i>Low pressure P-A</i> | 115 | 0/1 |
| <i>Pump circuit breaker P-A</i> | 117 | 0/1 |
| <i>High pressure partialization P-A</i> | 118 | 0/1 |
| <i>Low pressure partialization P-A</i> | 119 | 0/1 |
| <i>Discharge T partialization P-A</i> | 120 | 0/1 |
| <i>Inlet water high T P-A</i> | 155 | 0/1 |
| <i>Reverse cycle for high T of the discharge gas P-A</i> | 156 | 0/1 |
| <i>Error reading the remote sensor of the DHW panel P-A</i> | 157 | 0/1 |
| <i>Error reading external T sensor P-A</i> | 158 | 0/1 |
| <i>Low pressure limit. Unit exaust. P-A</i> | 307 | 0/1 |
| <i>ON/OFF System</i> | | 0/1 |
| <i>Alarms / Reset</i> | | 0/1 |

Anexo II - Estruturas DS com base em conhecimento especialista

| Estruturas DS | | |
|--|---------|-------|
| Causa | Foco | Massa |
| Pressão do Condensador Alta | | |
| Falta de permuta no condensador | {Pc} | 0.6 |
| Falta de permuta no evaporador | {Pe} | 0.02 |
| Sensores e Controladores | {sc} | 0.1 |
| Outros | {ot} | 0.03 |
| Funcionamento normal | {Fn} | 0.05 |
| Falta de permuta no evaporador& Sensores e Controladores | {Pc,sc} | 0.1 |
| Falta de permuta no evaporador& Outros | {Pc,ot} | 0.1 |
| Pressão do Condensador Normal | | |
| Falta de permuta no evaporador | {Pe} | 0.02 |
| Sensores e Controladores | {sc} | 0.05 |
| Outros | {ot} | 0.03 |
| Funcionamento normal | {Fn} | 0.7 |
| Funcionamento normal & Sensores e Controladores | {Fn,sc} | 0.1 |
| Funcionamento normal & Outros | {Fn,ot} | 0.1 |
| Pressão do Condensador Baixa | | |
| Fuga de Refrigerante | {Fr} | 0.7 |
| Sensores e Controladores | {sc} | 0.02 |
| Outros | {ot} | 0.03 |
| Funcionamento normal | {Fn} | 0.05 |
| Fuga de Refrigerante & Sensores e Controladores | {Fn,sc} | 0.1 |
| Fuga de Refrigerante & Outros | {Fn,ot} | 0.1 |

| Estruturas DS (continuação) | | |
|--|---------|-------|
| Causa | Foco | Massa |
| Temperatura do Condensador Alta | | |
| Falta de permuta no condensador | {Pc} | 0.5 |
| Falta de permuta no evaporador | {Pe} | 0.05 |
| Sensores e Controladores | {sc} | 0.15 |
| Outros | {ot} | 0.05 |
| Funcionamento normal | {Fn} | 0.05 |
| Falta de permuta no evaporador& Sensores e Controladores | {Pc,sc} | 0.1 |
| Falta de permuta no evaporador& Outros | {Pc,ot} | 0.1 |
| Temperatura do Condensador Normal | | |
| Falta de permuta no evaporador | {Pe} | 0.02 |
| Sensores e Controladores | {sc} | 0.05 |
| Outros | {ot} | 0.03 |
| Funcionamento normal | {Fn} | 0.7 |
| Funcionamento normal & Sensores e Controladores | {Fn,sc} | 0.1 |
| Funcionamento normal & Outros | {Fn,ot} | 0.1 |
| Temperatura do Condensador Normal | | |
| Fuga de Refrigerante | {Fr} | 0.5 |
| Sensores e Controladores | {sc} | 0.2 |
| Outros | {ot} | 0.05 |
| Funcionamento normal | {Fn} | 0.05 |
| Fuga de Refrigerante & Sensores e Controladores | {Fr,sc} | 0.1 |
| Fuga de Refrigerante & Outros | {Fr,ot} | 0.1 |
| Pressão do Evaporador Alta | | |
| Falta de permuta no evaporador | {Pe} | 0.6 |
| Sensores e Controladores | {sc} | 0.05 |
| Outros | {ot} | 0.05 |

| Estruturas DS (continuação) | | |
|--|---------|-------|
| Causa | Foco | Massa |
| Funcionamento normal | {Fn} | 0.1 |
| Excesso de Refrigerante & Sensores e Controladores | {Pe,sc} | 0.1 |
| Excesso de Refrigerante & Outros | {Pe,ot} | 0.1 |
| Pressão do Evaporador Normal | | |
| Sensores e Controladores | {sc} | 0.05 |
| Outros | {ot} | 0.05 |
| Funcionamento normal | {Fn} | 0.07 |
| Funcionamento normal & Sensores e Controladores | {Fn,sc} | 0.1 |
| Funcionamento normal & Outros | {Fn,ot} | 0.1 |
| Pressão do Evaporador Baixa | | |
| Fuga de Refrigerante | {Fr} | 0.5 |
| Caudal de água reduzido | {Ca} | 0.1 |
| Sensores e Controladores | {sc} | 0.05 |
| Outros | {ot} | 0.05 |
| Funcionamento normal | {Fn} | 0.1 |
| Fuga de Refrigerante & Sensores e Controladores | {Fr,sc} | 0.1 |
| Fuga de Refrigerante & Outros | {Fr,ot} | 0.1 |
| Diferença de Temperaturas de água no Evaporador Alta | | |
| Caudal de água reduzido | {Ca} | 0.6 |
| Sensores e Controladores | {sc} | 0.05 |
| Outros | {ot} | 0.05 |
| Funcionamento normal | {Fn} | 0.1 |
| Caudal de água reduzido & Sensores e Controladores | {Ca,sc} | 0.1 |
| Caudal de água reduzido & Outros | {Ca,ot} | 0.1 |
| Diferença de Temperaturas de água no Evaporador Normal | | |

Estruturas DS (continuação)

| Causa | Foco | Massa |
|---|---------|-------|
| Sensores e Controladores | {sc} | 0.05 |
| Outros | {ot} | 0.05 |
| Funcionamento normal | {Fn} | 0.7 |
| Funcionamento normal & Sensores e Controladores | {Fn,sc} | 0.1 |
| Funcionamento normal & Outros | {Fn,ot} | 0.1 |
| Diferença de Temperaturas de água no Evaporador Baixa | | |
| Fuga de Refrigerante | {Fr} | 0.5 |
| Caudal de água elevado | {Ca} | 0.1 |
| Sensores e Controladores | {sc} | 0.05 |
| Outros | {ot} | 0.05 |
| Funcionamento normal | {Fn} | 0.1 |
| Fuga de Refrigerante & Sensores e Controladores | {Fr,sc} | 0.1 |
| Fuga de Refrigerante & Outros | {Fr,ot} | 0.1 |

Anexo III - Estruturas DS adaptadas ao programa

| Estruturas DS | | |
|--|---------|------------|
| Causa | Foco | Massa |
| Pressão do Condensador Alta | | |
| Falta de permuta no condensador | {PC} | $0,425+x$ |
| Funcionamento normal | {FN} | $0,05- x $ |
| Fuga de refrigerante | {FR} | $0,025-x$ |
| Sensores e Controladores | {SC} | 0,025 |
| Falta de permuta no condensador & Sensores e Controladores | {PC,SC} | 0,1 |
| Falta de permuta no condensador & Funcionamento normal | {PC,FN} | 0,1 |
| Funcionamento normal & Sensores e Controladores | {FN,SC} | 0,05 |
| Pressão do Condensador Normal | | |
| Falta de permuta no condensador | {PC} | $0,25+x$ |
| Funcionamento normal | {FN} | $0,4- x $ |
| Fuga de refrigerante | {FR} | $0,25-x$ |
| Funcionamento normal & Falta de permuta no condensador | {FN,PC} | 0,05 |
| Funcionamento normal & Fuga de refrigerante | {FN,FR} | 0,05 |
| Pressão do Condensador Baixa | | |
| Falta de permuta no condensador | {PC} | $0,025-x$ |
| Funcionamento normal | {FN} | $0,05- x $ |
| Fuga de refrigerante | {FR} | $0,425+x$ |
| Sensores e Controladores | {SC} | 0,025 |
| Fuga de refrigerante & Sensores e Controladores | {FR,SC} | 0,1 |
| Fuga de refrigerante & Funcionamento normal | {FR,FN} | 0,1 |
| Funcionamento normal & Sensores e Controladores | {FN,SC} | 0,05 |
| Temperatura do Condensador Alta | | |
| Falta de permuta no condensador | {PC} | $0,425+x$ |

Estruturas DS (continuação)

| Causa | Foco | Massa |
|--|---------|------------|
| Funcionamento normal | {FN} | $0,05- x $ |
| Fuga de refrigerante | {FR} | $0,025-x$ |
| Sensores e Controladores | {SC} | 0,025 |
| Falta de permuta no condensador & Sensores e Controladores | {PC,SC} | 0,1 |
| Falta de permuta no condensador & Funcionamento normal | {PC,FN} | 0,1 |
| Funcionamento normal & Sensores e Controladores | {FN,SC} | 0,05 |

Temperatura do Condensador Normal

| | | |
|--|---------|-----------|
| Falta de permuta no condensador | {PC} | $0,25+x$ |
| Funcionamento normal | {FN} | $0,4- x $ |
| Fuga de refrigerante | {FR} | $0,25-x$ |
| Funcionamento normal & Falta de permuta no condensador | {FN,PC} | 0,05 |
| Funcionamento normal & Fuga de refrigerante | {FN,FR} | 0,05 |

Temperatura do Condensador Baixa

| | | |
|---|---------|------------|
| Falta de permuta no condensador | {PC} | $0,025-x$ |
| Funcionamento normal | {FN} | $0,05- x $ |
| Fuga de refrigerante | {FR} | $0,425+x$ |
| Sensores e Controladores | {SC} | 0,025 |
| Fuga de refrigerante & Sensores e Controladores | {FR,SC} | 0,1 |
| Fuga de refrigerante & Funcionamento normal | {FR,FN} | 0,1 |
| Funcionamento normal & Sensores e Controladores | {FN,SC} | 0,05 |

Pressão do Evaporador Alta

| | | |
|--|---------|------------|
| Excesso de refrigerante | {ER} | $0,425+x$ |
| Funcionamento normal | {FN} | $0,05- x $ |
| Fuga de refrigerante | {FR} | $0,025-x$ |
| Sensores e Controladores | {SC} | 0,025 |
| Excesso de refrigerante & Sensores e Controladores | {ER,SC} | 0,1 |

| Estruturas DS (continuação) | | |
|---|---------|------------|
| Causa | Foco | Massa |
| Excesso de refrigerante & Funcionamento normal | {ER,FN} | 0,1 |
| Funcionamento normal & Sensores e Controladores | {FN,SC} | 0,05 |
| Pressão do Evaporador Normal | | |
| Excesso de refrigerante | {ER} | $0,25+x$ |
| Funcionamento normal | {FN} | $0,4- x $ |
| Fuga de refrigerante | {FR} | $0,25-x$ |
| Funcionamento normal & Excesso de refrigerante | {FN,ER} | 0,05 |
| Funcionamento normal & Fuga de refrigerante | {FN,FR} | 0,05 |
| Pressão do Evaporador Baixa | | |
| Excesso de refrigerante | {ER} | $0,025-x$ |
| Funcionamento normal | {FN} | $0,05- x $ |
| Fuga de refrigerante | {FR} | $0,425+x$ |
| Sensores e Controladores | {SC} | 0,025 |
| Fuga de refrigerante & Sensores e Controladores | {FR,SC} | 0,1 |
| Fuga de refrigerante & Funcionamento normal | {FR,FN} | 0,1 |
| Funcionamento normal & Sensores e Controladores | {FN,SC} | 0,05 |
| Diferença de Temperaturas de água no Evaporador Alta | | |
| Falta de permuta no evaporador | {PE} | $0,425+x$ |
| Funcionamento normal | {FN} | $0,05- x $ |
| Fuga de refrigerante | {FR} | $0,025-x$ |
| Sensores e Controladores | {SC} | 0,025 |
| Falta de permuta no evaporador & Sensores e Controladores | {PE,SC} | 0,1 |
| Falta de permuta no evaporador & Funcionamento normal | {PE,FN} | 0,1 |
| Funcionamento normal & Sensores e Controladores | {FN,SC} | 0,05 |
| Diferença de Temperaturas de água no Evaporador Normal | | |

Estruturas DS (continuação)

| Causa | Foco | Massa |
|---|---------|-----------|
| Falta de permuta no evaporador | {PE} | $0,25+x$ |
| Funcionamento normal | {FN} | $0,4- x $ |
| Fuga de refrigerante | {FR} | $0,25-x$ |
| Funcionamento normal & Falta de permuta no evaporador | {FN,PE} | 0,05 |
| Funcionamento normal & Fuga de refrigerante | {FN,FR} | 0,05 |

Diferença de Temperaturas de água no Evaporador Baixa

| | | |
|---|---------|------------|
| Falta de permuta no evaporador | {PE} | $0,025-x$ |
| Funcionamento normal | {FN} | $0,05- x $ |
| Fuga de refrigerante | {FR} | $0,425+x$ |
| Sensores e Controladores | {SC} | 0,025 |
| Fuga de refrigerante & Sensores e Controladores | {FR,SC} | 0,1 |
| Fuga de refrigerante & Funcionamento normal | {FR,FN} | 0,1 |
| Funcionamento normal & Sensores e Controladores | {FN,SC} | 0,05 |

Anexo IV - Artigo ICMECE 2022

O artigo em anexo foi submetido para a conferência ICMECE 2022, tendo sido aceite sob uma taxa de aceitação de 64 %.



13/08/2022

ACCEPTANCE LETTER

Dear Daniel Baptista, Miguel Cavique

We are glad to inform you that your study full-text entitled "*ID 390 Chiller fault evaluation using Dempster-Shafer theory*" is accepted by the scientific committee of 2. The Interdisciplinary Conference on Mechanics, Computers and Electrics Interdisciplinary Conference on Mechanics, Computers and Electrics.

At least one author of each paper should register to the conference via the online registration page at <https://www.ecres.net/icmece/>. According to regulations, we deliver our Conference Proceedings via web-site just after the conference.

Please also note that your registration becomes valid after your payment. Please follow the instructions at the registration page. If you have registered once, please do not register for second time.

You can follow the latest news about the conference from the website at <http://www.icmece.org/>. You can participate at the conference with your full-text paper. You can also use this *acceptance letter* for all official permission and the *visa* requirements in your home country.

We would like to thank you for your interest and we are looking forward to seeing you in the ICMECE 2022

Yours sincerely,

Prof. Dr. Jose Manuel Lopez Guede
University of Basque Country,
Spain
Tel: +34665708247
E-mail: jm.lopez@ehu.es

Prof. Dr. Erol Kurt
Head of the Organization Committee
ICMECE
Tel: +90 312 202 85 50
E-mail: ekurt52tr@yahoo.com,
ekurt@gazi.edu.tr

Prof. Dr. Nicu Bizon
University of Pitesti,
Romania
E-mail: nicubizon@yahoo.com

FIGURA IV.1: Carta de aceitação

Chiller fault evaluation using Dempster-Shafer theory

Daniel Baptista
Naval Academy
Almada, Portugal
santos.baptista@marinha.pt

Miguel Cavique
Naval Academy, and
UNIDEMI, NOVA School of Science and Technology
Almada, Portugal
cavique.santos@escolanaval.pt

Abstract—The early detection of faults is critical for equipment maintenance. This work presents an application of the Dempster-Shafer theory to anticipate causes that may lead to failures. This theory uses subjective information from experts about the probability of events using abduction reasoning. Monitoring the chiller's performance in an air conditioning system gives hints to understanding problems in an early stage of the fault. This paper focuses on faults due to a lack of heat transfer in the chiller. A web system gets data from the chiller and gives the input to the application. The application was able to identify provoked faults in the chiller.

Keywords— Chiller, faults, Dempster-Shafer

I. INTRODUCTION

A function of an air conditioning (HVAC) system is to cool. Chillers do it in most commercial and industrial applications. The most common chillers cool water through a one-stage compression refrigeration cycle. Heat comes into the chiller in the evaporator at low temperature, and the chiller releases heat in the condenser at elevated temperature and pressure. Therefore, they are essential parts of an HVAC system. Any fault in a chiller affects all pieces of equipment of the plant it serves.

The early identification of faults is crucial in any system. In an HVAC system, identifying problems that may occur in the chiller avoids future comfort or process problems and allows predictive maintenance. This work aims to identify early heat exchange faults in the evaporator and condenser. It applies the Dempster-Shafer theory (DST), an abduction theory that uses expert knowledge and evaluates the possibility of faults. The chiller parameters come via the web to the DST application.

This work was able to identify the most significant modifications that create a reduction of heat transfer in the condenser and evaporator. Future works can make the application able to identify faults in other compounds and other models of chillers.

From the bibliography review, this work is the first attempt to define an abduction system for an HVAC chiller using DST. There have been other works addressing the evaluation of faults in chillers. Defects can be identified online by statistical evaluation and a fault tree [1]. Namburu et al. [2] applied a black box method to detect faults in centrifugal chillers using artificial intelligence (AI). It mixes support vector, principal component analysis, and partial least squares. Ahmad and Atta [3] used a wireless system to record data from an HVAC installation and the faults identified from a frequency evaluation. Fuzzy genetic algorithms [4] can identify faults of an HVAC system. They used fuzzy rules from test data at nominal conditions. The

difference between expected and actual data allows for identifying faults at different levels. Predictive methods can use logged data from operation and maintenance in a data-based learning system [5]. Gálvez [6] mixed simulated data with actual data to predict faults in an HVAC of a train. Actual data from chillers can be used to preview alarms in future time frames with new conditions [7]. Li et al. [8] used a Bayesian network with quantitative data and qualitative knowledge to predict HVAC faults.

This work has similarities with Li's. Instead of Bayesian inference, it uses the DST described in the next section. DST is better adapted to expert opinions, reaching a range for the probability of fault. It works with a fault graph. Section III shows how data is collected from the chiller and describes the method. Then, the results and discussion are presented. Finally, the last section presents the conclusions and future works.

II. DEMPSTER SHAFER THEORY

DST was first published in 1976 from the former works of Arthur Dempster and the late developments of Shafer. The theory is about evidence in a context of uncertainty. Unlike probabilities, DST allows quantifying uncertainty from a subjective evaluation of the mass of probability of a set of events. It enables fusing evidence from various sources or opinions and creates a range for the probability of events. Next, subsection B describes a summary of DST [9]. Yager [10] presented a reformulation of the evidence computation regarding conflicting opinions. Zadeh [11] fuzzified the method and created measures for the credibility of opinions.

A. Bayesian inference

For two events, A and B, the Bayesian inference allows defining the conditional probability $P(A|B)$ if $P(B|A)$ is known. $P(A|B)$ is an abduction evaluation of probability from a prior knowledge $P(B|A)$. Bayes theorem can be rewritten as:

$$\text{Abduction} \propto \text{Prior} \times \text{New} \quad (1)$$

The following section shows DST in a similar format to (1) to model the combination of evidence.

B. Dempster-Shafer theory

The DST uses sets that represent responses to questions. Similarly to probabilities theory, there is a frame of discernment Θ . However, unlike probabilities, which has $\#\Omega$ as the number of hypotheses, Θ has $2^{\#\Omega}$ propositions.

All possible combinations of sets of Ω , including \emptyset and Ω , are possible hypotheses of Θ . The expert defines the family of subsets of interest F from Θ . F contains the focal elements,

named sets A in this work. The expert also defines the subjective mass of probability, m , also called basic probability assignment to each set A. A body of evidence is the pair (F, \mathbf{m}) , \mathbf{m} a vector. The rules for the mass of probability are as follows:

$$m(\emptyset) = 0 \quad (2)$$

$$m(A) \geq 0, \forall A \in \Theta \quad (3)$$

$$\sum_{A \in \Theta} m(A) = 1 \quad (4)$$

The Belief and Plausibility bound the probability of a set A. The Belief of A is the sum of all probability masses of sets B contained in A (5); the Plausibility of A is the sum of all probability masses of sets B that intersects A (6). Therefore, Plausibility is greater than or equal to Belief. If Plausibility equals Belief, it is a probability.

$$Bel(A) = \sum_{B \subseteq A} m(B) \quad (5)$$

$$Pl(A) = \sum_{B \cap A \neq \emptyset} m(B) \quad (6)$$

Hence, from (F, \mathbf{m}) (F, \mathbf{m}, Bel, Pl) can be computed. DST combines evidence from two sources, 1 and 2, $m_1 \otimes m_2(A)$ in conjunctive form. It assumes information is independent. Similarly, to the probability theory $m_1 \otimes m_2(A)$ is the product of mass probabilities of sets whose intersection is A. If the sets do not intersect, then they are disjoint sets, or in other words, they do not agree - they conflict. A normalization factor χ is used to suppress the conflict. Therefore:

$$\chi = 1 / (1 - K), \quad K = \sum_{B \cap C = \emptyset} m_1(B) \cdot m_2(C) \quad (7)$$

$$m_1 \otimes m_2(A) = \chi \sum_{B \cap C = A, A \neq \emptyset} m_1(B) \cdot m_2(C) \quad (8)$$

III. METHOD AND DATA COLLECTION

The main compounds of a compressor chiller are the evaporator, compressor, condenser, expansion valve, and refrigeration fluid. All compounds, plus the interconnection lines and sensors, can damage. At high possibilities of damage, the control system gives chiller pre-alarms or alarms. On the contrary, the evaluation in this work regards identifying possible faults of a chiller working in "normal" conditions, without any chiller pre-alarm. Moreover, the method for the evaluation should identify potential faults without false warnings. False warnings disbelieve the program and are costly.

A chiller's most common minor faults are the following five (i) to (v). They arise from reduced heat exchange in the condenser or the evaporator, small refrigerant leaks, or control and sensor faults. Possible causes of reduction of heat exchange in the condenser (i) are a dusted condenser, fan malfunction in an air-water chiller, and corrosion in the condenser fins. The lack of heat transfer in the water-refrigerant evaporator is due to dirt (ii) or experiencing a reduction in water flow. The reduction of water flow is owing to filled filters, water pump damage, air traps in pipes or equipment, or poor maneuver of valves (iii). A small refrigerant leak usually happens in lines or joints because

of contact between lines or vibration (iv). Finally, control and sensor faults may give parameters values out of range, unexpected chiller behavior, or merely cause no alarm (v).

A constant monitoring online system can help identify those faults. In the experiment, a Modbus plus web system gathers the data about the chiller status and alarms. The DS algorithm is doable to check what might be happening before triggering an alarm or pre-alarm.

A. Method description and algorithm

Of the five prevalent faults, the most common is the reduction of heat transfer in the condenser, reduction of water flow, and refrigerant leakage. It creates three possible graphs of faults concerning expected values:

- High pressure and temperature than expected in the condenser means a reduction of heat transfer in the condenser. The outdoor temperature allows predicting the expected values of pressure and temperature;
- Low evaporator temperature and high compressor discharge relate to leaks of chiller refrigerant. A high level of leakage drops condenser temperature and pressure, and the in-out temperature difference increases;
- In-out water temperature increase generally means a lack of water flow.

Fig. 1 depicts the program algorithm. The program receives a batch data file from each day logged at a time interval. Then, a preprocessing program selects the data in the cooling mode, system working, and compressor on. The program discards the first event of a compressor startup and averages in sequence the data from three timestamps in succession. These operations avoid unnecessary data from transitory shooting and smooth the variations of each parameter.

For this work, the relevant parameters are sensor data, timestamp, inlet temperature (tiA), temperature out (tuA), condenser temperature (tSb), outside air temperature (tAE), condenser pressure (AP), evaporator pressure (bP), compressor discharge temperature (tGP), set point (SEt), compressor on/off (Po), Summer set-point (StF), working (ON/OFF). The first graph use parameters AP and tSb, the second AP, tSb, bP, tiA, tuA, and the third tuA and tiA. AP and tSb depend on tAE, as mentioned before. The SEt and the water flow define the tuA and tiA, which has a minor influence on bP. However, the water flow varies tiA-tuA. Finally, bP depends on tuA.

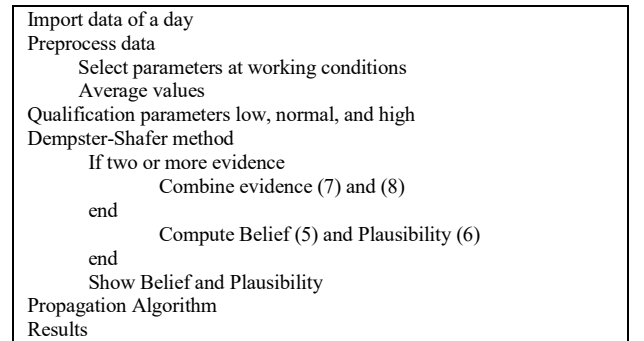


Fig. 1. Algorithm flow-chart

At "Qualification," the program defines the state of each parameter as low, normal, or high. Depending on the graph, the DS method computes Belief and Plausibility or prior combines the pieces of evidence, as per Fig. 1. The DS method pays attention to parameter states other than normal. The mass probability of the DS method depends on the qualification. The normal range of the parameters, μ_n , uses fuzzy triangular functions, presenting the lower value, the most common, and the higher. The ranges for the normal state of the variables are:

$$\mu_n(tSb) = [tAE+9, tAE+12, tAE+15];$$

$\mu_n(AP) = [R(tAE+5), R(tAE+10), R(tAE+15)]$, R a function that defines the condensing pressure depending on the temperature, for a refrigerant R;

$\mu_n(bP) = [R(tuA-22), R(tuA-16), R(tuA-10)]$, which depends on tuA, the water out temperature;

$\mu_n(tiA-tuA) = [3, 5, 7]$; it means that at normal water flow conditions, the difference between the temperature in and out of the chiller has a range of 3 to 7 °C, set for 5 °C.

The experiment evaluates the condenser heat exchange problem, CO, the water flow reduction, WF, and refrigerant leak, RL.

B. Experiment and data acquisition

The chiller refrigerant is the R410A. The chiller is an air-water chiller of 20 kW refrigeration capacity at Eurovent conditions. It has a constant water flow, and the compressor runs on/off mode controlled by the exit water temperature, set at 7°C. Moreover, from 20 °C external temperature, the condenser fan runs at full speed. The plant has served the office premises in Sintra, Portugal, since 2009. It works from 8 am to 8 pm each working day.

The chiller control can log the sensors and alarms data. The chiller control panel links through an RS485 port to the Modem system. The WAN port of the Modem connects an Ethernet cable to the office LAN. The LAN network logs data through the internet in the AERNET database, a database from AERMEC. The local AERNET administrator can access each plant's data and defines the logging parameters. The mentioned plant collects data at each 60 s at a baud rate of 19200 bps.

The data for the experiment runs from June 24 at 11:30 to July 21 at 18:30, 2022. It was a successful period for data collection because it included shallow and high air temperature values. The nearest meteorological station with online data near Sintra is Lisbon. In Lisbon, the colder day was June 24 with a min/max temperature of 15.1/ 23.4 °C, then rising to 26.0/ 39.5 °C on July 8 and further to 23.8/ 40.9 °C on July 13 [12]. Regarding the data collected in Sintra by AERNET during the working period, the minimum was 19 °C on June 24. On July 8 and 13 at working hours, the temperature varied from 29.4 °C to 41 °C and 27.6 °C to 39.2 °C, respectively. The range of observed outside temperatures is wide enough to allow checking the behavior of an HVAC system in cooling mode. According to the afore-mentioned algorithm, the selected data regards working periods, therefore with system parameter on, Summer mode, and compressor on.

C. Basic probability Assignment

Table I shows the mass probabilities for the sets defined by experts. X can be CO, WF, and ER (Excess of Refrigerant).

TABLE I. FAULT CAUSES AND MASS PROBABILITY ASSIGNMENT

| Focal elements and Mass Probability Assignment | | | | | |
|--|----------|--------|--------|--------|---------|
| High | | Normal | | Low | |
| foc | mass | foc | mass | foc | mass |
| X | 0.425+x | X | 0.25+x | X | 0.025+x |
| NF | 0.05- x | NF | 0.4- x | NF | 0.05- x |
| RL | 0.05- x | RL | 0.25-x | RL | 0.425-x |
| SC | 0.25 0.1 | X, NF | 0.05 | SC | 0.25 |
| X, SC | 0.1 | NF, RL | 0.05 | RL, SC | 0.1 |
| X, NF | 0.1 | | | NF, RF | 0.1 |
| NF, SC | 0.05 | | | NF, SC | 0.05 |

Additionally, the possibility of RL is shown in the column depicted as low. NF stands for normal functioning; SC, sensors, or control faults. Suppose a parameter belongs to state high and influences X, then the focal elements and mass probabilities are depicted at the left of Table 1. The most probable focal element is NF for a parameter qualified as normal. The right columns state the parameter qualification as low. The mass probabilities adjust by x up to 0.1 depending on the membership degree of the corresponding fuzzy functions.

The "Propagation Algorithm" increases Belief and Plausibility values based on the recurrence of the diagnosis. It mimics the increase in confidence of the expert when seeing uniformity of results. The focal elements and corresponding mass probabilities can combine depending on the graph.

IV. RESULTS AND DISCUSSION

The normal chiller operation was changed according to the plan on June 24, June 27 to June 29, and July 07. The faults caused were WF by slightly closing the return valve and CO covering about 20% of the condenser with a plastic film. The first was caused on June 24 from 11:30 to 18:55 and on July 07 from 12:10 to 14:20. The condenser cover-up happened from June 27, 15:40 to June 29, 16:45 and additionally on July 07 from 17:05 to 18:45.

Fig. 2 depicts the results on three graphs, a, b, and c, concerning June 28, during afternoon working hours. Graphic 2a is about CO, 2b on evaporator pressure, and 2c on the temperature difference between in and out. The Belief and Plausibility depicted in graphic bars regard the two events with the higher values. On the left, the blue scale shows the percentage of Belief and Plausibility. On the right axis, the orange scale shows temperatures in °C or pressure in bar. Fig. 2a is about the evolution of condenser temperature and pressure (Cond T. – orange line; Cond P. – brown line) that depends on outside air temperature (Air T. – blue line). Likewise, Fig. 2b depicts the Belief and Plausibility of the second graph regarding evaporator Pressure. It shows water temperature (Water T.) and evaporator pressure (Evap P.). Finally, Fig. 2c concerns the third graph, which is about water temperature difference (T. Diff.)

On June 28, the higher values of Belief (B) and Plausibility (P) about CO are 60%-70% (red bars) most of the time during the afternoon.

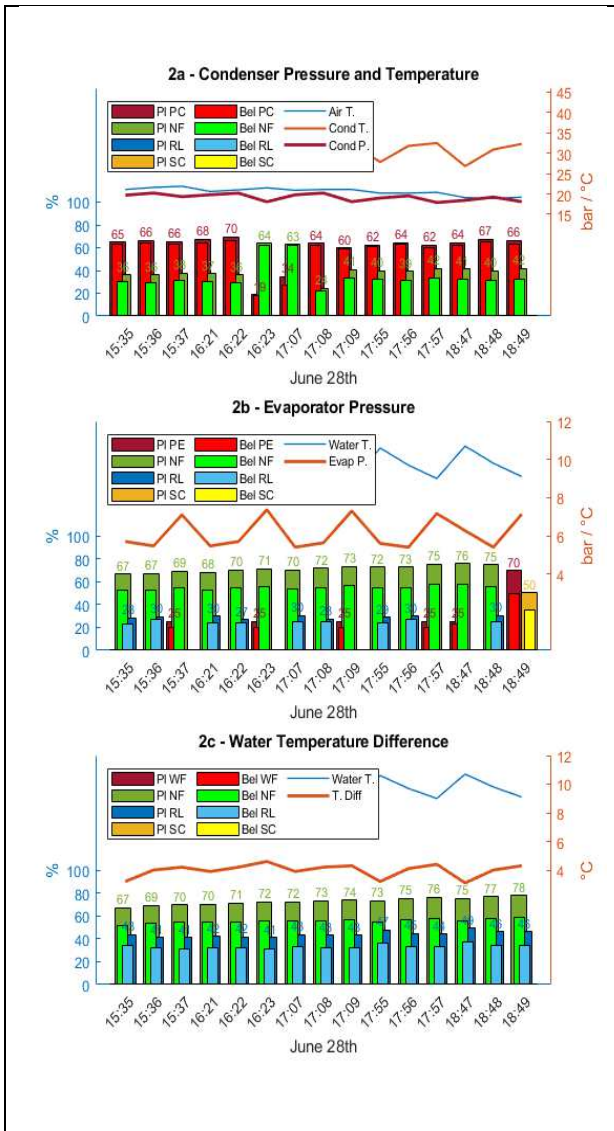


Fig. 2. Parameters, Belief, and Plausibility on June 28 – CO fault

It also shows two hours with normal functioning (NF). In Fig. 2b, the evaporator pressure generally shows NF in a 25-75% B-P range. B-P about RL is the second possible fault. A further check of the installation showed slightly small pressures in the evaporator, which may mean a minor lack of refrigerant over the years.

Finally, in Fig. 2c, the NF is the highest score considering the in-out temperature difference, with B-P 48-78%. Once more, the RL is the second most possible event in Fig. 2c. Analogous behavior is shown in the graphics of all other days due to condenser covering, including July 07.

Fig. 3 has an analogous reading to the previously explained one. Fig. 3 shows the result of WF reduction by closing the return valve on June 24, pm, which stopped by 18:55. Fig. 3a, 3b, and 3c regard CO, evaporator pressure, and temperature difference in and out, as well.

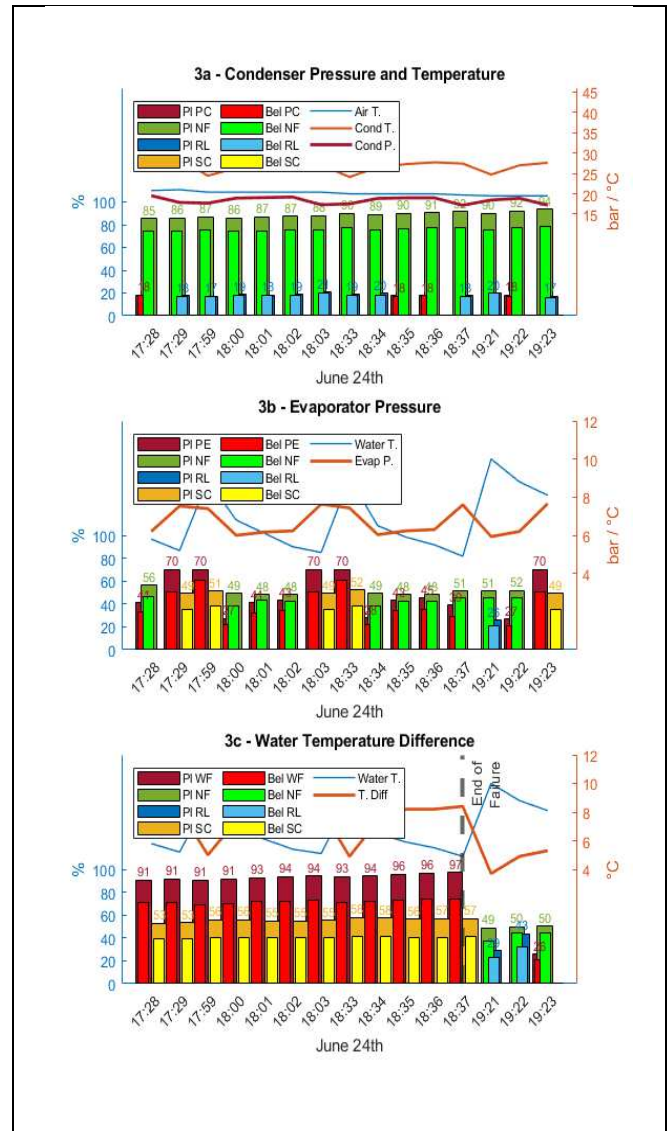


Fig. 3. Parameters, Belief, and Plausibility on June 24 – WF fault

It shows NF in what concerns CO (Fig. 3a). The Plausibility of NF climbed to 97%, and the Belief went close to 70%. Again, some events showed a high Plausibility of PE in the evaporator (Fig. 3b). The high values of B and P (Fig. 3c) were according to the caused fault, showing a WF fault.

On July 07, the valve was less closed, and the algorithm could not identify the problem. The higher values of Belief and Plausibility on NF were in the 50-60% range. The reduction of condenser surface from June 27 to 29 was identified more than 95% of the time.

In all other days, in normal functioning, the program did not give false faults. In these days, NF was the program judgement evaluating B-P is 50-60% range. It is essential not to have many false alarms in HVAC applications, as it asks maintenance teams to go to the site.

V. CONCLUSIONS AND FUTURE WORKS

This work presents the Dempster-Shafer (DS) application to anticipate faults in a chiller of an air-conditioning system. This work aims to identify possible faults before the chiller gives pre-alarms or alarms. The chiller has an on/off control and constant water flow, seeking to maintain the outlet water temperature at 7 °C. The experiments run from June 24 to July 21 in Sintra, Portugal, a period with low and extremely high temperatures for the season. Therefore, the data is a good expression of the conditions a chiller can have in Summer mode. The experiments had the intention to cause a reduction in the condenser heat exchange and water flow. The DS uses expert information to decide whether a fault is occurring. The most likely event for a parameter value was given a mass probability of 40-50%. Other possibilities, such as sensors, control problems, and refrigerant leaks, are possible but with lower mass probabilities.

Moreover, conjunction mass probabilities are also taken into consideration. The experiments program identified more than 95% of the events regarding the reductions of condenser heat exchange. Moreover, it identified the reduction of water flow due to maneuvering a valve near closing. For a valve less closed, the program did not identify the event

Finally, the method generally shows normal functioning on all days with no provoked faults. In normal functioning, no alarms were reported.

The literature review shows DS can merge with Artificial Intelligence to support a decision. In future works, the DS method can apply to other chiller faults. Moreover, it can apply to other types of chillers with different compressors and control methods.

ACKNOWLEDGMENT

The second author thanks the support of UNIDEMI, NOVA School of Science and Technology, by FCT (UIDB/00667/2020).

FUNDING

The authors thank the support of CINAV – Naval Investigation Center of the Naval Academy for the grant to publish this paper.

REFERENCES

- [1] D. Chakraborty, and H. Elzarka, "Early detection of faults in HVAC systems using an XGBoost model with a dynamic threshold", *Energy and Buildings*, 2019, 185, 326–344.
- [2] S.M. Namburu, M.S. Azam, J. Luo, K. Choi, and K.R. Pattipati, "Datadriven modeling, fault diagnosis and optimal sensor selection for HVAC chillers". *IEEE transactions on automation science and engineering*, 2007, 4 (3), 469– 473.
- [3] N. Ahmad and R. Atta, "Cost-effective wireless-controlled motor failure prediction for HVAC system in large buildings using demodulated current signature analysis", *Life Science Journal*, 2014, 11 (10s).
- [4] C. Lo, P. Chan, Y-K. Wong, A.B. Rad and K. Cheung, "Fuzzy-genetic algorithm for automatic fault detection in HVAC systems", *Applied soft computing*, 2007, 7 (2), 554–560
- [5] C. Yang, B. Gunay, Z. Shi and W. Shen, (2020). "Machine learning-based prognostics for central heating and cooling plant equipment health monitoring", *IEEE Transactions on Automation Science and Engineering*, 2020, 18 (1), 346–355.
- [6] A. Gálvez, A. Diez-Oliván, D. Seneviratne, and D. Galar, "Fault detection and rul estimation for railway hvac systems using a hybrid model-based approach", *Sustainability*, 2021, 13 (12), 6828.
- [7] K. Padmanabh, A. Al-Rubaie, J. Davies, S. Clarke and A. Aljasmí, "Fault Prediction in HVAC Chillers by Analysis of Internal System Dynamics", *International Conference on Smart Applications, Communications and Networking (SmartNets)*, 2021, 1–6
- [8] T. Li, Y. Zhao, C. Zhang, J. Luo and X. Zhang, "A knowledge-guided and data-driven method for building HVAC systems fault diagnosis", *Building and Environment*, 2021, 198, 107850
- [9] R. Yager, L. Liping, *Classic Works of the Dempster-Shafer Theory of Belief Functions*, *Studies in Fuzziness and Soft Computing*, Springer Berlin Heidelberg New York, pp. 1-32, 375-403
- [10] R. Yager, "On the Dempster-Shafer framework and new combination rules", *Information sciences*, 1987, 41 (2), 93–137.
- [11] L. A. Zadeh, "A simple view of the Dempster-Shafer theory of evidence and its implication for the rule of combination", *AI magazine*, 1986, 7 (2), 85–85.
- [12] ipma.pt/pt/oclima/monitoriza.dia - accessed July 29, 2022