

**Universidade Federal de Campina Grande - UFCG**  
**Centro de Engenharia Elétrica e Informática - CEEI**  
**Coordenação de Pós-Graduação em Ciência da Computação**

**Modelagem Acústica no Auxílio ao  
Diagnóstico do Funcionamento de  
Motores de Usinas Termoelétricas**

**Adalberto Gomes Teixeira Júnior**

**Joseana Macêdo Fachine Régis de Araújo, DSc.**

**Elmar Uwe Kurt Melcher, DSc.**

**(Orientadores)**

**Campina Grande, Paraíba, Brasil**  
**Julho – 2015**

**Universidade Federal de Campina Grande - UFCG**  
**Centro de Engenharia Elétrica e Informática - CEEI**  
**Coordenação de Pós-Graduação em Ciência da Computação**

# **Modelagem Acústica no Auxílio ao Diagnóstico do Funcionamento de Motores de Usinas Termoelétricas**

**Adalberto Gomes Teixeira Júnior**

Dissertação submetida à Coordenação do Curso de Pós-Graduação em Ciência da Computação da Universidade Federal de Campina Grande - Campus I como parte dos requisitos necessários para obtenção do grau de Mestre em Ciência da Computação.

**Joseana Macêdo Fachine Régis de Araújo, DSc.**

**Elmar Uwe Kurt Melcher, DSc.**

**(Orientadores)**

Área de Concentração: Ciência da Computação  
Linha de Pesquisa: Processamento Digital de Sinais / Inteligência Artificial

**Campina Grande, Paraíba, Brasil**  
**Julho – 2015**

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL DA UFCG

T266m      Teixeira Júnior, Adalberto Gomes.  
Modelagem acústica no auxílio ao diagnóstico do funcionamento de motores de usinas termoeletricas / Adalberto Gomes Teixeira Júnior. – Campina Grande, 2015.  
93 f. : il., color.

Dissertação (Mestrado em Ciência da Computação) – Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática.

Orientação: Profa. DSc. Joseana Macêdo Fachine Régis de Araújo, Prof. DSc. Elmar Uwe Kurt Melcher.

Referências.

1. Sistemas - Modelagem. 2. Processamento Digital de Sinais. 3. Análise Acústica. 4. Motores - Diagnóstico de Falhas. I. Araújo, Joseana Macêdo Fachine Régis de. II. Melcher, Elmar Uwe Kurt. III. Título.

CDU 004.414.23(043)

*"Conhecimento não é o mesmo que sabedoria. A sabedoria está em agir."*

*(Sócrates, em O Caminho do Guerreiro Pacífico, por Dan Millman)*

*Dedico esta pesquisa a todos aqueles que estiveram ao meu lado.  
Em especial, à minha família, pela compreensão e  
amor nos momentos de maior  
aprendizado e reflexão.*



# Agradecimentos

A Deus, por ser o guia de toda minha caminhada, principalmente por hoje compreender tantos questionamentos antes feitos a Ele.

A toda minha família. Primeiramente, a meus pais, que me proporcionaram os maiores ensinamentos sobre a vida, gerando em mim a busca por tentar fazer a diferença. Com ele, as melhores conversas e discussões. Com ela, uma sonhadora, que me mostrou o maior exemplo de fé e força. Minhas irmãs, Jullyana e Jannayna, minhas companhias de todas as horas, mesmo com as diferenças de cada um, estamos sempre crescendo juntos. Agradeço por tanto bem. Que essa união permaneça.

Aos meus professores Joseana Fachine e Elmar Melcher, que me mostraram o caminho da ciência, me questionando e oferecendo as ferramentas para que eu encontrasse as minhas próprias respostas. Em mais uma etapa de minha formação e vida, neles me inspiro como exemplo de mestres e pessoas.

Aos colegas do Laboratório BELADIA, que foram necessários para a realização da pesquisa, sempre presentes e pelos esforços durante as visitas à UTE Borborema S.A.. Em especial, à professora Silvana Costa, pelas longas conversas e discussões tão essenciais durante todo o desenvolvimento da pesquisa.

A todos da Borborema Energética S.A. e Maracanaú Geradora de Energia S.A., representados pelo Coordenador do Programa de P&D das referidas UTE, Gustavo de Brito Espínola, por viabilizar a realização do Projeto REPARAI, no qual a pesquisa está inserida.

A todos aqueles que o ROC 202 me proporcionou, em especial Barreto Couto e Sávio de França, companheiros durante esta fase da minha vida.

À CAPES e à COPIN, por tornarem possível a pesquisa.

A todos que me acompanharam durante o desenvolvimento da pesquisa.

# Resumo

O som gerado por motores em funcionamento contém informações sobre seu estado e condições, tornando-se uma fonte importante para a avaliação de seu funcionamento sem a necessidade de intervenção no equipamento. A análise do estado do equipamento muitas vezes é realizada por diagnóstico humano, a partir da experiência vivenciada no ambiente ruidoso de operação. Como o funcionamento dos motores é regido por um processo periódico, o sinal de áudio gerado segue um padrão bem definido, possibilitando, assim, a avaliação de seu estado de funcionamento por meio desse sinal. Dentro deste contexto, a pesquisa ora descrita trata da modelagem do sinal acústico gerado por motores em usinas termoeletricas, aplicando técnicas de processamento digital de sinais e inteligência artificial, com o intuito de auxiliar o diagnóstico de falhas, minimizando a presença humana no ambiente de uma sala de motores. A técnica utilizada baseia-se no estudo do funcionamento dos equipamentos e dos sinais acústicos por eles gerados por esses, para a extração de características representativas do sinal, em diferentes domínios, combinadas a métodos de aprendizagem de máquinas para a construção de um multiclassificador, responsável pela avaliação do estado de funcionamento desses motores. Para a avaliação da eficácia do método proposto, foram utilizados sinais extraídos de motores da Usina Termoeletrica Borborema Energética S.A., no âmbito do projeto REPARAI (*REPair over AiR using Artificial Intelligence*, código ANEEL PD-6471-0002/2012). Ao final do estudo, o método proposto demonstrou acurácia próxima a 100%. A abordagem proposta caracterizou-se, portanto, como eficiente para o diagnóstico de falhas, principalmente por não ser um método invasivo, não exigindo, portanto, o contato direto do avaliador humano com o motor em funcionamento.

**Palavras-chaves:** Processamento Digital de Sinais. Análise Acústica. Aprendizagem de Máquina. Diagnóstico de Falhas em Motores de uma UTE. Abordagem híbrida (Caracterização e Classificação).



# Abstract

The sound generated by an engine during operation contains information about its conditions, becoming an important source of information to evaluate its status without requiring intervention in equipment. The fault diagnosis of the engine usually is performed by a human, based on his experience in a noisy environment. As the operation of the engine is a periodic procedure, the generated signal follows a well-defined pattern, allowing the evaluation of its operating conditions. On this context, this research deals with modeling the acoustic signal generated by engines in power plants, using techniques from digital signal processing and artificial intelligence, with the purpose of assisting the fault diagnosis, minimizing the human presence at the engine room. The technique applied is based on the study of engines operation and the acoustic signal generated by them, extracting signal representative characteristics in different domains, combined with machine learning methods, to build a multi-classifier to evaluate the engines status. Signals extracted from engines of Borborema Energética S.A. power plant, during the REPARAI Project (REPair over AiR using Artificial Intelligence), ANEEL PD-6471-0002/2012, were used in the experiments. In this research, the method proposed has demonstrated an accuracy rate of nearly 100%. The approach has proved itself to be efficient to fault diagnosis, mainly by not being an invasive method and not requiring human direct contact with the engine.

**Keywords:** *Digital Signal Processing. Acoustic Emission. Fault Diagnosis in Power Plant Engines. Learning Machine. Multi-classifiers System.*

# Lista de Siglas e Abreviações

CGTEE	Companhia de Geração Térmica de Energia Elétrica
DML	Decomposição da Média Local
FFNN	Redes Neurais <i>Feedforward</i>
FFT	<i>Fourier Fast Transform</i> (Transformada Rápida de Fourier)
FI	Frequência Instantânea
FP	Função Produto
IA	Inteligência Artificial
IMF	<i>Intrinsic Mode Functions</i> (Funções de Modo Intrínseco)
LPC	<i>Linear Predictive Coding</i> (Codificação pro Predição Linear)
MLP	<i>Multi-layer Perceptron</i> (Perceptron de Múltiplas Camadas)
MSE	<i>Mean Squared Error</i> (Erro Médio Quadrático)
MTM	<i>Multi-Taper Method</i>
NLARX	<i>Non-Linear Autoregressive Exogenous</i>
NR	Norma Regulamentadora
PCA	<i>Principal Component Analysis</i> (Análise de Componentes Principais)
PDS	Processamento Digital de Sinais
P&D	Pesquisa e Desenvolvimento
RBF	<i>Radial Basis Function</i> (Função Radial Base)
RMS	<i>Root Mean Square</i> (Valor Médio Quadrático)
RNA	<i>Artificial Neural Networks</i> (Rede Neural Artificial)
SVM	<i>Support Vector Machine</i> (Máquinas de Vetores de Suporte)
SMC	Sistema Multiclassificador

TWP	Transformada <i>Wavelet Packet</i>
QV	Quantizador Vetorial
UTE	Usina Termoelétrica
UTENF	Usina Termoelétrica Norte Fluminense

# Lista de Figuras

Figura 1. Exemplo de sala de máquinas de uma UTE.....	2
Figura 2. Exemplo de planta de uma usina termoelétrica. ....	4
Figura 3. Combustão do diesel em motor rotativo de 4 tempos. ....	5
Figura 4. Planta da sala de máquinas de uma UTE.....	6
Figura 5. Diagrama em Blocos da Fase de Treinamento de um Sistema de Reconhecimento de Padrões.....	25
Figura 6. Diagrama em Blocos da Fase de Classificação de um Sistema de Reconhecimento de Padrões.....	26
Figura 7. Organização modular de um SMC. ....	29
Figura 8. Organização paralela de um SMC.....	29
Figura 9. Sistema de Diagnóstico de Motor com Multiclassificação.....	32
Figura 10. Diagrama em Blocos da Estratégia de Classificação Aplicada.....	38
Figura 11. Boxplot do desempenho do Multiclassificador no domínio 2. ....	46
Figura 12. Boxplot do desempenho do Multiclassificador no domínio híbrido. ....	47
Figura 13. Boxplot das diferenças de médias das classes “Normal” e “Alerta” para os parâmetros do domínio da Frequência.....	82
Figura 14. Boxplot das diferenças de médias das classes “Normal” e “Alerta” para os parâmetros do domínio do Tempo. ....	83
Figura 15. Boxplot das diferenças de médias das classes “Normal” e “Alerta” para os parâmetros do domínio Híbrido.....	83
Figura 16. Boxplot das médias das classes “Normal” e “Alerta” para os parâmetros do domínio da Frequência.....	85
Figura 17. Boxplot das médias das classes “Normal” e “Alerta” para os parâmetros do domínio do Tempo.....	85
Figura 18. Boxplot das médias das classes “Normal” e “Alerta” para os parâmetros do domínio Híbrido.....	86
Figura 19. Boxplot das médias de acerto nos testes.....	89

# Lista de Quadros

Quadro 1. Limites de tolerância para ruído intermitente de acordo com a NR 15. ....	3
Quadro 2. Resumo das pesquisas abordadas.....	19

# Lista de Tabelas

Tabela 1. Propriedade dos sinais por ponto de captura para o treinamento e teste.....	35
Tabela 2. Descrição dos Sinais “Alerta” aplicados.....	36
Tabela 3. Teste de Wilcoxon para avaliação dos Intervalos de Confiança (IC) das diferenças maiores que 0,5 e da eficácia de cada método avaliado (Metodologia 1). ....	41
Tabela 4. Testes de disjunção dos conjuntos “Normal” e “Alerta” de cada método avaliado (Metodologia 2).....	41
Tabela 5. Média de acerto para os testes por sistema analisado. ....	42
Tabela 6. Teste de Wilcoxon pareado para avaliação do desempenho do Multiclassificador. ....	42
Tabela 7. Média de acerto para os testes do Multiclassificador para cada um dos vetores aplicados.....	43
Tabela 8. Teste de Wilcoxon para avaliação do desempenho dos vetores de características. ....	43
Tabela 9. Desempenho do Multiclassificador no domínio 2.....	45
Tabela 10. Desempenho do Multiclassificador híbrido.....	45
Tabela 11. Média de acertos para a validação no C1-D1. (continua) .....	59
Tabela 12. Desempenho de classificação do C2-D1. (continua) .....	61
Tabela 13. Desempenho de classificação do MULT-D1. (continua).....	63
Tabela 14. Desempenho de classificação do C1-D2. (continua) .....	65
Tabela 15. Desempenho de classificação do C2-D2. (continua) .....	67
Tabela 16. Desempenho de classificação do MULT-D2. (continua).....	69
Tabela 17. Desempenho de classificação do C1-HÍB. (continua) .....	71
Tabela 18. Desempenho de classificação do C2-HÍB. (continua) .....	73
Tabela 19. Desempenho de classificação do MULT-HÍB. (continua).....	75
Tabela 20. Testes de normalidade das diferenças entre os resultados das classes “Normal” e “Alerta” para cada sistema avaliado. ....	80
Tabela 21. Intervalos de confiança das diferenças entre os resultados das classes “Normal” e “Alerta” para cada sistema avaliado. ....	81
Tabela 22. Teste de Wilcoxon para avaliação dos IC das diferenças são maiores que 0,5 e eficácia de cada método avaliado. ....	81
Tabela 23. Testes de normalidade das médias dos conjuntos “Normal” e “Alerta” de cada método avaliado.....	84
Tabela 24. Testes de disjunção dos conjuntos “Normal” e “Alerta” de cada método. ....	84

Tabela 25. Testes de normalidade para média de acerto cada sistema avaliado.....	87
Tabela 26. Média e IC de acerto para os testes por sistema analisado. ....	88
Tabela 27. Teste de Wilcoxon pareado para avaliação do desempenho do Multiclassificador. ...	88
Tabela 28. Teste de Wilcoxon para avaliação do desempenho dos vetores de características. ...	90
Tabela 29. Desempenho por classe para MULT-D1. ....	90
Tabela 31. Desempenho por classe para MULT-D2. ....	91
Tabela 32. Desempenho por classe para MULT-HÍB. ....	91

# Sumário

Capítulo 1 .....	1
Considerações Iniciais .....	1
1.1 Introdução .....	1
1.2 Motivação e Justificativa para a Pesquisa .....	2
1.3 Identificação do Problema .....	5
1.4 Objeto da Pesquisa .....	7
1.5 Objetivos da Pesquisa .....	7
1.5.1 Objetivo Geral .....	8
1.5.2 Objetivos Específicos .....	8
1.6 Organização do Documento .....	9
Capítulo 2 .....	10
Pesquisas Correlatas .....	10
2.1 Extração de Características para Diagnóstico de Falhas em Motores .....	10
2.2 Métodos de Classificação para Diagnóstico de Falhas em Motores .....	15
2.3 Discussão .....	23
Capítulo 3 .....	24
Fundamentação Teórica .....	24
3.1 Sistema para Diagnóstico Acústico de Motores .....	24
3.1.1 Treinamento .....	24
3.1.2 Classificação .....	25
3.2 Características Acústicas dos motores .....	27
3.3 Métodos de Classificação .....	27
3.3.1 Classificador 1 .....	27
3.3.2 Classificador 2 .....	27
3.3.3 Sistemas Multiclassificadores .....	28



3.4 Discussão .....	30
Capítulo 4 .....	31
Abordagem para o Diagnóstico de Motores por Análise Acústica .....	31
4.1 Abordagem Proposta .....	31
4.2 Treinamento .....	32
4.2.1 Pré-processamento .....	32
4.2.2 Extração de Características .....	32
4.2.3 Geração dos Padrões de Referência .....	33
4.3 Classificação .....	33
4.4 Discussão .....	33
Capítulo 5 .....	34
Apresentação e Análise dos Resultados.....	34
5.1 Metodologia .....	34
5.2 Resultados .....	39
5.3 Discussão .....	48
Capítulo 6 .....	49
Considerações Finais e Sugestões para Pesquisas Futuras .....	49
6.1 Considerações Finais .....	49
6.2 Contribuições da Pesquisa .....	50
6.3 Sugestões para Pesquisas Futuras .....	51
Referências Bibliográficas .....	52
Apêndice A - Análise da Combinação de Classificador e Vetor de Características .....	58
Apêndice B - Análise Estatística .....	77
Anexo A - Descrição Geral do Projeto REPARAI .....	92

# Capítulo 1

## Considerações Iniciais

Neste capítulo, será apresentada uma visão geral da abordagem proposta para a Modelagem Acústica no Auxílio ao Diagnóstico do Funcionamento de Motores de Usinas Termoelétricas, além da motivação, justificativa e objetivos da pesquisa.

### 1.1 Introdução

No processo industrial, o monitoramento dos equipamentos se tornou um elemento importante para a redução de custos de manutenção. Os métodos para diagnósticos e prognósticos de falhas evoluem na busca por parâmetros que possam indicar problemas, principalmente de forma antecipada, em máquinas e motores, evitando a interrupção da produção e os seus efeitos.

Durante o funcionamento, alguns motores emitem um sinal de áudio bastante representativo das suas condições de funcionamento. Portanto, o uso de técnicas de processamento digital de sinais de áudio pode se mostrar útil no monitoramento das condições de funcionamento desses motores.

As informações acústicas capturadas podem ser utilizadas como uma ferramenta adicional para a chamada manutenção preditiva, cujo intuito é possibilitar a identificação de falhas em fases incipientes. Por conseguinte, há uma melhoria do desempenho e, normalmente, custos são reduzidos, possibilitando mais tempo de utilização do equipamento e redução de impactos que podem ser causados em função da consumação da falha (LEVITT, 2011; MOBLEY, 2002).

Em uma usina termoelétrica (UTE), o processo de geração de energia é baseado na utilização de motores, que realizam a combustão de compostos químicos. Com isso, torna-se útil que essas empresas busquem métodos de

manutenção preditiva que possam diagnosticar problemas nos equipamentos.

## **1.2 Motivação e Justificativa para a Pesquisa**

A sala de máquinas de uma UTE, local onde os motores estão instalados (conforme apresentado na Figura 1), é isolada por motivos de segurança, considerando que há combustão de líquidos inflamáveis, temperatura elevada e altos níveis de ruído sonoro produzido pelos equipamentos. Os sons presentes nessa sala acarretam um limite para permanência do operador humano no local. Os níveis de emissão sonora podem prejudicar não somente o aparelho auditivo humano, mas também o sistema endócrino (COSTA, 1989-90). Essas emissões sonoras podem ser consideradas nocivas diante de uma permanência prolongada nesse tipo de ambiente (PALMA, 1999).

**Figura 1. Exemplo de sala de máquinas de uma UTE.**



**Fonte: REPARAI (2013).**

O Ministério do Trabalho, a partir da Norma Regulamentadora (NR 15), define um limite de permanência em ambientes com ruídos contínuos e intermitentes, conforme apresentado no Quadro 1. Esses ruídos são bastante representativos das emissões sonoras produzidas na sala de máquinas de uma UTE, na qual são gerados ruídos da ordem de 110 dB (NISKODE, HOOVER, 1977). Este fato reforça, portanto, a viabilidade da permanência de um operador somente por um curto período de tempo.

Na sala de máquinas de uma UTE, em função do limite de permanência do operador no ambiente, torna-se necessário que o controle dos equipamentos seja realizado em um ambiente externo (sala de controle), no qual se avalia o estado dos motores por meio de sistemas que extraem informações de todos os equipamentos. Na Figura 2 é apresentado um exemplo da estrutura de uma usina termoelétrica, com destaque para as salas de máquinas e de controle.

**Quadro 1. Limites de tolerância para ruído intermitente de acordo com a NR 15.**

<b>Nível de Ruído dB (A)</b>	<b>Máxima Exposição Diária Permitida</b>
85	8 horas
86	7 horas
87	6 horas
88	5 horas
89	4 horas e 30 minutos
90	4 horas
91	3 horas e 30 minutos
92	3 horas
93	2 horas e 40 minutos
94	2 horas e 15 minutos
95	2 horas
96	1 hora e 45 minutos
98	1 hora e 15 minutos
100	1 hora
102	45 minutos
104	35 minutos
105	30 minutos
106	25 minutos
108	20 minutos
110	15 minutos
102	45 minutos
104	35 minutos
105	30 minutos
106	25 minutos
108	20 minutos
110	15 minutos
112	10 minutos
114	8 minutos
115	7 minutos

**Fonte: Adaptado de BRASIL (2011).**

**Figura 2. Exemplo de planta de uma usina termoeletrica.**



**Fonte: Adaptado de BORBOREMA ENERGÉTICA S.A. (2008).**

Aliado a esse fato, a possibilidade de dispor de uma técnica que possibilite a geração de diagnósticos e prognósticos acerca do funcionamento dos motores de uma UTE, se mostra relevante por viabilizar redução de custos de manutenção e operação, a partir de uma indicação de possível falha que poderia se agravar com a continuidade do uso do equipamento sem o devido reparo.

Neste contexto, o projeto de pesquisa e desenvolvimento (P&D) REPARAI (*REPair over AiR using Artificial Intelligence*) foi idealizado e, por conseguinte, desenvolvido e integralizado pela equipe do laboratório BELADIA (Laboratório de Pesquisas em BioEnergia, Arquiteturas Dedicadas e Inteligência Artificial) da Unidade Acadêmica de Sistemas e Computação da Universidade Federal de Campina Grande (UFCG), durante 12 meses, código ANEEL PD-6471-0002/2012. Este contemplou na sua origem e transcurso, além das atividades de desenvolvimento, duas pesquisas macro: De doutorado e, essa presente, de mestrado ora descrita. O objetivo global do projeto BELADIA/REPARAI consistiu no desenvolvimento de um protótipo de instrumento para diagnóstico acústico automático, de falhas mecânicas em motores, embarcando técnicas de IA. O projeto é resultante de parceria entre a UTE Borborema Energética S. A., UTE Maracanaú Geradora de Energia S. A. e o BELADIA. Uma descrição geral do projeto REPARAI é apresentada no Anexo A deste documento.


Diante do exposto, buscou-se desenvolver, no âmbito desta pesquisa, uma abordagem metodológica para análise acústica dos sinais provenientes dos motores, aplicando técnicas de Processamento Digital de Sinais (PDS) e Inteligência Artificial (IA) para auxílio ao diagnóstico de falhas nos equipamentos.

A partir do levantamento bibliográfico sobre o tema, no âmbito do projeto, observou-se que a maioria das pesquisas se baseia na análise do sinal de vibração para a realização do diagnóstico dos motores. Aliado a isso, poucas pesquisas têm como foco o ambiente de uma usina termoeletrica. Esses fatos reforçaram, portanto, a motivação para o estudo proposto.

### 1.3 Identificação do Problema

Motores de combustão interna são exemplos de motores utilizados em termoeletricas. Na Figura 3, está ilustrado o processo de combustão de um motor a diesel de quatro tempos, que consiste em: (1) admissão, (2) compressão, (3) combustão/explosão e (4) ejeção/expulsão. Nesse processo, ocorrem duas rotações do eixo (MORAN et al., 2011), cujo funcionamento caracteriza-se como um processo periódico. Os sinais de áudio emitidos seguem, portanto, um determinado padrão de repetição. Logo, a partir da análise do sinal acústico com comportamento periódico, é possível obter informações sobre a atividade e condições de funcionamento dos motores (TANDON, CHOUDHURY, 1999).

**Figura 3. Combustão do diesel em motor rotativo de 4 tempos.**



Fonte: Adaptado de BENNET (2010).




No entanto, embora o som proveniente dos motores esteja associado a inúmeras características e as suas condições de funcionamento, poucos sistemas de controle fazem uso desse recurso para monitoramento dos equipamentos (WANG et al., 2014; REPARAI, 2013; KABIRI, MAKINEJAD, 2011).

No mesmo ambiente, encontram-se diversos outros sinais de áudio gerados pelos demais equipamentos ali presentes, como, por exemplo, o sistema de ventilação. Na Figura 4, é ilustrada a planta da sala de máquinas com alguns dos equipamentos presentes nesse ambiente.

Usualmente, as informações obtidas a partir das emissões dos sinais de áudio são avaliadas apenas por humanos, que se baseiam nas percepções auditiva e vibratória captadas pelo operador em contato direto com os motores, que, em função de sua experiência, pode caracterizar o sinal percebido. Esta forma de monitoramento evidencia a dependência da permanência do operador em um ambiente que pode se tornar nocivo, em função do tempo necessário para a conclusão de sua avaliação.

**Figura 4. Planta da sala de máquinas de uma UTE.**



**Fonte: Baseado em BORBOREMA ENERGÉTICA S.A. (2008).**

O sinal sonoro emitido pelas máquinas pode ser utilizado, portanto, para a extração de características, a fim de possibilitar o diagnóstico remoto do funcionamento dessas máquinas (realizado por meio da avaliação de anormalidades que possam ocorrer, considerando um padrão previamente definido para o funcionamento do equipamento). Assim, torna-se possível detectar a ocorrência de falhas em uma fase preliminar, evitando maior desgaste do equipamento e viabilizando a redução de custos provenientes de possíveis reparos. Além disso, a partir do monitoramento, torna-se desnecessária a permanência prolongada do operador no ambiente. A avaliação sonora remota poderá servir também para detecção de falhas para o diagnóstico complementar a outros sistemas de detecção de falhas baseados em outras medidas, como temperatura e pressão.

Porém, é essencial que os parâmetros extraídos do sinal de áudio, a serem mensurados, não sofram interferência significativa do áudio emitido por outros equipamentos ou ruídos esporádicos, como por exemplo, vozes de operadores, sons emitidos por uma empilhadeira ou mudança esporádica das características acústicas do ambiente, como por exemplo, som proveniente da abertura de uma porta.

#### **1.4 Objeto da Pesquisa**

No contexto da pesquisa, busca-se, para o monitoramento e o diagnóstico do funcionamento dos motores, a construção de um sistema baseado na análise acústica. O sistema utiliza técnicas de processamento digital de sinais para a análise das características extraídas dos sinais de áudio e técnicas de inteligência artificial para a classificação dos resultados, os quais possibilitarão auxílio na identificação de indícios de mau funcionamento e possíveis falhas em motores de uma UTE.

#### **1.5 Objetivos da Pesquisa**

Nesta seção serão discutidos os objetivos do estudo. Inicialmente, será apresentado o propósito principal da pesquisa. Em seguida, serão abordados os objetivos específicos a serem tratados no desenvolvimento da pesquisa.



### **1.5.1 Objetivo Geral**

O principal objetivo desta pesquisa de mestrado<sup>1</sup> foi desenvolver um sistema para o auxílio ao diagnóstico das condições de funcionamento dos motores de usinas termoelétricas, de forma não invasiva, por meio da modelagem acústica, a partir do uso de técnicas de processamento digital de sinais.

### **1.5.2 Objetivos Específicos**

A fim de atingir o objetivo geral supracitado, os seguintes objetivos específicos se fizeram necessários:

1. Realizar o levantamento do estado da arte acerca do diagnóstico de motores, avaliando os parâmetros acústicos extraídos e as técnicas de inteligência artificial aplicadas;
2. Construir uma base de dados composta por sinais capturados no ambiente de uma sala de máquinas de uma UTE e, também, outros tipos de sinais presentes no ambiente, a exemplo do sistema de ventilação, ruídos gerados por outros equipamentos, como uma empilhadeira, que possam interferir nos resultados e, caso necessário, avaliar o emprego de técnicas de pré-processamento para minimização dos efeitos desses sinais e melhoramento do sinal de áudio proveniente dos motores. Para tanto, a UTE Borborema Energética S.A. (projeto REPARAI) foi o ambiente de pesquisa para o estudo de caso a ser realizado no trabalho;
3. Definir características a serem extraídas dos sinais de áudio provenientes dos motores, que proporcionem informações representativas do estado e condições de funcionamento dos equipamentos;
4. Definir técnicas de classificação e a forma de diagnóstico, a partir das características extraídas;

---

<sup>1</sup> Pesquisa realizada conjuntamente dentro do projeto REPARAI (2013), duração de 12 meses, com demais pesquisadores e alunos.

5. Avaliar o desempenho de um sistema multiclassificador para diagnóstico acústico do estado dos motores.

## **1.6 Organização do Documento**

Este documento está dividido em seis capítulos. O primeiro capítulo, em questão, contém uma introdução sobre o ambiente da UTE, bem como os objetivos da pesquisa.

No segundo capítulo, são apresentadas pesquisas relacionadas ao tema proposto, as quais tratam da análise acústica dos sinais emitidos pelos motores, em especial em usinas termoelétricas. As pesquisas analisadas tratam também de sistemas e métodos para análise e diagnóstico de motores.

No terceiro capítulo, é descrita a fundamentação teórica sobre extração de características de um sinal acústico e métodos de classificação aplicados à pesquisa.

O quarto capítulo trata do sistema proposto, com a descrição da metodologia utilizada para treinamento e classificação, a ser aplicada no diagnóstico do funcionamento dos motores.

No quinto capítulo, os resultados obtidos são apresentados e discutidos.

Ao final, no sexto capítulo, são enunciadas as considerações finais, as contribuições e as sugestões para pesquisas futuras.

# Capítulo 2

## Pesquisas Correlatas

Neste capítulo, é apresentado o levantamento bibliográfico acerca do estado da arte para o diagnóstico de falhas em motores, abordando características extraídas e métodos de classificação aplicados.

A seguir, são tratadas diversas pesquisas que propõem métodos para diagnóstico de motores utilizando, em sua maioria, características extraídas do sinal acústico ou de vibração, bem como várias abordagens para classificação. Porém, poucas tratam do diagnóstico de motores de usinas termoelétricas.

Inicialmente, serão descritas as pesquisas que tratam da extração das características e, posteriormente, as que abordam as técnicas de classificação aplicadas à modelagem dos sinais acústicos provenientes dos motores.

### **2.1 Extração de Características para Diagnóstico de Falhas em Motores**

Kimura e Mizutani (1991) utilizaram o sinal sonoro emitido por um motor de navio para monitorar as suas condições de funcionamento, a partir da análise espectral. Foram observadas as frequências do sinal extraído a cada ciclo formado por 2 rotações do motor. O sinal obtido a cada ciclo foi particionado em 40 partes, cada uma com duração de 200 ms. Para cada parte foi obtido o espectro do sinal. Os espectros foram então particionados em intervalos de 100 Hz até o limite de 20 kHz. Ao final, as médias da energia por intervalo, para todos os espectros foram calculadas e somadas por intervalo, gerando um vetor de 200 valores. A partir dos vetores extraídos dos sinais do motor, em estado normal, foi gerado um padrão representativo e calculado a distância entre esse padrão e os vetores, baseado na distância de Mahalanobis. Para as distâncias observadas, foi calculada uma distribuição

Normal  $p$ -variada. Na etapa de classificação, a distância entre o vetor de teste e o padrão previamente armazenado era obtida e comparada com a distribuição, caso houvesse uma pequena variação em relação ao centro da distribuição, o sinal era considerado normal, caso contrário, havia indicação alguma falha presente. O método proposto demonstrou êxito na detecção das falhas avaliadas.

Kimura, Nakai e Mizutani (1994) utilizaram o sinal de vibração na avaliação do funcionamento de motores a diesel, seguindo os mesmos fundamentos da proposta anterior, gerando um padrão espectral do sinal para o estado normal, com cálculo da distância de Mahalanobis e análise estatística. Dois experimentos foram realizados, um com o motor a 500 RPM e outro a 670 RPM, demonstrando eficácia do método. Por fim, foi realizada uma comparação com os resultados obtidos para o sinal de áudio e o sinal de vibração do motor. Ambos proporcionaram valores bem similares para as anormalidades apresentadas, embora o nível de variação do sinal de áudio tenha sido menor que o de vibração. O método demonstrou ser eficiente com ambos os sinais indicados, mas o sinal de vibração apresentou ter alcance mais limitado devido à distância entre o ponto de captura e a falha. A pesquisa também indicou que o som gerado pelo motor conseguiu ser útil para a detecção de falhas no motor, mesmo com a presença de ruído no ambiente durante o funcionamento.

Em outro estudo abordaram-se as características extraídas do rolamento do motor, conforme apresentado em Konstantin-Hansen (2003), com foco nos componentes de frequência conhecidos como *Fundamental Train Frequency*, *Ball Pass Frequency Out Race* e o dobro dessa componente, as quais são medidas a partir do espectro do sinal de vibração, utilizando uma análise do envelope espectral, após aplicação da transformada rápida de Fourier (*Fast Fourier Transform* - FFT) ao sinal. Não foi realizado diagnóstico automático, apenas aplicados em dois estudos de caso que avaliaram a variação dessas medidas na presença de falhas nos motores, as quais demonstraram mudanças, certificando que essas podem ser utilizadas no diagnóstico de falhas.

Ocak e Loparo (2004) avaliaram as mesmas medidas da pesquisa anterior, também extraídas do sinal de vibração, desenvolvendo também, algoritmos para calcular o tempo de estimação do diagnóstico. O estudo também apresentou um levantamento das frequências influenciadas por determinadas falhas. Os algoritmos avaliaram as possíveis falhas a partir dos picos observados no espectro, utilizando-os para estimação das frequências dos defeitos no motor e calculando a probabilidade baseada nos picos já observados para frequência menores. O algoritmo e análise pelos picos do espectro proporcionaram verificar a mudança nas condições durante o diagnóstico dos casos avaliados, indicando assim a dependência direta entre a variação das componentes espectrais apresentadas e as condições do motor.

Em Almeida (2007), foram extraídas do sinal de vibração do motor, medidas estatísticas como Fator de Defeito, Fator de Crista, Valor Médio Quadrático (*Root Mean Square* - RMS), Pico Máximo, Fator de Forma, Fator de Impulso e Distribuição de Curtose. Foi aplicada a técnica de agrupamento (clusterização) para avaliação da variação dessas medidas em relação às mudanças na carga, rotações e lubrificante do equipamento. Observou-se que as medidas RMS, Pico, Fator de defeito e Curtose foram mais sensíveis à carga e rotação do motor, as quais foram selecionadas para serem aplicadas ao método de reconhecimento automático a partir da formação de grupos (*clusters*) para as falhas verificadas. A técnica aplicada proporcionou desempenho esperado, pois conseguiu definir os *clusters* de diferentes falhas.

O estudo de Guangpu e Hongxia (2006) visou avaliar o áudio proveniente do motor de um automóvel em diferentes pontos de captura e para diferentes velocidades. Os espectros dos sinais foram comparados e observou-se que todos tinham alta correlação com as frequências específicas de atividade do motor, mas com valores distintos em cada ponto, indicando a dependência do sinal em relação ao ponto de captura.

Chen et al. (2009) avaliaram o sinal de vibração do motor, aplicando o método de Decomposição de Média Local (DML) com análise do Envelope

Espectral. A partir do método, foram calculadas as componentes de frequência do sinal. No teste aplicado, as componentes já eram previamente conhecidas em função das características do rolamento do equipamento, sendo confirmadas pelo experimento com sinal normal e com falhas simuladas. Dessa forma, a técnica proposta demonstrou capaz de detectar falhas nos motores.

Souza (2011), em sua pesquisa, com foco em motores a diesel aplicou a Transformada *Wavelet Packet* (TWP) (GOEBEL, 2009), e no diagnóstico avaliou os coeficientes de energia em intervalos de frequência, aplicando a técnica de análise de componentes principais (PCA). A partir da PCA, foi calculado um polinômio de resposta a partir dos dados dos motores em condições normais. Nos experimentos foram comparados sinais de diferentes tipos de motores e rotações, incluindo casos com falhas inseridas nos motores, concluindo que equipamentos com características construtivas diferentes devem ser avaliados por padrões diferentes. A técnica de diagnóstico, que combinou TWP e PCA, conseguiu diferenciar as condições em um grupo de motores para algumas faixas de frequência, mas para outras não obteve êxito.

Wang et al. (2013) buscaram o reconhecimento de falhas em motores pela taxa de crescimento da energia do sinal de vibração do motor durante sua partida. A taxa de crescimento foi obtida para frequências específicas a partir da aplicação da Transformada de Fourier de Curta Duração para pequenos intervalos. Em cada intervalo foi calculada a taxa de crescimento, sendo gerado um vetor com os valores da energia para cada um dos intervalos. Para classificação do sinal, foi aplicada uma Rede Neural Artificial (RNA), do tipo *Radial Basis Functional* (RBF) (HAYKIN, 2008; RUSSEL, NORVIG, 2010). No treinamento, diversos tipos de sinais foram previamente classificados e alguns testes foram realizados com diferentes acelerações e falhas. Os resultados observados obtiveram acurácia maior do que características comparadas extraídas diretamente do domínio do tempo, como a curtose e entropia. Mas a técnica apresentou problemas com algumas falhas para diferentes condições de funcionamento, por considerar somente

este momento na análise.

Chamay, Oh e Kim (2013) aplicaram a técnica de codificação por predição linear (LPC), com extração de vetor de características composto por coeficientes LPC e coeficientes cepstrais, bastante utilizadas no processamento de voz (RABINER, SCHAFER, 2010), para avaliação do sinal de vibração do motor. Padrões para diferentes condições do motor foram criados utilizando a matriz de covariância e comparados pela distância de Mahalanobis, sendo observadas diferenças entre esses. O método proporcionou 100% de acurácia nos casos avaliados, melhor que os resultados obtidos com o uso da distância Euclidiana, que apresentou 96%, normalmente utilizada no reconhecimento de padrões.

A seguir, são apresentadas pesquisas que realizaram um levantamento do estado da arte sobre o diagnóstico de motores.

Tandon e Choudury (1999) apresentaram o estado da arte de métodos de medição por sinais de vibração e sinais acústicos no diagnóstico de rolamentos. Medidas de nível global, no domínio do tempo, tais como RMS e medição regular dos Fatores de Crista foram utilizadas para avaliar o sinal de vibração. No domínio da frequência, foi realizada uma análise do envelope espectral, a partir da qual foram avaliadas as variações do espectro em função de mudanças das frequências durante uma falha no equipamento. Sobre a análise acústica, os autores abordaram a detecção de falhas a partir da quantidade de picos e a amplitude do pico máximo obtido no sinal. Esse valor de amplitude pode indicar possíveis problemas, caso seja maior que o esperado. O trabalho demonstra a vantagem das características acústicas sobre as de vibração, pois, a partir dessas, é possível avaliar o crescimento da falha por meio do sinal.

Em Patidar e Soni (2013), as medidas citadas na pesquisa anterior continuaram a ser aplicadas no diagnóstico pela análise do sinal de vibração. Novas medidas também são apresentadas, como Fator de Impulso e Curtose, extraídas no domínio do tempo; além das extraídas no domínio tempo-frequência com o sinal *wavelet* e seus derivados. No trabalho também são

elencadas as frequências de rolamento, que são características inerentes aos motores. Ou seja, indicando que a detecção de falhas em motores pode ser realizadas por diferentes domínios.

Após a avaliação das características aplicadas, a seguir serão apresentadas pesquisas com foco nos métodos de classificação utilizados no diagnóstico de falhas em motores.

## **2.2 Métodos de Classificação para Diagnóstico de Falhas em Motores**

Kimura, Nakai e Kishimoto (1998) aplicaram uma RNA para averiguar a condição de anormalidade em um motor a diesel. Para a construção do classificador, foi utilizado um operador humano que realizou a classificação prévia dos sinais (aprendizagem supervisionada). Dentre as anormalidades consideradas, foram utilizados o vazamento de gás a partir do tubo de escape e a combustão anormal. Os dados do espectro de radiação dos sinais provenientes do motor foram inseridos na entrada da RNA para classificação. A taxa de reconhecimento correto foi de, aproximadamente, 90%. Em se tratando do funcionamento anormal, a taxa de acerto foi similar àquela associada ao caso normal. De acordo com os autores, em alguns ensaios não foram obtidos bons resultados para poucos casos de testes.

Moschioni e Vania (2004) realizaram um estudo das medidas de vibração, de áudio e químicas em uma usina termoelétrica, criando uma rede de medidas multissensorial. Após captura de dados durante dias, foi avaliada a correlação entre as medidas. A primeira medida verificada foi o coeficiente de relação linear, cujos valores obtidos foram próximos a 1, mas o autor observou que essa é apenas uma medida preliminar e indicou que uma RNA ou relação não linear apresentou resultados mais eficientes.

Algumas pesquisas utilizaram informações dos motores diferentes do sinal de vibração e áudio para realizar o diagnóstico. Como apresentou Brzowska, Brzowski e Nowakowski (2005), em que foi aplicada uma RNA, com o intuito de modelar os processos de funcionamento dos cilindros de um motor a diesel. Os parâmetros utilizados no modelo para determinar o



comportamento do motor foram: velocidade de rotação do motor, temperatura, quantidade de combustível, ângulo de ignição, pressão e grau de circulação de gases. Os resultados obtidos com RNA se aproximaram dos resultados reais observados.

Deng, Stobart e Maass (2009) também aplicaram o modelo de uma RNA para diagnóstico de motores e utilizaram como entrada do classificador os resultados das emissões atmosféricas geradas durante o funcionamento dos geradores. No estudo, uma nova arquitetura de rede neural foi apresentada, a *Non-linear Autoregressive Exogenous* (NLARX), sendo baseada no modelo *Multi-layer Perceptron* (MLP), que se fundamenta na relação não linear entre as entradas e saídas da RNA. Para simular as falhas, foram utilizados sinais aleatórios, tais como perturbações à operação do motor. De acordo com os autores, o modelo apresentou ótimo desempenho, apenas com um resultado inferior a 90%, chegando a casos com 97%, além de apresentar pequeno tempo de resposta.

Linhare et al. (2009) desenvolveram um sistema para a detecção e o diagnóstico de falhas em motores de indução destinado à manutenção dos motores elétricos de uma Companhia de Geração Térmica de Energia Elétrica (CGTEE). A partir do estudo das falhas mais comuns, tais como a quebra de barras e anéis do rotor (danos do sistema de rolamentos e curto-circuito no rolamento do estator), o sistema realizou uma análise da assinatura da corrente. Os protótipos desenvolvidos são móveis e utilizam computadores portáteis, com aplicativos, tais como banco de dados com informações sobre os motores e os sinais de corrente e rotação emitidos durante o funcionamento e também o módulo de análise, que identifica desvios que possam apontar falhas. A partir dos métodos de Welch, Periodograma e MTM (*Multi-Taper Method*) (RABINER, SCHAFFER, 2010), foi obtido o espectro dos sinais de corrente do motor, identificando os componentes espectrais relacionados às falhas de forma otimizada. Após a extração dos componentes, foi realizada uma análise histórica e aplicado o algoritmo de diagnóstico, que utiliza técnicas de inteligência artificial e métodos estatísticos para avaliar as condições do motor. Por fim, o método

demonstrou obter o diagnóstico de forma fácil e em tempo real. Como o método não exige a abertura do motor para diagnóstico, os resultados têm garantido melhoria na manutenção preventiva e preditiva pelo método não invasivo de aquisição e análise de dados.

Em conjunto com uma RNA, outro classificador não informado foi aplicado no modelo proposto por Biondi Neto et al. (2009), que propuseram um sistema inteligente para a detecção e o diagnóstico de falhas em geradores de energia elétrica de usinas termoelétricas. Os autores se basearam na premissa de que todos os dispositivos de proteção dos geradores operam de forma correta e que os alarmes enviados pelos sensores também o são, logo, uma ocorrência de falha será configurada por um padrão particular dos estados desse conjunto de alarmes acionados. A ativação de um ou mais sensores pode indicar uma falha em um gerador. Na pesquisa, foram utilizados 4 modelos de geradores semelhantes, 27 falhas foram detectadas e mapeadas por gerador. O sistema foi aplicado na Usina Termoelétrica Norte Fluminense (UTENF) e os resultados apresentados atenderam os requisitos para a detecção de falhas dos geradores.

Li (2011) apresentou um método de avaliação de falhas utilizando autoregressão para extrair vetores do espectro do sinal de vibração, reduzindo a dimensão dos dados para 20 autovetores. Para classificá-los, foi aplicada uma RNA do tipo RBF. Os testes aplicados, além do padrão normal, também avaliaram dois tipos de falhas: falha de rolamento interno e externo, todos apresentando acurácia superior a 90% e taxa de erro menor que 7,5%.

Kabiri e Makinejad (2011) propuseram uma técnica para o monitoramento de condição e detecção de falhas em motores a partir da emissão acústica, empregando a transformada *wavelet*. Esta técnica foi aplicada à análise de falhas no sistema de ignição de automóvel, especificamente na geração de faíscas, utilizando amostras de som coletadas em oficinas de reparo. Por este motivo, nos sinais capturados há ruídos e interferências. Os pesquisadores em questão apontaram o tratamento do ruído presente como sendo a maior dificuldade encontrada na pesquisa,

sendo necessária a aplicação de uma etapa de pré-processamento. Características do domínio do tempo foram extraídas para análise, sendo estas: Energia, RMS, Curtose, Assimetria, Marse (medida da superfície sobre a curva), Fator de Crista, Taxa de Cruzamento por Zero, a contagem dos Mínimos e Máximos Locais do *frame* (quadro) em análise. A técnica de PCA foi empregada para a avaliação das características e seleção das mais representativas. Na fase de treinamento, 10% dos dados foram selecionados, o restante foi usado na fase de teste. Foram avaliados 150 registros das emissões acústicas para modelos similares de automotores (marca Kia Motors). O método apresentou acurácia e precisão superiores a 70%.

A pesquisa de Wang et al. (2014) propôs uma combinação de Máquinas de Vetores de Suporte (*Support Vector Machines - SVM*) com características extraídas no domínio tempo-frequência, baseado na Transformada de Hilbert-Huang, a partir das Funções de Modo Intrínsecas (*Intrinsic Mode Functions - IMF*). Os vetores de características são formados pelos momentos de energia de cada IMF e os coeficientes de correlação entre elas. O sinal acústico aplicado nos testes foi proveniente de um motor de automóvel, tanto em condições normais como apresentando falhas. No pré-processamento do sinal, foi realizada uma filtragem de sinais acústicos provenientes de outras partes do carro.

Li et al. (2015) utilizou a aproximação do sinal de vibração nas condições normais do motor a uma distribuição normal. Para tomada de decisão do estado do motor, foi calculada a distorção entre o sinal obtido em tempo real e o padrão normal. Esse valor foi, então, comparado com limiares calculados na fase de treinamento. Quanto aos métodos de classificação, o trabalho ainda observou o uso de RNA com diversas arquiteturas, como *feedforward* (FFNN) e RBF, além de sistemas utilizando lógica *fuzzy* e SVM. A técnica baseada na combinação de uma rede RBF e um modelo de autoregressão proporcionou uma taxa de acerto superior a 90%.

Nas pesquisas correlatas apresentadas, diversos parâmetros foram extraídos dos sinais – tanto no domínio da frequência como no domínio do

tempo – demonstrando que as características de ambos os domínios têm representatividade na caracterização do funcionamento dos motores.

Quanto às técnicas de classificação, a maior parte da bibliografia revisada utilizou uma rede neural artificial na construção do classificador. A principal dificuldade apontada nos trabalhos reside no fato de que não há como simular ou obter todas as possíveis falhas esperadas em um motor. Aliado a este fato, cada técnica baseia-se em alguma característica que proporciona bom desempenho para problemas específicos, mas não se mostra tão eficiente para outros.

Vale ressaltar, que deve ser considerado o fato de o problema modelado tratar de uma aplicação em um ambiente não controlado, pelo fato da possibilidade de não haver uma restrição quanto às atividades na sala de máquinas, que podem gerar ruídos não inerentes ao ambiente, o que dificulta a classificação em casos específicos. É importante destacar também, que poucos trabalhos fizeram uso de um multiclassificador, ou seja, não utilizaram mais de uma técnica para a modelagem e a classificação dos padrões representativos do funcionamento dos motores.

No Quadro 2, são apresentadas todas as pesquisas discutidas neste capítulo, com apresentação de um breve resumo, tipo de sinal utilizado no método, as características avaliadas com o respectivo domínio, o método de classificação e o resultado obtido.

**Quadro 2. Resumo das pesquisas abordadas. (continua)**

<b>Pesquisa</b>	<b>Sinal</b>	<b>Domínio</b>	<b>Características</b>	<b>Método de Classificação</b>	<b>Resultado</b>
<b>Pesquisas com foco nas características</b>					
Kimura, R. e Mizutani, H. (1991)	Áudio	Frequência	Energia por Intervalos de Frequência	Distância com o padrão normal, aplicado a uma distribuição Normal	Demonstrou êxito nos testes executados.

**Quadro 2. Resumo das pesquisas abordadas. (continuação)**

<b>Pesquisa</b>	<b>Sinal</b>	<b>Domínio</b>	<b>Características</b>	<b>Método de Classificação</b>	<b>Resultado</b>
Kimura, R., Nakai, N. e Mizutani, H. (1994)	Vibração e Áudio	Frequência	Energia por Intervalos de Frequência	Distância com o padrão normal, aplicado a uma distribuição Normal	Ambos os sinais demonstraram eficiência, mas o sinal de vibração apresentou alcance limitado.
Konstantin-Hansen, H. (2003)	Vibração	Frequência	Análise do Envelope Espectral	---	Foi observada a variação nessas medidas na presença de falhas nos motores, caracterizando o estado do motor.
Ocak, H. e Loparo, K. A. (2004)	Vibração	Frequência	Análise Espectral, com foco dos picos presentes no espectro	Análise estatística para diagnóstico utilizando as variações dos picos observados no espectro	Algoritmos se mostraram eficientes para cálculo e diagnóstico dos estudos de caso apresentados.
Guangpu, L. G. L. e Hongxia, P. H. P. (2006)	Áudio	Frequência	Espectro do sinal	---	Observou a relação entre os pontos de captura, com maior correlação nas frequências do motor.
Almeida, F. R. do V. (2007)	Vibração nos rolamentos	Tempo	Fator de Defeito, Fator de Crista, RMS, Pico, Fator de Forma, Fator de Impulso e Distribuição de Curtose	Clusterização	Constatou a relação direta entre as medidas estatísticas do sinal de vibração com a mudança no funcionamento do motor.
Chen et al. (2009)	Vibração	Tempo-Frequência	Componentes de Frequência do sinal, Função do Produto (FP)	Decomposição de Média Local + Envelope Espectral	Os resultados coincidiram com os esperados tanto para os sinais normais, quanto com falhas.

**Quadro 2. Resumo das pesquisas abordadas. (continuação)**

<b>Pesquisa</b>	<b>Sinal</b>	<b>Domínio</b>	<b>Características</b>	<b>Método de Classificação</b>	<b>Resultado</b>
Souza, G. F. de. (2011)	Vibração	Tempo-Frequência (TWP)	Níveis de energia são calculados em cada um dos pontos obtidos pela TWP	PCA	Conseguiu observar padrões para motores do mesmo tipo e obteve sucesso no diagnóstico para grupo de motores, enquanto para outros não.
Wang, Z. et al. (2013)	Vibração	Tempo-Frequência	Taxa de crescimento do sinal em intervalos de frequências	RNA RBF	Mais eficiente que medidas do domínio do tempo, mas apresenta problemas com falhas do tipo desbalanceamento e desalinhamento.
Chamay, M., Oh, S. e Kim, Y. (2013)	Vibração	Tempo	Coefficientes LPC/Cepstrais	Cálculo da distância de Mahalanobis	100% de acurácia nos resultados e melhor desempenho que distância Euclidiana (96%).
<b>Pesquisas com foco no levantamento do estado da arte</b>					
Tandon, N., e Choudhury, A. (1999)	Vibração e Áudio	Tempo e Frequência	Vibração: Valor RMS, Crista e Envelope Espectral; Áudio: Picos de amplitude	---	Apresenta melhor resultado quando ao sinal de áudio, pois é possível avaliar o crescimento da falha.
Patidar, S. e Soni, P. K. (2013)	Vibração	Tempo, Frequência e Tempo-Frequência	Tempo: RMS, Curtose, Fator de Impacto, etc. Frequência: Envelope espectral, etc	RNA (RBF), Lógica Fuzzy, SVM	Visão geral sobre as técnicas utilizadas no diagnóstico de motores.
Kimura, R., Nakai, N, e Kishimoto, T. (1998)	Áudio	Frequência	Intervalos de frequência	RNA	Taxa de reconhecimento em torno de 80-90%, na maioria dos experimentos.

**Quadro 2. Resumo das pesquisas abordadas. (continuação)**

<b>Pesquisa</b>	<b>Sinal</b>	<b>Domínio</b>	<b>Características</b>	<b>Método de Classificação</b>	<b>Resultado</b>
<b>Pesquisas com foco nos métodos de classificação</b>					
Moschioni, G, Vania, A. (2004)	Vibração, Áudio e Medidas químicas	Frequência	Medidas de correlação	---	A análise demonstrou a alta correlação entre as diversas medidas avaliadas.
Brzozowska, L., Brzozowski, K. e Nowakowski, J. (2005)	---	---	Velocidade de rotação, dose de combustível, ângulo de ignição avançada, temperatura, pressão e recirculação de gás exaustiva	RNA	Os resultados calculados se aproximaram dos resultados reais obtidos nos testes.
Deng, J., Stobart, R. e Maass, B. (2009)	---	---	Medidas dos compostos químicos como NOx	RNA	O modelo apresentou ótimo desempenho e um tempo de resposta reduzido.
Linhare, A. et al. (2009)	----	Frequência	Corrente do motor	Análise histórica vinculada a um banco de dados	O método demonstrou obter o diagnóstico de forma fácil e em tempo real.
Biondi Neto, L. et al. (2009)	---	---	27 parâmetros distintos (não especificados)	RNA + Método não especificado	Os resultados apresentados atenderam aos requisitos para a detecção de falhas dos geradores.
Li, M. (2011)	Vibração	Frequência	Coefficientes de autoregressão do espectro	RNA RBF	Acurácia acima de 90%, taxa de erro de aproximadamente 7,5%.
Kabiri, P. e Makinejad, A. (2011)	Áudio	Tempo-Frequência	Energia, Valor RMS, Curtose, Assimetria, Marse, Taxa de Cruzamento por Zero, Crista	PCA	Acurácia e precisão superior a 70%.

**Quadro 2. Resumo das pesquisas abordadas. (continuação)**

<b>Pesquisa</b>	<b>Sinal</b>	<b>Domínio</b>	<b>Características</b>	<b>Método de Classificação</b>	<b>Resultado</b>
Wang, Y. S. et al. (2014)	Áudio	Tempo-Frequência	Coeficientes de correlação e momentos de energia da IMF	SVM	Acurácia acima de 90% para todos os casos avaliados com validação cruzada.
Li, W. et al. (2014)	Vibração	---	Características estatísticas, aproximação de distribuição Normal	Cálculo da distância	Acurácia próxima de 100%, obtendo melhor resultado comparando com SVM e RNA.
<b>Pesquisa Proposta</b>					
(REPARAI, 2013); Teixeira Jr., A. G. (2015)	Áudio	Tempo, Frequência e Híbrido	Tempo: RMS, Pico Máximo, Crista, Curtose, Coeficientes LPC; Frequência: Picos, Vales e Diferença de Amplitude entre eles	Quantização Vetorial, Rede Neural Artificial e Multiclassificação	Sistema Multiclassificador no domínio do tempo apresentou performance superior às demais combinações de método de classificação e domínios.

### 2.3 Discussão

O objetivo deste capítulo foi abordar pesquisas correlatas ao tema em questão. Para maioria das pesquisas, foi observada a aplicação do sinal de vibração e sinal acústico para a manutenção preditiva dos motores. Quanto às medidas aplicadas, foram extraídas características nos domínios do tempo e da frequência. Em se tratando dos métodos de classificação, sistemas com RNA, SVM e PCA se mostraram como as principais técnicas utilizadas.

No próximo capítulo, será apresentada a fundamentação teórica relacionada ao contexto da pesquisa. Para tanto, serão definidos conceitos de processamento de sinais para a extração das características acústicas dos sinais dos motores e de inteligência artificial, aplicados à classificação e ao diagnóstico dos motores.



# Capítulo 3

## Fundamentação Teórica

Neste capítulo, serão apresentados os conceitos relevantes à abordagem proposta para o diagnóstico de motores de uma UTE.

### 3.1 Sistema para Diagnóstico Acústico de Motores

O objetivo da abordagem proposta para o diagnóstico de motores é avaliar o estado de funcionamento do equipamento durante o seu funcionamento, utilizando como entrada o sinal sonoro emitido pelo motor. Pela análise do sinal capturado é possível observar a presença de falhas ou mudanças nas condições de funcionamento dos motores, bem como, a influência de acessórios auxiliares (ventiladores de resfriamento, bombas, etc.) que estiverem ao alcance do mecanismo de captura do sinal.

O problema em questão está inserido, portanto, no contexto do reconhecimento de padrões, dividido em duas fases: treinamento e classificação. Na fase de treinamento, são definidos padrões de referência, extraídos do sinal acústico do motor, capazes de caracterizar o estado do motor. Na fase de classificação, serão obtidos os padrões de teste e, a partir de uma lógica de decisão, é fornecida uma resposta binária, capaz de classificar o sinal como "Normal", se o motor está em condições normais de funcionamento, ou "Alerta", se há alguma mudança em suas condições de normalidade (REPARAI, 2013).

A seguir, será apresentada uma descrição detalhada das fases de treinamento e classificação de um sistema de reconhecimento de padrões, considerando as técnicas a serem aplicadas na abordagem proposta.

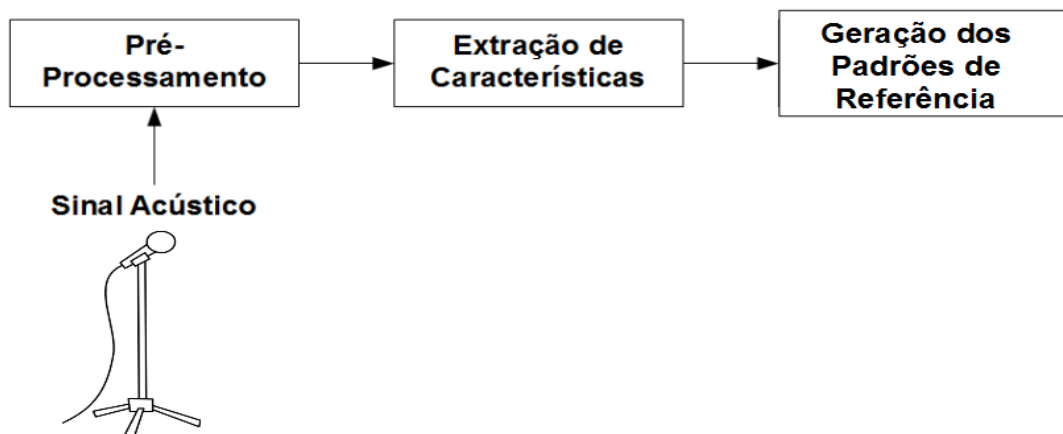
#### 3.1.1 Treinamento

A fase de treinamento busca gerar os padrões de referência a serem

aplicados na fase de classificação, cujas etapas são descritas a seguir (Figura 5) (RABINER, SCHAFER, 2010).

- **Pré-Processamento:** nesta etapa, após a captura do sinal, é realizada a segmentação desse para análise a curtos intervalos de tempo. O sinal acústico é particionado em *frames* (quadros), de forma a garantir as condições de estacionariedade. Em seguida é feito o janelamento, no qual uma função é aplicada ao quadro para minimizar os efeitos adversos provocados pela segmentação abrupta provenientes da divisão em quadros. Janelas de Hamming e Hanning são usualmente utilizadas para janelamento do sinal (RABINER, SCHAFER, 2010).
- **Extração das Características:** para cada *frame*, é extraído um vetor de características representativo do estado do motor.
- **Geração dos Padrões de Referência:** nesta etapa, a partir das características extraídas, são construídos os padrões representativos do estado do motor, os quais serão utilizados na etapa de classificação.

**Figura 5. Diagrama em Blocos da Fase de Treinamento de um Sistema de Reconhecimento de Padrões.**



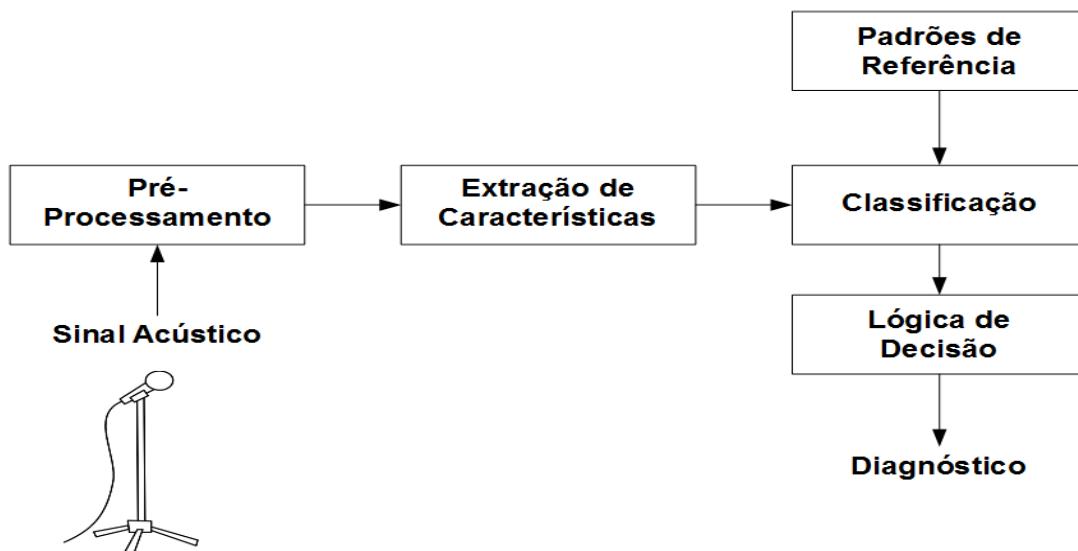
### 3.1.2 Classificação

A fase de classificação (Figura 6) se inicia pela aquisição do sinal, seguida da extração das características acústicas, as quais são aplicadas a um classificador, para uma tomada de decisão acerca do diagnóstico do motor.

As etapas da classificação são apresentadas a seguir (RABINER, SCHAFER, 2010).

- **Pré-processamento:** a mesma metodologia utilizada no pré-processamento da fase de treinamento, é utilizada nesta fase. São gerados, portanto, um conjunto de *frames*.
- **Extração de Características:** a exemplo da fase de treinamento, para cada *frame* é obtido um vetor de características.
- **Classificação:** a partir do classificador utilizado na fase de treinamento, os padrões de teste são comparados com os padrões de referência e, por meio de uma lógica de decisão, tem-se a classificação do sinal acústico de entrada.
- **Lógica de Decisão:** nesta etapa é aplicada uma regra que avalia o resultado obtido na saída do classificador e toma uma decisão acerca do diagnóstico do motor.

**Figura 6. Diagrama em Blocos da Fase de Classificação de um Sistema de Reconhecimento de Padrões.**



A seguir, serão apresentadas as características acústicas e os classificadores investigados na pesquisa em questão.

### **3.2 Características Acústicas dos motores**

O propósito desta pesquisa é avaliar a representatividade de medidas acústicas extraídas nos domínios do tempo e da frequência para o diagnóstico do estado do motor de uma UTE (Pesquisas BELADIA/REPARAI).

A partir das pesquisas correlatas descritas no Capítulo 2, algumas medidas foram selecionadas e investigadas em uma análise prévia do seu comportamento, na representação dos estados dos motores da UTE. Características de domínios diferentes foram selecionadas.

### **3.3 Métodos de Classificação**

Para escolha dos métodos de classificação, alguns aspectos relevantes acerca das características a serem utilizadas devem ser considerados.

Inicialmente, há disponibilidade de características extraídas a partir de sinais reais sem falhas, sinais com falhas reais e com falhas simuladas. Assim, pode-se utilizar uma abordagem supervisionada para construção do classificador.

Dois métodos iniciais foram selecionados para análise, a partir dos estudos apresentados nas pesquisas correlatas, a saber: Classificador 1 e Classificador 2.

Com o objetivo de melhorar o desempenho do classificador, foi proposta uma abordagem de multiclassificação, combinando os dois classificadores.

#### **3.3.1 Classificador 1**

O método de classificação 1 avalia a relação linear entre as características extraídas do sinal acústico do motor.

#### **3.3.2 Classificador 2**

O método de classificação 2 investiga a relação não linear entre as características extraídas do sinal acústico do motor.

### **3.3.3 Sistemas Multiclassificadores**

Com o aumento de sistemas complexos, buscam-se novas soluções para melhorar também o diagnóstico. Embora a quantidade de técnicas de classificação tenha crescido, uma nova abordagem busca a combinação de classificadores individuais (FUMERA, ROLI, 2005), chamada de Sistema Multiclassificador (SMC).

Dessa forma, busca-se encontrar padrões distintos e complementares, melhorando, assim, os resultados esperados, a partir da combinação dos chamados classificadores base.

Um dos pontos negativos dessa técnica é o custo computacional da etapa de treinamento, pois será realizado um treinamento para cada um dos classificadores base (SANTOS, 2008; PARADEDA, 2007).

Um SMC é formado pelos classificadores base acoplados a um módulo de combinação. Nele é definida a metodologia de decisão para o sistema.

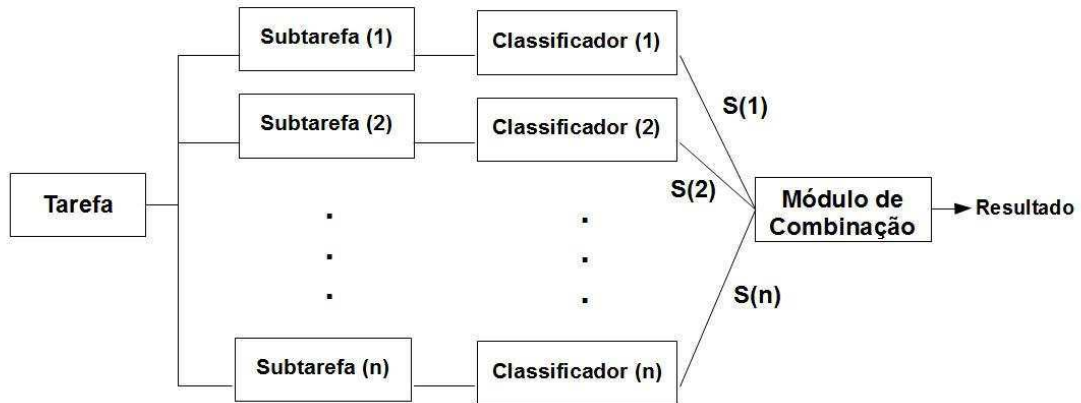
Para que um SMC seja considerado eficiente, é importante que os classificadores base sejam diversificados quanto aos seus algoritmos. Isso pode ser constatado pela diferença dos erros obtidos entre eles, para um mesmo conjunto de dados treinados e verificados.

Existem dois tipos de organização dos componentes para um multiclassificador: Modular ou Paralela. A primeira representa a divisão de uma tarefa em diversas subtarefas para cada um dos especialistas/classificadores, ou seja, cada um é parte da tarefa principal, como demonstrado na Figura 7. A segunda representa um comportamento redundante, todos os especialistas realizam a mesma tarefa, apenas cada um com sua lógica, como apresentado na Figura 8.

Outra classificação para os tipos de SMC refere-se aos tipos de componentes, podendo ser: homogêneos ou heterogêneos. O homogêneo utiliza apenas um algoritmo de aprendizado de máquina, mas varia, por exemplo, quanto à amostragem de dados para cada um deles, ou, no caso de RNA, a taxa de aprendizado em cada uma. No caso do heterogêneo, busca-se

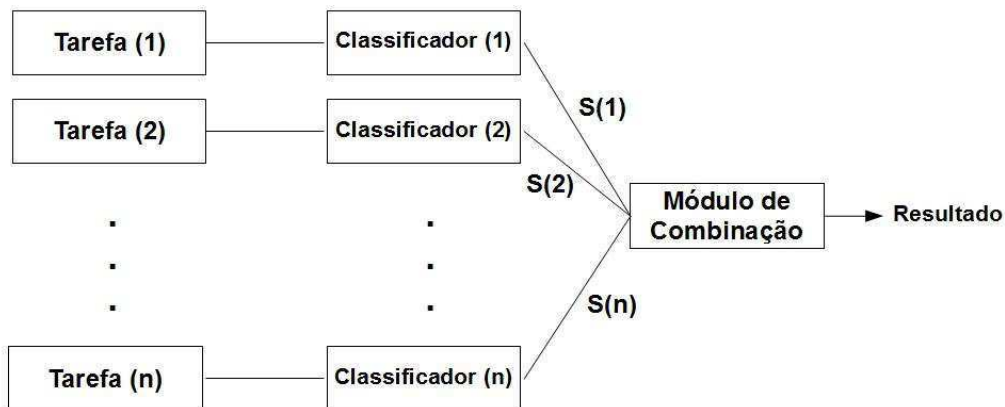
combinar diferentes modelos de classificadores, como por exemplo, combinar uma SVM e uma RNA, sendo treinadas com os mesmos dados (SANTOS, 2008; PARADEDA, 2007).

**Figura 7. Organização modular de um SMC.**



Fonte: Adaptado de PARADEDA (2007).

**Figura 8. Organização paralela de um SMC.**



Fonte: Adaptado de PARADEDA (2007).

Quanto às regras de combinação, os métodos se baseiam em combinação ou em seleção. O primeiro pode ser do tipo:

- **Combinação linear:** apenas uma relação linear entre os resultados dos classificadores é aplicada, como a soma, média ou mediana;

- **Combinação não linear:** mais complexo que os lineares, buscam estratégias como voto majoritário ou *ranking*;
- **Estatísticas:** aplicam combinações estatísticas ou probabilidades aos resultados dos classificadores.

Os métodos de seleção, também conhecidos como dinâmicos, utilizam apenas um dos classificadores base para a tomada de decisão. A regra de combinação apenas é responsável por selecionar qual dos classificadores será o escolhido para realizar a classificação.

No contexto de diagnóstico de motores, busca-se modelar um sistema multiclassificador, combinando diferentes técnicas de classificação, com o objetivo de melhorar o desempenho na classificação.

### **3.4 Discussão**

O objetivo deste capítulo foi apresentar os conceitos relevantes à modelagem da abordagem proposta. Observou-se que por ser um problema de reconhecimento de padrões, duas etapas são necessárias: treinamento e classificação. O primeiro consiste na geração dos padrões que representam os estados dos motores, a partir dos vetores de características extraídos dos sinais analisados. O segundo, a classificação, baseia-se na avaliação vetor de características do sinal de entrada, em relação aos padrões armazenados no treinamento.

Foram definidas as medidas acústicas de dois domínios que possibilitam diferenciar comportamentos distintos para diferentes estados do motor.

Em seguida, foram abordados métodos de classificação: Classificador 1, que busca representar a análise linear entre as diferentes características; Classificador 2, que considera a combinação não linear entre essas. A abordagem proposta utiliza um Sistema Multiclassificador, cujo objetivo é combinar diferentes classificadores, para melhorar a acurácia da classificação do sistema.

No capítulo seguinte, será descrita a abordagem proposta.

# Capítulo 4

## Abordagem para o Diagnóstico de Motores por Análise Acústica

Neste capítulo, será descrita a abordagem proposta para o diagnóstico acústico de motores de uma UTE, a qual se baseia em um sistema multiclassificador, com características extraídas nos domínios do tempo e da frequência. Devido a questões de confidencialidade, relacionadas aos projeto e pesquisas nos quais esta pesquisa está inserida (REPARAI - *REPair over AiR using Artificial Intelligence*, código ANEEL PD-6471-0002/2012), algumas informações não serão apresentadas. Entretanto, a omissão dessas no documento não inviabilizará a descrição e validação da abordagem proposta.

### 4.1 Abordagem Proposta


Conforme descrito nos capítulos anteriores, existem diversos métodos para diagnóstico acústico de motores. E, na busca por melhor desempenho e classificação em tempo real, foi modelado um sistema baseado na abordagem de multiclassificação supervisionada (Figura 9), o qual estruturou-se no escopo do sistema desenvolvido para o projeto REPARAI (REPARAI, 2013).

O SMC é heterogêneo paralelo, o qual combina duas técnicas já reconhecidas no âmbito de uma classificação baseado em diagnóstico acústico, a primeira com foco na relação linear entre as características extraídas e, a segunda, cujo propósito é a busca pela relação não linear entre as informações capturadas do sinal.

Por se tratar de uma tarefa de reconhecimento de padrões, conforme apresentado no Capítulo 3, a seguir serão descritas as fases de treinamento e de classificação da abordagem proposta.



Figura 9. Sistema de Diagnóstico de Motor com Multiclassificação.



## 4.2 Treinamento

Esta etapa consiste das seguintes sub-etapas: aquisição do sinal, pré-processamento, extração de características e construção dos padrões de referência, descritas a seguir.

### 4.2.1 Pré-processamento

O sinal capturado é processado e subdividido em *frames* de tamanho fixo, seguido do janelamento a partir de uma janela retangular. A janela retangular foi aplicada por ser mais adequada à identificação de impactos em frequências específicas (MATHIAS, OLIVEIRA, MEDEIROS, 2014). Tal característica da janela retangular se mostra adequada, visto que possíveis falhas nos motores são caracterizadas por variações em frequências específicas do sinal.

### 4.2.2 Extração de Características

Para cada *frame*, é extraído um vetor de características com representatividade das condições de funcionamento do motor.

### **4.2.3 Geração dos Padrões de Referência**

Nesta etapa, foram utilizados dois classificadores base independentes para construção dos padrões de referência.

### **4.3 Classificação**

A etapa de classificação é responsável pelo diagnóstico das condições de funcionamento do motor. Nesta etapa, após a aquisição do sinal de teste, seguida do pré-processamento e extração de características, conforme descrito na fase de treinamento, é realizada a classificação do referido sinal de teste de entrada.

Um conjunto de características extraído de um sinal acústico de testes é avaliado pelos dois classificadores. Uma descrição mais aprofundada da lógica de decisão não poderá ser apresentada, devido às questões de confidencialidade do projeto REPARAI, no qual está inserida a pesquisa.

### **4.4 Discussão**

Neste capítulo, foi apresentado o método de multiclassificação proposto, que busca unir fatores observados em estudos prévios que utilizam dois classificadores base para representação das características dos motores. Essa combinação busca realizar a classificação de forma adequada aos propósitos da pesquisa, para que o diagnóstico possa ser realizado em tempo real e de forma acurada.

O SMC proposto é heterogêneo paralelo, pois depende dos resultados obtidos dos dois classificadores para um dado vetor de características.

A etapa de treinamento ocorre de forma independente para os dois classificadores. Na fase de classificação, é aplicada uma lógica de decisão, considerando a relação linear e não linear das características.

No Capítulo 5, são apresentados e discutidos os resultados obtidos com o uso da abordagem proposta.

# Capítulo 5

## Apresentação e Análise dos Resultados

Neste capítulo, serão registrados os experimentos realizados e seus respectivos resultados, obtidos a partir da combinação das características definidas e classificadores descritos no Capítulo 4. Inicialmente, será descrita a metodologia aplicada, que inclui a descrição da base de dados, definição dos vetores de características e dos classificadores, dos sistemas avaliados, em seguida, os resultados obtidos e, por fim, serão abordados os resultados e as discussões acerca do desempenho de cada um dos sistemas no âmbito da aplicação.

### 5.1 Metodologia

A base de dados utilizada para avaliação da pesquisa foi obtida e refinada a partir do projeto REPARAI, dado que esta pesquisa nasceu e evoluiu concomitante – por um ano, conforme supracitado, com demais pesquisadores, indústria e alunos.

A base de dados para treinamento e teste dos sistemas foi composta por sinais que representam os estados básicos do motor, a serem classificados como “Normal” e “Alerta”. Todos os sinais foram pré-classificados conforme essas condições. O estado “Normal” é representado pelo sinal capturado durante o funcionamento do motor em condições normais. O estado “Alerta” representa sinais com falhas simuladas, falhas reais e sinais que buscam caracterizar condições diferentes da normalidade do motor.

Para a análise, os sinais de áudio foram particionados em *frames* de 3 segundos. Não foi necessário utilizar um *frame* de curtíssima duração (16 – 32 ms), em virtude da periodicidade do sinal (RABINER, SCHAFER, 2010). Assim, intervalos maiores conseguem representar o estado de funcionamento do motor e, conseqüentemente, proporcionar uma compressão significativa

dos dados de entrada, com a diminuição da quantidade de vetores de características a processar nas fases de treinamento e de classificação (REPARAI, 2013).

Todos os sinais capturados foram digitalizados a 44.100 amostras/s, 16 bits e o formato WAVE, com subdivisão em *frames* de 3 s e aplicação da Janela Retangular.

Na Tabela 1, são listadas as propriedades dos sinais, por ponto de captura, a serem usados na avaliação dos classificadores. Foram utilizados 50% dos dados para treinamento, 20% para validação e 30% para teste, com validação cruzada utilizando o Método *holdout* (com 40 iterações) (BALDISSEROTTO, 2005).

**Tabela 1. Propriedade dos sinais por ponto de captura para o treinamento e teste.**

Abrevia- tura	Ponto	Posição	Captura	Total Sinais "Normal"	Total Sinais "Alerta"	Total	Treinamento/Validação (70%)	Teste (30%)
P1	1	Superior	Microfone	689	656	1345	942	403
P1_inf	1	Inferior	Microfone	100	607	707	495	212
P2	2	Superior	Microfone	120	765	885	620	265
P2_inf	2	Inferior	Microfone	100	705	805	564	241
P3	3	Superior	Microfone	120	766	886	621	265
P3_inf	3	Inferior	Microfone	100	708	808	566	242
P4	4	Superior	Microfone	100	728	828	580	248
P4_inf	4	Inferior	Microfone	100	708	808	566	242
P5	5	Superior	Microfone	120	766	886	621	265
P5_inf	5	Inferior	Microfone	100	706	806	565	241
P6	6	Superior	Microfone	120	766	886	621	265
P6_inf	6	Inferior	Microfone	100	706	806	565	241
P7	7	Superior	Microfone	100	646	746	522	224
P1_bbxm	1	Inferior	BeagleBoard	100	705	805	564	241

Fonte: (REPARAI, 2013).

Na Tabela 2, são apresentados todos os sinais declarados com "Alerta" e os casos que representam. Os dados buscam representar o motor em condições diferentes da normalidade. Esses são compostos por sinais representando falhas reais e simuladas, apresentados anteriormente, somados a sinais de outros motores (com falhas e normais), além de outros com características distintas (sinal adicional ao áudio gerado por um ventilador presente na sala de máquinas e uma onda senoidal)

As falhas Simuladas 1, 2 e 3 foram geradas para cada ponto de captura, de acordo com o padrão apresentado acima.

**Tabela 2. Descrição dos Sinais "Alerta" aplicados.**

Sinais	Descrição da Característica do Sinal	Total
I	Falha Simulada 1	1422
II	Falha Simulada 2	1423
III	Adição de Ruído (Falha Simulada 3)	1423
IV	Falhas Reais no Motor (Falhas Simuladas Reais 1, 2 e 3)	34
V	Sinais de motores diferentes	271
VI	Falhas Reais em outros Motores	92
VII	Onda Senoidal	4
VIII	Ventilador da Sala de Máquinas	4

Fonte: (REPARAI, 2013).

Na pesquisa, foram analisadas as combinações das diversas características e classificadores apresentados para avaliar o desempenho no diagnóstico de falhas de motores utilizados, em usinas termoeletricas.

O diagnóstico de falhas nos motores se baseou em duas etapas: treinamento e classificação.

Na fase de treinamento, foram construídos os padrões de referência. As etapas de pré-processamento e extração de características seguiram o mesmo procedimento para todos os casos. A geração dos padrões de referência foi conduzida de acordo com o método de classificação aplicado.

Na etapa de pré-processamento, foi realizada a subdivisão do sinal em *frames* de 3 segundos e aplicação da janela retangular. A janela retangular foi aplicada pois ser mais simples e se adequar às características do sinal sob análise (sinal com poucas variações ao longo do tempo).

Na etapa de extração de características, foram construídos os vetores de características.

Para a definição dos vetores, foi realizada uma análise prévia sobre a relação das características definidas e os diferentes estados do motor. A análise é apresentada no Apêndice A.

As medidas que apresentaram comportamento distinto para as diferentes condições do motor, ou seja, se mostraram mais adequadas à caracterização do estado do motor, foram selecionadas para compor os vetores de características.

Foram definidos 3 grupos de vetores, em função do domínio utilizado para extração das características, a saber:

- **Vetor-Domínio-1:** composto por todas as características extraídas no domínio 1, totalizando 16 valores.
- **Vetor-Domínio-2:** composto por todas as características extraídas no domínio 2, contabilizando 17 valores.
- **Vetor-Híbrido:** combinação das características extraídas nos dois domínios, somando 33 valores.

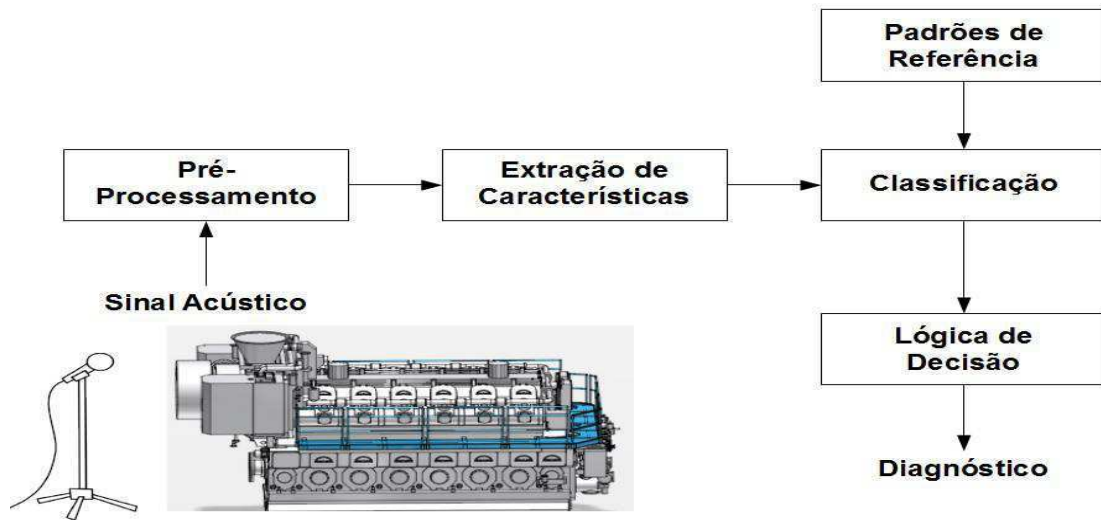
Os valores dos vetores foram normalizados no intervalo  $[-1, 1]$ . Tal ação se justificou, dado que as características apresentam grandezas com escalas diferentes e, devido à lógica dos classificadores, todos os elementos do vetor de entrada devem estar no mesmo intervalo, de forma a evitar que os pesos da RNA ou a linearidade do QV sejam neutralizados.

Quanto aos métodos de classificação, as técnicas utilizadas para construção dos classificadores avaliados foram apresentadas no Capítulo 3, a saber: Classificador 1 e Classificador 2. O modelo de multiclassificação

(híbrido) proposto foi descrito no Capítulo 4.

A etapa de classificação (Figura 10) foi realizada conforme descrito nos Capítulos 3 e 4 para cada método aplicado.

**Figura 10. Diagrama em Blocos da Estratégia de Classificação Aplicada.**



**Fonte: Adaptado de REPARAI (2013).**

Todas as etapas das fases de treinamento e de classificação (pré-processamento do sinal, extração de características, análise das características e classificação) foram implementadas no software Matlab (MATHWORKS, 2013).

Para a execução dos experimentos, foi realizada validação cruzada de 40 experimentos para cada um dos 14 pontos de captura/microfone, combinando 3 métodos de classificação com 3 formações distintos de vetores de características, resultando, assim, em 5.040 experimentos.

Para cada experimento, na etapa de treinamento foram aplicados os sinais reservados para o treinamento (50%), como descrito na Tabela 1, sendo reservadas 20% para a validação. Para cada classificador, foram aplicados os sinais de teste, de acordo com a Tabela 1.

Para avaliação do desempenho da abordagem proposta, foram consideradas as métricas descritas a seguir.

- **Eficácia:** média dos conjuntos dos sinais “Normal” e “Alerta” dos resultados obtidos na validação e a diferença entre elas. Por meio dessas medidas, foi possível avaliar se o sistema conseguiu distinguir as classes treinadas.
- **Desempenho:** proporção de acerto nos testes avaliados.

A análise estatística dos resultados obtidos nos experimentos foi implementada na ferramenta R (R CORE TEAM, 2012), conforme a seguir.

- 1. Avaliação da Eficácia:** avaliação da eficácia, baseado na disjunção dos conjuntos “Normal” e “Alerta”, definindo, assim, os sistemas que foram eficazes, ou seja, conseguiram distinguir as duas classes.
- 2. Avaliação dos Classificadores:** avaliação do desempenho de todos os sistemas que proporcionaram sucesso na distinção entre as duas classes da avaliação anterior.
- 3. Avaliação das Características:** avaliação do desempenho do classificador com maior desempenho para todos os vetores de características avaliados na pesquisa.

## 5.2 Resultados

Para melhor observação dos resultados obtidos, a parte mais significativa desses é apresentada nesta seção. Informações complementares estão apresentadas em Apêndices deste documento. No Apêndice A, são descritos os resultados obtidos nos experimentos. No Apêndice B, a Análise Estatística é apresentada, contemplando as questões de pesquisa levantadas, a descrição da análise e os resultados obtidos.

No quesito eficácia, as seguintes questões de pesquisas foram definidas:

- **C1-D1:** É possível diferenciar os sinais dos motores em 2 estados (“Normal” e “Alerta”), utilizando parâmetros acústicos extraídos do domínio 1, aplicados no Classificador 1?



- **C1-D2:** É possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 2, aplicados no Classificador 1?
- **C1-HÍB:** É possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 1 e 2 em conjunto, aplicados no Classificador 1?
- **C2-D1:** É possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 1, aplicados no Classificador 2?
- **C2-D2:** É possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 2, aplicados no Classificador 2?
- **C2-HÍB:** É possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 1 e 2 em conjunto, aplicados no Classificador 2?
- **MULT-D1:** É possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 1, aplicados no Multiclassificador proposto?
- **MULT-D2:** É possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 2, aplicados no Multiclassificador proposto?
- **MULT-HÍB:** É possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 1 e 2, aplicados no Multiclassificador proposto?

Duas metodologias foram abordadas. Na Metodologia 1, foi avaliada a diferença das médias dos conjuntos de dados "Normal" e "Alerta" em cada experimento. Na Metodologia 2, foi avaliada a disjunção das médias dos conjuntos de dados "Normal" e "Alerta".

Nas Tabela 3 e Tabela 4, são apresentados os resultados dos testes estatísticos realizados para Metodologia 1 e Metodologia 2, respectivamente. Em ambos os casos, todos os sistemas foram eficazes na distinção entre as duas classes ("Normal" e "Alerta").

**Tabela 3. Teste de Wilcoxon para avaliação dos Intervalos de Confiança (IC) das diferenças maiores que 0,5 e da eficácia de cada método avaliado (Metodologia 1).**

Características (Domínio)	Método de Classificação	Teste de Wilcoxon ( <i>p-value</i> )	Eficaz
FREQ	C1	< 2,2e-16	Sim
	C2	< 2,2e-16	Sim
	MULT	< 2,2e-16	Sim
TEMPO	C1	< 2,2e-16	Sim
	C2	< 2,2e-16	Sim
	MULT	< 2,2e-16	Sim
HÍB	C1	< 2,2e-16	Sim
	C2	< 2,2e-16	Sim
	MULT	< 2,2e-16	Sim

**Tabela 4. Testes de disjunção dos conjuntos "Normal" e "Alerta" de cada método avaliado (Metodologia 2).**

Características (Domínio)	Classificador	Teste de Wilcoxon ( <i>p-value</i> )	Disjuntos
FREQ	C1	< 2,2e-16	Sim
	C2	< 2,2e-16	Sim
	MULT	< 2,2e-16	Sim
TEMPO	C1	< 2,2e-16	Sim
	C2	< 2,2e-16	Sim
	MULT	< 2,2e-16	Sim
HÍB	C1	< 2,2e-16	Sim
	C2	< 2,2e-16	Sim
	MULT	< 2,2e-16	Sim

Após a avaliação da eficácia de cada método, a etapa seguinte buscou avaliar os classificadores. A seguinte questão foi avaliada.

- **Desempenho-Classificador:** Considerando os classificadores eficazes, o desempenho do Multiclassificador (QV + RNA) proporcionou desempenho superior?

Para a avaliação da significância dos classificadores, foi aplicado teste estatístico de forma pareada, considerando que as mesmas condições de experimento foram aplicadas, ou seja, mesmo conjunto de treinamento e

teste, e, também, o mesmo vetor de características, de forma a diminuir as variáveis na análise.

Conforme resultados obtidos, expostos na Tabela 5, todos os sistemas avaliados apresentaram acurácia superior a 90%. Entretanto, os Multiclassificadores proporcionaram uma taxa de acerto maior que os classificadores base (C1 e C2) aplicados de forma independente, respondendo à questão levantada na pesquisa, conforme teste estatístico pareado que avalia se o multiclassificador obteve desempenho superior que o classificador comparado (Tabela 6). É possível concluir, portanto, que a abordagem proposta, proporcionou melhoria no desempenho do sistema.

**Tabela 5. Média de acerto para os testes por sistema analisado.**

Características (Domínio)	Classificador	Média Global	Lim. Inferior	Lim. Superior
FREQ	QV	90,71%	90,43%	90,97%
	RNA	94,16%	93,83%	94,48%
	MULT	94,53%	94,22%	94,84%
TEMPO	QV	95,24%	94,87%	95,59%
	RNA	98,82%	98,46%	99,22%
	MULT	98,93%	98,56%	99,30%
HÍB	QV	95,89%	95,64%	96,12%
	RNA	98,20%	97,91%	98,48%
	MULT	98,65%	98,35%	98,93%

**Tabela 6. Teste de Wilcoxon pareado para avaliação do desempenho do Multiclassificador.**

Classificador	Classificador Comparado	<i>p-value</i>	Desempenho Superior do MULT
MULT	QV	< 2.2e-16	Sim
	RNA	< 2.2e-16	Sim

Na última etapa, que busca a avaliação dos vetores de características, o desempenho de cada um desses vetores no multiclassificador foi avaliado. A seguinte questão foi investigada:

- **Desempenho-Características:** Considerando o classificador de melhor desempenho, qual (quais) vetor (vetores) de características proporcionou(aram) desempenho superior?

Na Tabela 7, é apresentado o desempenho de cada um dos vetores de características no Multiclassificador. Na Tabela 8, a partir do resultado do teste estatístico, para comparação entre o Domínio 1 e o Domínio 2, verifica-se que o domínio do tempo proporciona desempenho superior.

**Tabela 7. Média de acerto para os testes do Multiclassificador para cada um dos vetores aplicados.**

Características (Domínio)	Classificador	Média Global (%)	Lim. Inferior (%)	Lim. superior (%)
D1	MULT	94,53	94,22	94,84
D2	MULT	98,93	98,56	99,30
HÍB	MULT	98,65	98,35	98,93

**Tabela 8. Teste de Wilcoxon para avaliação do desempenho dos vetores de características.**

Domínio 1	Domínio 2	<i>p-value</i>	Domínio 1 > Domínio 2
HÍB	D1	< 2.2e-16	Sim
TEMPO	HÍB	< 2.2e-16	Sim
	D1	< 2.2e-16	Sim

Em se tratando da análise da representatividade das características, observa-se, de forma geral, que a caracterização no domínio 1 proporcionou uma taxa de acerto inferior às demais representações (domínios 2 e híbrido).

Entretanto, apesar do desempenho inferior aos demais, o estudo demonstra que as características extraídas no domínio 1 são também representativas do estado de funcionamento do motor em uma UTE.

Diante do melhor desempenho da caracterização no domínio do tempo em detrimento ao domínio da frequência, a utilização de vetores híbridos não proporcionou melhoria na classificação, conforme se verifica nas Tabelas 9 e 10 e Figuras 10 e 11. Observa-se desempenho muito próximo para as duas abordagens (domínio 2 e híbrida).

As tabelas demonstram o desempenho superior do domínio do tempo pelo maior valor das medianas e médias observadas. Mas nos dois casos todos os pontos tiveram experimentos com acurácia 100%.

Pelas figuras, observa-se que na maioria dos pontos, o domínio híbrido teve um maior variância indicando uma menor dispersão dos resultados, mas todos os casos apresentaram *outliers*.

O resultado observado, o desempenho um pouco superior do domínio 2 sobre o híbrido, pelo mesmo motivo do desempenho inferior do domínio 1, pode ser justificado pelo fato de os sinais que compõem a base de dados apresentarem falhas que se mostram mais bem representadas pelas características extraídas no domínio 2.

**Tabela 10. Dados do desempenho do Multiclassificador no domínio 2.**

Ponto	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
<b>Média (%)</b>	98,88	98,90	99,52	99,13	99,32	98,20	98,94	99,37	99,13	98,57	98,64	98,98	98,81	98,68
<b>Mediana (%)</b>	100,00	99,13	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
<b>Mínimo (%)</b>	83,96	96,78	85,12	83,83	85,12	83,83	85,12	87,16	85,12	83,83	85,12	84,96	86,70	85,12
<b>Máximo (%)</b>	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
<b>Desvio Padrão</b>	0,0395	0,0092	0,0236	0,0350	0,0304	0,0487	0,0287	0,0262	0,0317	0,0437	0,0418	0,0328	0,0366	0,0409

**Tabela 11. Dados do desempenho do Multiclassificador no domínio híbrido.**

Ponto	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
<b>Média (%)</b>	99,75	98,84	98,85	98,98	98,65	97,37	98,32	98,73	98,41	98,41	97,94	98,80	99,24	98,75
<b>Mediana (%)</b>	100,00	99,26	99,79	99,62	99,59	98,50	98,76	99,54	99,17	98,87	99,17	99,25	99,54	99,59
<b>Mínimo (%)</b>	98,58	93,07	86,78	85,34	86,78	85,71	87,60	88,99	86,78	88,35	86,78	88,35	96,33	87,60
<b>Máximo (%)</b>	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
<b>Desvio Padrão</b>	0,0037	0,0140	0,0320	0,0235	0,0316	0,0371	0,0260	0,0289	0,0311	0,0193	0,0361	0,0246	0,0082	0,0310

Figura 11. *Boxplot* do desempenho do Multiclassificador no domínio 2.





Figura 12. *Boxplot* do desempenho do Multiclassificador no domínio híbrido.





### **5.3 Discussão**

Ao final do presente capítulo, no qual foi apresentada a base de dados utilizada (REPARAI, 2013), seguida das características e métodos de classificação avaliados, juntamente com a metodologia e os testes realizados, constatou-se a eficácia das medidas acústicas avaliadas, juntamente com os métodos de classificação investigados para o diagnóstico de falhas em motores.

No âmbito dos classificadores, observou-se melhor desempenho do multiclassificador em relação a cada classificador (baseado em C1 ou C2), dado que combina a relação linear e não linear das características.

A caracterização dos sinais no domínio híbrido e no domínio 2 proporcionaram as maiores acurácias para os testes avaliados, com resultado um pouco superior para o domínio 2. O melhor desempenho pode ser justificado pela composição da base dados.

No próximo capítulo, serão elencadas as considerações finais da pesquisa, assim como as contribuições e as pesquisas futuras propostas.

# Capítulo 6

## Considerações Finais e Sugestões para Pesquisas Futuras

Neste capítulo, são dispostas as considerações finais acerca da pesquisa. Na Seção 6.1, os principais resultados obtidos são destacados. Na Seção 6.2, são apresentadas as contribuições da pesquisa e, na Seção 6.3, são ressaltadas as sugestões para pesquisas futuras.

### 6.1 Considerações Finais

Nesta pesquisa, foi proposta uma abordagem para o diagnóstico de motores baseada na modelagem acústica, aplicada em uma UTE. A avaliação das condições de funcionamento do motor ("Normal" ou "Alerta") foi baseada na extração de características, seguida de sua classificação, e, posteriormente, da avaliação por uma lógica de decisão, definindo o estado do motor.

O estudo selecionou diversas combinações de características acústicas e métodos de classificação, com o intuito de avaliar o desempenho da combinação desses na classificação do estado do motor.

Foram utilizadas características acústicas extraídas em dois domínios. Essas características foram avaliadas na forma individual e combinadas (vetor híbrido).

Os métodos de classificação selecionados foram definidos por diferentes objetivos. O Classificador 1 buscou avaliar a relação linear entre as características. O Classificador 2 buscou representar a relação não linear entre as características.

O método de classificação proposto na pesquisa é um sistema multiclassificador heterogêneo paralelo, combinando os dois classificadores, agregando a relação linear e não linear entre as características acústicas.

A partir de um subconjunto da base de dados do sistema REPARAI, formada por sinais extraídos de uma UTE, alocados em diversos pontos de

captura em torno dos motores, e por outros com falhas reais e simuladas, previamente classificados em duas classes: "Normal" e "Alerta", tornou-se possível a análise, em um ambiente real, com um conjunto de dados representativo desse ambiente. Além de falhas reais, falhas simuladas foram aplicadas, pela dificuldade de conseguir dados representativos de falhas reais, considerando o tempo de operação dos equipamentos e a manutenção o que inviabilizou a obtenção de um número significativo de falhas reais.

A partir de um conjunto significativo de sinais de áudio analisados (6.742), obtidos em diversos pontos próximos ao motor, observou-se a eficácia de todas as combinações avaliadas, pois esses permitiram a distinção entre as duas classes avaliadas ("Normal" e "Alerta").

As características extraídas no domínio 2 permitiram caracterizar melhor as condições do motor, com uma pequena diferença de desempenho para o vetor de características formado pelos dois domínios (1 e 2).

Ao final da pesquisa, considerando-se os estudos realizados e os resultados obtidos (REPARAI, 2013), conclui-se que o diagnóstico dos motores pode ser realizado, de forma eficiente, pela análise acústica. O diagnóstico pode se mostrar, portanto, como um auxílio à tomada de decisão sobre o estado de funcionamento dos motores de uma UTE.

A principal contribuição da modelagem proposta visa colaborar na diminuição do risco de danos maiores em uma unidade geradora de energia comprometida, favorecendo ações preventivas, minimizando, assim, os custos provenientes de ações corretivas de impacto significativo no processo de geração de energia em usinas termoeletricas.

## **6.2 Contribuições da Pesquisa**

Ao final da pesquisa, podem-se elencar as contribuições, destacadas a seguir.

- O motor de uma UTE pode ser diagnosticado em tempo real a partir do seu sinal acústico, baseado numa etapa anterior de classificação supervisionada.

- Características extraídas do sinal acústico demonstraram ser eficazes para o diagnóstico de motores em uma UTE.
- A utilização de um sistema multiclassificador, demonstra ser eficaz e eficiente, com ótima acurácia para a predição de falhas e diagnóstico do motor.
- O sinal de áudio gerado pelos motores se mostra, portanto, útil no auxílio ao diagnóstico de falhas.

### **6.3 Sugestões para Pesquisas Futuras**

Ao final da pesquisa ora apresentada, outras questões podem ser definidas para pesquisas futuras, com destaque para as seguintes.

- Obtenção de uma quantidade mais significativa de sinais de áudio com falhas reais. Dessa forma, uma melhor representatividade de possíveis falhas pode ser obtida na etapa de treinamento.
- Utilização da Análise de Componentes Principais, para avaliar, de maneira mais acurada, o nível de representatividade das características acústicas.
- Avaliação de outras técnicas de IA, como Lógica *Fuzzy*, na formação de diferentes sistemas de multiclassificação. Comparando o desempenho obtido e analisando os pontos positivos e negativos de cada um deles.
- Análise de outras lógicas de decisão na definição de uma falha, por exemplo, avaliar um intervalo de *frames* ou defini-lo a partir do classificador base selecionado. Visto que diferentes falhas se comportam de maneiras distintas, podendo ser uma avaliação inicial para a definição da falha no motor.
- Realização de um estudo que combine a análise do sinal acústico com vibração capturada dos motores, formando, assim, um novo vetor de características. Como já foi indicado, o impacto das falhas ocorre de forma distinta para cada um dos sinais, podendo ser avaliado em cada um deles.

## Referências Bibliográficas

ALMEIDA, F. R. V. **Análises estatísticas e reconhecimento de padrão aplicados em diagnósticos de defeitos em rolamentos através da análise de vibração**. Tese (Doutorado em Projeto/Fabricação) - Instituto de Engenharia Mecânica, Universidade Federal de Itajubá, Itajubá, 2007. 111 p.

ANGARITA, J. A. C. **Compressão de Dados para Sinais de Distúrbios no Ambiente de Redes Elétricas Inteligentes**. Tese de Doutorado. Departamento de Engenharia Elétrica, Universidade de Brasília, 2013.

BALDISSEROTTO, C. **Técnicas de Apredizagem de Máquina para Previsão**. Trabalho de Conclusão de Curso – Engenharia da Computação. Escola Politécnica de Pernambuco. Recife, julho de 2005.

BENNET, S. **Modern Diesel Technology**: Diesel Engines. 2nd ed. Canadá: Cengage Learning, 2009. ISBN 978-1-4354-4044-9.

BIONDI NETO, L.; FUKUDA, F. H.; RODRIGUES, P. T.; AMÉRICO, M.; LIMA JUNIOR, M. P. Sistema Inteligente para Detecção e Diagnóstico de Falhas em Geradores de Energia Elétrica de Usinas Termoelétricas. **Revista da Escola de Engenharia da UFF (ENGEVISTA)**, Rio de Janeiro, v. 11, n. 2, p. 90-103, dezembro de 2009.

BORBOREMA ENERGÉTICA S.A. **Estudo de Impacto Ambiental (EIA)**: Relatório de Impacto Ambiental (RIMA). Campina Grande, v. 1, 2008. Disponível em: <[http://www.sudema.pb.gov.br/index.php?option=com\\_docman&task=doc\\_download&gid=2111&Itemid=100032](http://www.sudema.pb.gov.br/index.php?option=com_docman&task=doc_download&gid=2111&Itemid=100032)>. Acesso em: 30 maio de 2015.

BRASIL. Ministério do Trabalho. Portaria 3214, 8 de junho de 1978. **NR 15**: Atividades e Operações Insalubres. Brasília, jun. 1978. Disponível em: <[http://portal.mte.gov.br/data/files/FF8080812DF396CA012E0017BB3208E8/NR-15%20\(atualizada\\_2011\).pdf](http://portal.mte.gov.br/data/files/FF8080812DF396CA012E0017BB3208E8/NR-15%20(atualizada_2011).pdf)>. Acesso em: 30 maio de 2015.

CHAMAY, M.; OH, S.; KIM, Y. J. Development of a diagnostic system using LPC/cepstrum analysis in machine vibration. **Journal of Mechanical Science and Technology**. Korea, v. 27, n. 9, p. 2629–2636, 2013. Disponível em: <[doi:10.1007/s12206-013-0707-5](https://doi.org/10.1007/s12206-013-0707-5)>. Acesso em: 30 maio 2015.

CHEN, B.; CHEN, X.; HE, Z.; TAN, Z. Mechanical Fault Diagnosis Based on Local Mean Decomposition Method. **International Conference on**

**Measuring Technology and Mechatronics Automation.** [s.l.], v. 11, n. i, p. 681–684, 2009. Disponível em: <doi:10.1109/ICMTMA.2009.373>. Acesso em: 30 maio 2015.

COSTA, V. H. C. **Cartilha - O ruído e suas interferências na saúde e no trabalho.** São Paulo: Departamento Intersindical de Estudos e Pesquisas de Saúde e dos Ambientes de Trabalho/DIESAT, 1989-90.

DENG, J.; STOBART, R.; MAASS, B. **Artificial Neural Networks - Industrial and Control Engineering Applications:** The Applications of Artificial Neural Networks to Engines. Reino Unido: InTech, p. 309-332, 2009. Disponível em: <http://cdn.intechweb.org/pdfs/14741.pdf>. Acesso em: 13 maio de 2015.

ENDER, P. The Story of Kurtosis. **Introduction to Research Design and Statistics.** 2004. Disponível em: <http://www.philender.com/courses/intro/notes3/kurtosis.html>. Acesso em: 30 de maio de 2015.

FECHINE, J. M. **Reconhecimento Automático de Identidade Vocal Utilizando Modelagem Híbrida: Paramétrica e Estatística.** Tese de Doutorado. Pós-Graduação em Engenharia Elétrica, Universidade Federal de Campina Grande, Campina Grande, 2000.

FUMERA, G.; ROLI, F. A theoretical and experimental analysis of linear combiners for multiple classifier systems. **IEEE Transactions on Pattern Analysis and Machine Intelligence.** [s.l.], v. 27, n. 6, p. 942–956, 2005. Disponível em: <doi:10.1109/TPAMI.2005.109>. Acesso em: 30 maio de 2015.

GERSHO, A.; GRAY, R. M. **Vector Quantization and Signal Compression.** 1<sup>st</sup> ed. United States: Springer US, 1992.

GOEBEL, J. E. **Transformada Wavelet Packet.** Trabalho de Conclusão de Curso - Curso Engenharia Elétrica. Universidade Federal do Rio Grande do Sul. 2009. Disponível em: <http://hdl.handle.net/10183/24310?locale=pt\_BR>. Acesso em: 19 maio de 2015.

GUANGPU, L.; HONGXIA, P. Measurement and Analysis of Noise Characteristics for Diesel Engine. **IEEE International Conference on Mechatronics.** [s.l.], p. 181–184, 2006. Disponível em: <http://ieeexplore.ieee.org/xpls/abs\_all.jsp?arnumber=4018355>. Acesso em: 19 maio de 2015.

GURNEY, K. **An Introduction to Neural Networks**. 1st ed. Paperbrack, 1997.

HAYKIN, S. O. **Neural Networks and Learning Machines**. 3rd ed. Canadá: Prentice Hall, 2008.

JAIN, A. K.; MURTY, M. N.; FLYNN, P. J. Data Clustering: a Review. **ACM Computing Surveys**. v. 31, n. 3, p. 264-323, 1999.

KABIRI, P.; MAKINEJAD, A. Using PCA in Acoustic Emission Condition Monitoring to Detect Faults in an Automobile Engine. **Journal of 29th European Conference on Acoustic Emission**. Áustria, 2011. Disponível em <[http://212.8.206.21/article/ewgae2010/papers/18\\_Guagliano.pdf](http://212.8.206.21/article/ewgae2010/papers/18_Guagliano.pdf)>. Acesso em: 27 maio de 2015.

KIMURA, R.; MITZUTANI, H. Diesel Engine Monitoring System by Abnormal Sound Detection. **Journal of the Marine Engineering Society in Japan**. Japão, v. 19, n. 2, p. 76-87, 1991.

KIMURA, R.; NAKAI, N.; KISHIMOTO, T. Abnormal Sound Detection by Neural Network in the Diesel Engine. **Journal of the Marine Engineering Society in Japan**. Japão, v. 24, n. 1, p. 24-31, 1998. Disponível em: <<http://www.jime.jp/publication/bulletin/english/pdf/mv26n011998p24.pdf>> . Acesso em: 11 maio de 2015.

KIMURA, R.; NAKAI, N.; MIZUTANI, H. Diagnosis System of Diesel Engine by Statistical Vibration Analysis. **Bulletin of the Marine Engineering Society in Japan**. Japão, v. 24, n. 1, p. 14-20, 1994.

KONSTANTIN-HANSEN, H. **Envelope analysis for diagnostics of local faults in rolling element bearings**. Dinamarca: Brüel & Kjær, 2003. Disponível em: <<http://bksv.it/doc/bo0501.pdf>>. Acesso em: 15 maio de 2015.

LEVITT, J. **Complete Guide to Predictive and Preventive Maintenance**. 2nd ed. United States: Industrial Press Inc., 2011.

LI, M. An intelligent fault diagnosis system of rolling bearing. **Proceedings of International Conference on Transportation, Mechanical, and Electrical Engineering (TMEE)**. [s.l.], v. 1, n. 1, p. 544-547, 2011. Disponível em: <[doi:10.1109/TMEE.2011.6199261](https://doi.org/10.1109/TMEE.2011.6199261)>. Acesso em: 15 maio de 2015.

LI, W., ZHU, Z., JIANG, F., ZHOU, G., CHEN, G. Fault diagnosis of rotating machinery with a novel statistical feature extraction and evaluation method.

**Mechanical Systems and Signal Processing.** [s.l.], v. 50-51, p. 414-426, 2015.

LINHARE, A. P.; PEREIRA, L. A.; GAZZANA, D. da S.; FERNANDES, D.; SILVA, J. S. Desenvolvimento do protótipo de um Sistema de Detecção e Diagnóstico de Falhas Incipientes em Motores de Indução. **Revista Pesquisa e Desenvolvimento da ANEEL.** Brasília, n. 3, 2009.

LORENA, A. C.; CARVALHO, A. C. P. L. F. de. Introdução às Máquinas de Vetor Suporte. **Relatório N° 192.** Instituto de Ciências Matemáticas e de Computação, São Carlos – SP, abr. 2003.

MATHIAS, M. H.; OLIVEIRA, R. J. G. de; MEDEIROS, E. C. Aula 06 - Ferramentas de processamento - parte 1. In: **Ferramentas de Diagnóstico de Máquinas.** [s.l.], 2012. Disponível em <<http://www.acervodigital.unesp.br/bitstream/123456789/46460/6/Aula%206%20-%20Ferramentas%20de%20processamento%20-%20parte%201.ppt>>. Acesso em: 30 maio de 2015.

MATHWORKS. **MATLAB R2013a.** [s.l.]: MathWorks, 2013.

MOBLEY, K. **An Introduction to Predictive Maintenance.** 2nd ed. United States: Elsevier Science, 2002. ISBN-10: 0750675314.

MOSCHIONI, G.; VANIA, A. Vibroacoustic Monitoring of Complex Phenomena with Multisensorial Measurement Network. An Application to an Electrical Power Plant. **Instrumentation and Measurement Technology Conference.** Italy, p. 1930-1935, 2004.

MORAN, M. J.; SHAPIRO, H. N.; BOETTNER, D. D.; BAILEY, M. B. **Fundamentals of Engineering Thermodynamics.** 7th ed. United States: Wiley, 2011. ISBN 13 978-0470-49590-2.

NISKODE, P. M.; HOOVER, R. M. Noise Control Approaches in the Design of Thermal Power Plants. **Journal of IEEE Transactions on Power Apparatus and Systems.** [s.l.], v. PAS-96, n. 4, p. 1337-1340. Disponível em: <[http://ieeexplore.ieee.org/xpls/abs\\_all.jsp?arnumber=1602060](http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=1602060)>. Acesso em: 15 maio de 2015.

NUNES, G. B.; PINHEIROS, R. B. **"O que são Redes Neurais Artificiais?"**. Trabalho Final de Computação Gráfica - PUC-RIO. Rio de Janeiro, 2007. Disponível em: <<http://www.tecgraf.puc-rio.br/~mgattass/RedeNeural/redeneural.html>>. Acesso em: 10 maio de 2015.



OCAK, H.; LOPARO, K. A. Estimation of the running speed and bearing defect frequencies of an induction motor from vibration data. **Mechanical Systems and Signal Processing**. [s.l.], v. 18, n. 3, p. 515–533, 2004. Disponível em: <doi:10.1016/S0888-3270(03)00052-9>. Acesso em: 15 maio de 2015.

OLIVEIRA JR, G. M. de. **Máquina de Vetores Suporte: estudo e análise de parâmetros para otimização de resultado**. Trabalho de Graduação. Centro de Informática, UFPE, dez. 2010. Disponível em: <http://www.cin.ufpe.br/~tg/2010-2/gmoj.pdf>. Acesso em: 15 maio de 2015.

PALMA, D. C. **Quando o ruído atinge a audição**. Monografia de Conclusão de Curso de Especialização em Audiologia Clínica. Centro de Especialização em Fonoaudiologia Clínica. Rio Grande do Sul: Porto Alegre, 1999.

PARADEDA, R. B. **Utilizando Pesos Estáticos e Dinâmicos em Sistemas Multi-Classificadores com Diferentes Níveis de Diversidade Utilizando Pesos Estáticos e Dinâmicos em Sistemas Multi-Classificadores com Diferentes Níveis de Diversidade**. Dissertação (Mestrado). Universidade Federal do Rio Grande do Norte (UFRN). Rio Grande do Norte: Natal, 2007. Disponível em: <http://repositorio.ufrn.br:8080/jspui/bitstream/123456789/17963/1/RaulBP.pdf>. Acesso em: 20 maio de 2015.

PATIDAR, S.; SONI, P. K. An Overview on Vibration Analysis Techniques for the Diagnosis of Rolling Element Bearing Faults. **International Journal of Engineering Trends and Technology**. [s.l.], v. 4, n. 5, p. 1804–1809, 2003.

R CORE TEAM. R: A language and environment for statistical computing. **R Foundation for Statistical Computing**. Vienna, Austria, 2012. ISBN 3-900051-07-0. Disponível em: <http://www.R-project.org/>. Acesso em: 20 maio de 2015.

RABINER, L. R.; SCHAFER, R. W. **Theory and Applications of Digital Speech Processing**. 3rd ed. United States: Prentice Hall, 2010.

REPARAI. **REPARAI: Relatório Técnico 12**. ANEEL PD-6471-0002/2012. Universidade Federal de Campina Grande (UFCG). Laboratório de BioEnergia, Arquiteturas Dedicadas e Inteligência Artificial (BELADIA). Campina Grande-PB, 2013. Disponível em <http://beladia.sergiodbe.net>.

RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. 3rd ed. United States: Prentice Hall, 2010.

SANTOS, S. P. **Aplicação de Sistemas Multi-Classificadores no Diagnóstico de Falhas em Motores de Indução Trifásicos**. Dissertação (Mestrado). Programa de Pós-Graduação em Engenharia Elétrica – Universidade Federal do Rio Grande do Norte. Rio Grande do Norte: Natal, 2008.

SOUZA, G. F. **Análise do funcionamento de motores diesel utilizando wavelets**. Dissertação (Mestrado). Faculdade de Engenharia Elétrica – Universidade Estadual de Campinas (UNICAMP). São Paulo: Campinas, 2011.

TANDON, N.; CHOUDHURY, A. **A Review of Vibration and acoustic measurement methods for the detection of defects in rolling element bearings**. *Journal of Tribology International*. [s.l.], v. 32, p. 469-480, 1999.

VELLASCO, M. B. R. **Redes Neurais Artificiais**. Laboratório de Inteligência Computacional Aplicada – PUC Rio de Janeiro. Rio de Janeiro, 2007.

VIEIRA, V. J. D.; COSTA, S. C; COSTA, W. C. de A.; ARAÚJO, J. M. F. R. de. **Avaliação de Desempenho na Classificação de Patologias Laríngeas por Análise LPC de Sinais de Voz e Redes Neurais MLP**. Congresso Brasileiro de Inteligência Computacional - CBIC, Porto de Galinhas - Recife. 2013.

WANG, Z.; ZHU, Z.; LI W.; CHEN; G.; ZHOU G. Total Energy Growth Rate of Rolling Bearing due to Faults during Run-Up. **Advances in Mechanical Engineering**. [s.l.], p. 1-7, 2013. Disponível em: <doi:10.1155/2013/502051>. Acesso em: 15 maio de 2015.

WANG, Y. S.; MA, H. Q.; ZHU, Q.; LIU, X. T.; ZHAO L. H. An intelligent approach for engine fault diagnosis based on Hilbert–Huang transform and support vector machine. **Applied Acoustics**. [s.l.], v. 75, p. 1–9, 2014.

YANG, Q.; LIU, C.; ZHANG, D.; WU, D. A New Ensemble Fault Diagnosis Method Based on K-means Algorithm. **International Journal of Intelligent Engineering and Systems**. [s. l.], v. 5, n. 2, p. 9-16, 2012.

# Apêndice A

## Análise da Combinação de Classificador e Vetor de Características

Neste apêndice, são descritos os resultados obtidos para as combinações avaliadas considerando a combinação classificador e vetor de características, a saber (REPARAI, 2013):

- C1-D1: Classificador 1 com características do domínio 1;
- C1-D2: Classificador 1 com características do domínio 2;
- C1-HÍB: Classificador 1 com características do domínio híbrido;
- C2- D1: Classificador 2 com características do domínio 1;
- C2- D2: Classificador 2 com características do domínio 2;
- C2-HÍB: Classificador 2 com características do domínio híbrido;
- MULT-D1: Multiclassificador com características do domínio 1;
- MULT- D2: Multiclassificador com características do domínio 2;
- MULT-HÍB: Multiclassificador com características do domínio híbrido.

A seguir, da Tabela 11 a Tabela 19, são apresentados os resultados obtidos para cada ponto de captura e sistema avaliados. Nelas, são apresentadas as médias de acerto nos testes, por experimento, para cada um dos pontos de captura/microfone, com os valores de média, mediana, mínimo, máximo, coeficiente de variação e desvio padrão.

**Tabela 12. Média de acertos para a validação no C1-D1. (continua)**

Experim.	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
1	94,34%	91,09%	87,19%	89,47%	90,50%	86,84%	90,50%	90,37%	85,95%	90,23%	87,60%	87,22%	88,53%	95,45%
2	91,04%	91,83%	87,60%	87,59%	90,50%	86,84%	90,08%	91,28%	91,32%	88,72%	85,95%	85,71%	87,16%	92,15%
3	94,34%	90,10%	86,36%	92,11%	89,26%	86,09%	92,15%	92,66%	91,74%	93,23%	90,08%	90,98%	91,28%	94,21%
4	93,87%	91,34%	88,84%	89,85%	88,43%	86,47%	91,32%	92,20%	90,91%	93,23%	90,08%	90,23%	92,66%	95,45%
5	93,40%	89,11%	87,19%	87,97%	89,26%	87,59%	90,08%	94,95%	89,67%	89,47%	90,91%	89,85%	91,28%	93,39%
6	94,81%	91,09%	85,95%	89,47%	92,98%	90,23%	91,74%	93,12%	90,50%	93,23%	85,12%	85,71%	91,74%	95,45%
7	94,81%	89,60%	86,36%	86,84%	91,32%	89,10%	90,50%	91,28%	91,74%	90,98%	88,02%	87,22%	91,74%	95,45%
8	90,57%	88,12%	85,95%	90,23%	90,08%	91,73%	91,32%	93,12%	89,26%	90,23%	88,43%	86,84%	90,83%	96,28%
9	93,40%	89,85%	90,08%	89,10%	91,74%	86,47%	91,32%	90,83%	90,91%	92,11%	87,60%	86,84%	89,45%	95,87%
10	93,40%	90,35%	86,36%	90,60%	92,56%	89,85%	90,91%	93,12%	88,43%	91,73%	90,08%	89,47%	91,28%	96,69%
11	93,87%	89,60%	89,67%	92,11%	88,84%	90,23%	90,91%	91,74%	92,15%	94,74%	92,56%	88,35%	94,04%	94,63%
12	93,40%	92,08%	90,91%	89,10%	92,98%	88,72%	93,39%	90,37%	90,91%	92,48%	88,43%	90,60%	92,66%	96,69%
13	93,87%	90,35%	84,71%	86,09%	92,15%	92,48%	89,67%	92,20%	91,32%	91,73%	88,02%	88,72%	90,37%	94,21%
14	94,34%	92,57%	88,43%	89,85%	92,98%	89,47%	91,32%	94,04%	91,74%	90,60%	89,67%	90,60%	92,66%	97,52%
15	94,81%	91,09%	87,19%	89,10%	90,91%	87,59%	89,67%	88,99%	90,50%	90,98%	87,19%	87,59%	83,03%	93,39%
16	93,40%	90,59%	85,54%	88,72%	91,74%	88,35%	91,32%	94,04%	90,91%	90,98%	89,67%	89,10%	90,37%	92,98%
17	94,34%	92,08%	86,36%	87,59%	90,08%	87,59%	90,50%	92,20%	90,50%	90,98%	87,60%	88,35%	88,99%	97,11%
18	93,40%	89,36%	86,36%	86,47%	91,74%	88,72%	92,15%	89,91%	92,15%	87,22%	88,02%	87,22%	91,28%	93,80%
19	93,40%	92,57%	86,78%	90,60%	91,74%	86,84%	89,67%	91,74%	93,39%	90,60%	90,08%	89,47%	92,20%	95,45%
20	91,04%	91,34%	88,84%	87,59%	87,19%	88,35%	88,84%	89,45%	90,50%	90,23%	84,71%	86,09%	85,78%	93,39%
21	88,68%	87,38%	87,60%	88,35%	89,67%	88,72%	90,91%	91,74%	92,56%	87,97%	89,26%	89,10%	91,28%	94,21%
22	94,81%	90,59%	89,67%	88,35%	92,56%	86,47%	92,15%	91,28%	91,32%	91,73%	90,50%	92,11%	90,83%	97,93%
23	91,98%	88,37%	90,91%	92,11%	90,50%	89,10%	91,32%	92,66%	90,08%	90,98%	90,08%	89,10%	91,74%	96,69%
24	94,34%	91,09%	87,19%	89,47%	90,50%	86,84%	90,50%	90,37%	85,95%	90,23%	87,60%	87,22%	88,53%	95,45%

**Tabela 12. Desempenho de classificação do C1- D1. (continuação)**

Experim.	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
<b>25</b>	95,28%	90,59%	88,02%	88,35%	90,91%	86,47%	92,56%	90,37%	95,04%	93,23%	90,08%	89,85%	91,28%	95,45%
<b>26</b>	94,34%	90,10%	91,32%	88,72%	90,50%	88,72%	88,43%	94,04%	93,39%	92,86%	88,84%	90,23%	90,37%	96,69%
<b>27</b>	94,34%	90,59%	88,02%	87,59%	88,43%	87,59%	88,84%	93,12%	89,26%	94,36%	87,19%	87,22%	89,91%	93,39%
<b>28</b>	91,51%	91,58%	87,60%	91,73%	93,80%	88,35%	91,32%	93,58%	91,74%	94,74%	90,08%	88,72%	92,20%	92,98%
<b>29</b>	93,87%	89,85%	89,26%	91,73%	90,08%	88,35%	90,50%	94,95%	92,98%	91,35%	87,19%	90,60%	91,28%	94,21%
<b>30</b>	95,75%	90,59%	88,02%	90,23%	94,63%	93,23%	92,56%	94,04%	89,67%	92,86%	90,08%	87,97%	91,74%	96,28%
<b>31</b>	92,92%	89,60%	86,78%	89,85%	88,43%	89,47%	89,67%	91,28%	93,39%	92,48%	88,02%	87,97%	90,83%	95,04%
<b>32</b>	94,81%	90,10%	86,78%	87,97%	89,67%	88,35%	89,67%	93,12%	88,84%	91,35%	87,19%	86,84%	90,37%	94,21%
<b>33</b>	91,51%	89,85%	89,67%	87,59%	90,50%	89,47%	91,32%	91,74%	92,56%	90,98%	90,08%	88,35%	91,74%	94,63%
<b>34</b>	93,40%	91,34%	88,43%	87,22%	89,67%	89,10%	90,50%	91,74%	91,32%	91,35%	89,26%	87,59%	90,37%	95,87%
<b>35</b>	91,51%	92,33%	87,19%	90,60%	90,50%	89,10%	91,32%	91,74%	91,74%	91,73%	89,26%	88,35%	89,91%	96,69%
<b>36</b>	90,09%	91,34%	87,19%	91,35%	91,32%	89,10%	92,98%	93,12%	91,74%	91,73%	90,50%	87,59%	92,20%	96,28%
<b>37</b>	94,34%	90,84%	90,50%	90,23%	91,32%	88,72%	92,56%	93,12%	92,15%	90,98%	91,74%	90,60%	90,83%	97,11%
<b>38</b>	91,04%	89,36%	88,43%	90,23%	90,08%	90,23%	90,91%	93,12%	93,39%	90,23%	87,19%	89,85%	89,91%	95,04%
<b>39</b>	90,57%	91,58%	89,26%	92,48%	88,84%	89,85%	89,67%	92,66%	88,84%	91,73%	90,50%	88,72%	92,20%	96,28%
<b>40</b>	96,23%	89,36%	91,32%	89,10%	87,60%	89,47%	92,98%	92,20%	92,56%	92,86%	90,08%	88,72%	90,37%	94,63%
<b>Média</b>	<b>93,30%</b>	<b>90,43%</b>	<b>88,01%</b>	<b>89,39%</b>	<b>90,67%</b>	<b>88,69%</b>	<b>91,00%</b>	<b>92,24%</b>	<b>91,21%</b>	<b>91,56%</b>	<b>88,95%</b>	<b>88,62%</b>	<b>90,65%</b>	<b>90,71%</b>
<b>Mediana</b>	<b>93,63%</b>	<b>90,59%</b>	<b>87,60%</b>	<b>89,29%</b>	<b>90,50%</b>	<b>88,72%</b>	<b>91,12%</b>	<b>92,20%</b>	<b>91,32%</b>	<b>91,54%</b>	<b>89,26%</b>	<b>88,72%</b>	<b>91,06%</b>	<b>90,79%</b>
<b>Mínimo</b>	<b>88,68%</b>	<b>87,38%</b>	<b>84,71%</b>	<b>86,09%</b>	<b>87,19%</b>	<b>86,09%</b>	<b>88,43%</b>	<b>88,99%</b>	<b>85,95%</b>	<b>87,22%</b>	<b>84,71%</b>	<b>85,71%</b>	<b>83,03%</b>	<b>86,88%</b>
<b>Máximo</b>	<b>96,23%</b>	<b>92,57%</b>	<b>91,32%</b>	<b>92,48%</b>	<b>94,63%</b>	<b>93,23%</b>	<b>93,39%</b>	<b>94,95%</b>	<b>95,04%</b>	<b>94,74%</b>	<b>92,56%</b>	<b>92,11%</b>	<b>94,04%</b>	<b>93,94%</b>
<b>Desvio Padrão</b>	<b>1,73%</b>	<b>1,27%</b>	<b>1,68%</b>	<b>1,71%</b>	<b>1,67%</b>	<b>1,60%</b>	<b>1,22%</b>	<b>1,41%</b>	<b>1,67%</b>	<b>1,64%</b>	<b>1,73%</b>	<b>1,52%</b>	<b>1,95%</b>	<b>1,43%</b>

**Tabela 13. Desempenho de classificação do C2- D1. (continua)**

Experim.	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
1	99,53%	91,58%	95,45%	92,48%	93,80%	92,48%	93,80%	89,45%	92,56%	95,86%	96,28%	95,86%	92,20%	99,17%
2	99,53%	93,81%	93,39%	85,71%	93,39%	89,85%	94,21%	85,78%	95,45%	93,98%	90,08%	97,37%	94,04%	98,76%
3	99,06%	92,57%	88,02%	96,62%	88,02%	87,22%	88,84%	90,37%	88,43%	91,73%	90,91%	96,62%	93,58%	98,76%
4	98,58%	91,83%	97,52%	92,48%	95,45%	95,49%	94,21%	94,04%	92,98%	94,74%	95,45%	98,12%	95,41%	97,52%
5	99,06%	90,10%	93,39%	92,48%	95,04%	89,10%	93,39%	95,41%	94,21%	93,98%	94,63%	94,74%	93,12%	99,59%
6	99,06%	93,32%	95,45%	93,98%	95,45%	95,11%	90,50%	91,74%	94,63%	94,74%	93,39%	92,48%	94,95%	98,35%
7	98,58%	89,85%	96,69%	89,10%	94,63%	91,35%	95,87%	90,83%	89,67%	95,86%	92,56%	97,74%	96,79%	99,59%
8	99,53%	89,11%	94,21%	93,61%	93,80%	94,36%	93,80%	91,74%	93,80%	94,74%	93,80%	95,86%	95,87%	98,76%
9	98,58%	93,07%	88,02%	90,60%	94,21%	95,86%	86,36%	88,07%	86,36%	95,49%	89,67%	96,99%	91,28%	97,11%
10	98,58%	90,35%	98,35%	92,86%	95,87%	90,60%	95,87%	89,91%	95,45%	95,86%	92,15%	98,12%	96,79%	97,93%
11	99,06%	92,33%	97,52%	93,61%	94,21%	95,86%	96,28%	91,74%	96,69%	95,86%	91,74%	96,24%	97,71%	94,21%
12	97,64%	93,81%	91,74%	90,98%	95,04%	94,74%	95,45%	89,45%	95,87%	93,61%	97,52%	95,11%	94,95%	98,35%
13	94,81%	91,83%	92,98%	91,73%	95,45%	92,48%	90,50%	94,04%	95,87%	96,24%	96,28%	98,50%	94,04%	98,35%
14	99,06%	94,55%	92,15%	93,23%	94,21%	96,62%	94,63%	92,20%	95,45%	96,62%	94,21%	96,62%	96,33%	97,52%
15	99,06%	92,33%	97,11%	86,84%	94,63%	95,86%	95,04%	91,28%	92,56%	93,23%	93,39%	95,11%	93,58%	99,59%
16	92,92%	92,82%	95,04%	90,60%	92,15%	87,22%	92,98%	95,41%	88,84%	93,98%	92,15%	95,49%	95,87%	98,35%
17	98,58%	94,06%	98,35%	91,73%	97,11%	93,23%	95,45%	91,74%	94,21%	92,11%	95,45%	97,37%	92,66%	98,35%
18	99,53%	90,10%	89,67%	93,61%	94,63%	95,11%	96,69%	90,37%	96,28%	95,49%	94,63%	96,99%	96,33%	96,28%
19	95,75%	91,34%	91,32%	93,98%	96,28%	93,23%	92,98%	93,12%	95,04%	89,47%	92,98%	90,98%	92,66%	97,52%
20	97,64%	92,08%	96,69%	93,23%	95,04%	98,12%	95,45%	88,07%	95,04%	93,98%	94,21%	97,74%	95,41%	96,28%
21	98,58%	90,10%	98,35%	95,86%	91,32%	86,84%	93,39%	91,74%	95,45%	91,73%	92,15%	96,24%	96,79%	95,04%
22	99,06%	93,56%	97,11%	90,98%	94,63%	91,35%	98,35%	92,66%	96,28%	97,37%	92,56%	95,86%	94,04%	98,76%
23	94,34%	90,35%	91,74%	90,23%	94,63%	95,11%	89,67%	91,74%	93,80%	93,98%	94,21%	97,74%	95,41%	95,04%
24	94,34%	89,85%	97,52%	89,47%	96,28%	88,72%	96,28%	92,20%	97,11%	95,86%	95,87%	95,11%	93,12%	100,00%

**Tabela 13. Desempenho de classificação do C2-D1. (continuação)**

Experim.	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
<b>25</b>	98,11%	91,58%	97,93%	92,48%	94,21%	96,99%	92,98%	91,74%	95,45%	97,74%	95,45%	97,37%	92,20%	99,59%
<b>26</b>	97,64%	88,86%	90,08%	91,73%	92,98%	95,11%	92,15%	88,99%	95,87%	95,11%	90,08%	94,74%	96,33%	98,76%
<b>27</b>	99,53%	93,32%	91,74%	93,61%	94,63%	93,23%	94,21%	89,91%	92,98%	90,23%	92,56%	93,23%	93,58%	99,59%
<b>28</b>	99,53%	91,83%	95,45%	93,98%	93,39%	89,47%	96,69%	90,83%	95,04%	95,49%	93,39%	96,24%	97,25%	99,17%
<b>29</b>	99,06%	91,34%	91,32%	95,49%	94,21%	90,60%	93,39%	92,20%	96,28%	92,48%	92,98%	95,49%	92,20%	95,87%
<b>30</b>	97,17%	90,35%	95,87%	90,98%	96,28%	93,98%	95,87%	94,04%	96,28%	90,23%	93,39%	93,23%	92,20%	96,69%
<b>31</b>	98,58%	89,60%	93,80%	93,98%	94,63%	90,23%	95,04%	91,28%	95,04%	95,49%	95,45%	98,12%	97,25%	98,76%
<b>32</b>	99,53%	90,59%	95,45%	94,36%	95,04%	88,72%	96,69%	94,04%	89,26%	90,23%	86,36%	92,86%	94,50%	97,52%
<b>33</b>	91,98%	90,35%	96,28%	93,61%	90,50%	94,36%	94,63%	94,95%	96,69%	96,24%	97,11%	97,37%	96,79%	100,00%
<b>34</b>	98,11%	90,84%	96,69%	89,47%	95,45%	87,59%	93,80%	89,45%	92,56%	87,59%	94,63%	98,12%	91,74%	92,98%
<b>35</b>	95,75%	93,07%	92,56%	91,35%	96,28%	92,11%	97,11%	91,74%	92,98%	93,61%	96,28%	92,48%	93,58%	96,28%
<b>36</b>	96,70%	92,33%	88,43%	92,86%	95,04%	92,11%	97,52%	90,83%	96,28%	92,86%	95,04%	96,24%	92,20%	96,28%
<b>37</b>	99,53%	91,83%	98,35%	88,72%	96,69%	90,98%	97,52%	89,91%	93,39%	89,85%	95,45%	88,35%	91,74%	95,04%
<b>38</b>	98,58%	92,08%	95,87%	93,61%	94,63%	89,85%	94,63%	91,28%	93,39%	92,48%	90,08%	96,62%	93,12%	97,93%
<b>39</b>	97,17%	89,85%	97,11%	89,85%	95,87%	92,11%	95,45%	94,04%	95,45%	92,11%	96,69%	97,74%	90,83%	100,00%
<b>40</b>	97,64%	93,56%	94,21%	94,74%	92,98%	92,11%	94,21%	89,45%	92,98%	96,62%	95,87%	96,99%	92,20%	96,69%
<b>Média</b>	<b>97,88%</b>	<b>91,65%</b>	<b>94,47%</b>	<b>92,17%</b>	<b>94,45%</b>	<b>92,39%</b>	<b>94,30%</b>	<b>91,44%</b>	<b>94,05%</b>	<b>93,87%</b>	<b>93,68%</b>	<b>95,86%</b>	<b>94,27%</b>	<b>97,76%</b>
<b>Mediana</b>	<b>98,58%</b>	<b>91,83%</b>	<b>95,45%</b>	<b>92,48%</b>	<b>94,63%</b>	<b>92,29%</b>	<b>94,63%</b>	<b>91,74%</b>	<b>95,04%</b>	<b>93,98%</b>	<b>94,01%</b>	<b>96,24%</b>	<b>94,04%</b>	<b>98,35%</b>
<b>Mínimo</b>	<b>91,98%</b>	<b>88,86%</b>	<b>88,02%</b>	<b>85,71%</b>	<b>88,02%</b>	<b>86,84%</b>	<b>86,36%</b>	<b>85,78%</b>	<b>86,36%</b>	<b>87,59%</b>	<b>86,36%</b>	<b>88,35%</b>	<b>90,83%</b>	<b>92,98%</b>
<b>Máximo</b>	<b>99,53%</b>	<b>94,55%</b>	<b>98,35%</b>	<b>96,62%</b>	<b>97,11%</b>	<b>98,12%</b>	<b>98,35%</b>	<b>95,41%</b>	<b>97,11%</b>	<b>97,74%</b>	<b>97,52%</b>	<b>98,50%</b>	<b>97,71%</b>	<b>100,00%</b>
<b>Desvio Padrão</b>	1,91%	1,51%	3,06%	2,32%	1,72%	2,98%	2,48%	2,10%	2,51%	2,39%	2,37%	2,19%	1,95%	1,73%

**Tabela 14. Desempenho de classificação do MULT-D1. (continua)**

Experim.	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
1	99,53%	92,33%	96,28%	93,23%	93,80%	92,48%	94,21%	90,37%	92,98%	96,62%	97,11%	95,86%	92,66%	99,59%
2	99,53%	94,31%	93,80%	86,09%	93,80%	89,85%	94,63%	85,78%	95,87%	94,74%	90,08%	97,74%	94,50%	98,76%
3	99,06%	92,82%	88,84%	97,37%	88,84%	87,22%	88,84%	90,37%	88,84%	92,86%	91,32%	96,99%	94,04%	98,76%
4	98,58%	92,08%	98,35%	93,23%	95,45%	95,49%	94,63%	94,04%	93,39%	95,11%	95,87%	98,12%	95,41%	97,52%
5	99,06%	90,35%	94,63%	92,86%	94,63%	89,10%	93,80%	95,41%	94,63%	94,36%	94,63%	95,11%	93,12%	99,59%
6	99,06%	93,32%	95,87%	94,74%	95,87%	95,49%	90,91%	91,74%	94,63%	94,74%	93,39%	92,86%	94,95%	98,76%
7	98,58%	90,10%	97,93%	89,85%	95,45%	92,48%	96,69%	90,83%	90,91%	96,62%	92,98%	97,74%	96,79%	99,59%
8	99,53%	89,11%	95,87%	93,61%	94,21%	94,36%	95,45%	92,20%	94,21%	95,11%	93,80%	95,86%	96,33%	98,76%
9	98,58%	93,07%	89,26%	90,98%	93,80%	95,86%	86,78%	88,99%	86,36%	96,24%	89,67%	97,74%	91,74%	97,11%
10	99,06%	90,84%	98,35%	92,86%	95,87%	91,35%	96,28%	89,91%	95,45%	95,86%	93,39%	98,12%	96,79%	97,93%
11	99,06%	92,33%	98,76%	93,61%	95,04%	96,24%	96,28%	92,20%	96,69%	96,62%	91,74%	96,62%	98,62%	94,21%
12	97,64%	94,06%	92,15%	92,48%	95,04%	95,86%	95,87%	89,91%	95,87%	94,36%	97,52%	95,11%	95,41%	98,35%
13	94,81%	91,83%	93,39%	92,11%	95,45%	92,48%	92,15%	94,04%	96,69%	96,24%	96,28%	98,50%	94,95%	98,35%
14	99,06%	94,55%	92,56%	94,36%	94,21%	96,99%	95,04%	92,20%	95,45%	96,62%	94,21%	96,62%	96,33%	97,93%
15	99,06%	92,33%	97,11%	87,97%	94,63%	96,24%	95,45%	92,66%	93,39%	93,61%	93,80%	95,11%	94,50%	99,59%
16	92,92%	92,82%	96,69%	92,11%	92,15%	87,59%	95,45%	96,33%	92,15%	94,74%	93,39%	95,86%	96,79%	97,52%
17	98,11%	94,06%	98,35%	92,48%	97,52%	93,23%	95,45%	91,74%	95,45%	92,11%	96,28%	97,37%	92,66%	98,76%
18	99,53%	90,35%	90,91%	93,98%	94,63%	95,11%	97,11%	90,37%	96,69%	95,86%	95,87%	97,37%	96,33%	96,69%
19	95,75%	91,58%	91,74%	95,11%	95,87%	93,61%	94,21%	93,12%	95,04%	90,23%	92,98%	91,35%	92,66%	97,93%
20	97,64%	92,57%	97,11%	93,23%	95,04%	98,12%	95,87%	88,99%	95,45%	94,36%	94,21%	97,74%	96,33%	96,28%
21	98,58%	90,35%	99,17%	96,24%	91,74%	87,59%	94,63%	91,74%	96,28%	92,48%	92,15%	96,24%	96,79%	95,04%
22	99,06%	93,56%	98,35%	92,86%	94,63%	92,11%	98,35%	92,66%	96,28%	97,74%	92,56%	95,86%	94,04%	99,17%
23	95,28%	90,84%	93,39%	90,98%	94,63%	95,11%	91,32%	91,74%	93,80%	94,74%	94,21%	97,74%	96,79%	95,04%
24	95,28%	90,10%	97,93%	89,85%	96,28%	89,10%	96,28%	92,20%	97,11%	96,62%	95,87%	95,11%	93,58%	100,00%



**Tabela 14. Desempenho de classificação do MULT-D1. (continuação)**

Experim.	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
25	98,58%	91,83%	98,76%	92,86%	94,63%	96,99%	93,39%	91,74%	95,45%	98,12%	97,11%	97,74%	92,66%	99,59%
26	97,64%	89,11%	91,32%	92,86%	94,21%	95,86%	93,80%	89,45%	96,28%	96,24%	90,50%	95,11%	97,25%	98,76%
27	99,53%	93,32%	95,04%	93,61%	94,63%	93,61%	95,04%	89,91%	93,80%	91,73%	92,98%	93,98%	94,04%	99,59%
28	99,53%	92,33%	96,69%	93,98%	93,39%	89,47%	96,69%	90,83%	95,04%	96,62%	93,39%	96,62%	97,25%	99,59%
29	99,06%	91,83%	93,80%	95,49%	94,21%	91,35%	93,80%	92,20%	96,28%	94,74%	93,39%	96,62%	92,20%	95,87%
30	97,17%	90,59%	96,28%	91,73%	96,28%	94,36%	96,28%	94,04%	96,69%	91,73%	93,39%	93,23%	92,20%	96,69%
31	98,58%	90,10%	94,63%	94,36%	95,04%	90,23%	95,87%	91,74%	95,87%	95,49%	95,45%	98,87%	97,71%	98,76%
32	100,00%	90,59%	96,28%	94,74%	95,87%	88,72%	97,11%	94,04%	90,08%	91,35%	86,36%	93,61%	94,50%	97,52%
33	92,92%	90,59%	97,11%	93,61%	90,50%	94,36%	95,04%	94,95%	97,11%	96,24%	97,11%	97,37%	96,79%	100,00%
34	98,58%	91,09%	97,11%	90,98%	95,45%	88,35%	95,04%	89,45%	95,04%	89,10%	94,63%	98,50%	92,20%	92,98%
35	96,23%	93,32%	92,98%	91,73%	97,11%	92,11%	97,11%	92,20%	93,39%	93,98%	96,69%	92,86%	94,04%	96,28%
36	97,17%	92,33%	88,84%	93,23%	95,04%	92,48%	97,52%	91,74%	97,11%	93,23%	95,04%	96,24%	92,66%	96,28%
37	99,53%	91,83%	98,76%	89,10%	96,69%	91,73%	97,93%	89,91%	94,21%	90,60%	95,45%	88,35%	92,66%	95,04%
38	99,06%	92,08%	96,28%	93,61%	94,63%	89,85%	95,04%	91,28%	93,80%	93,61%	90,08%	97,74%	93,58%	97,93%
39	97,17%	89,85%	97,52%	90,23%	95,87%	92,11%	95,45%	94,04%	95,45%	92,48%	96,69%	97,74%	90,83%	100,00%
40	98,11%	93,56%	94,63%	94,74%	93,39%	93,98%	95,04%	90,37%	93,80%	96,99%	95,87%	97,37%	93,12%	96,69%
Média	98,03%	91,85%	95,32%	92,73%	94,64%	92,72%	94,90%	91,69%	94,58%	94,52%	93,94%	96,12%	94,64%	97,82%
Mediana	98,58%	91,96%	96,28%	93,05%	94,63%	92,48%	95,25%	91,74%	95,25%	94,74%	94,01%	96,62%	94,50%	94,80%
Mínimo	92,92%	89,11%	88,84%	86,09%	88,84%	87,22%	86,78%	85,78%	86,36%	89,10%	86,36%	88,35%	90,83%	88,54%
Máximo	100,00%	94,55%	99,17%	97,37%	97,52%	98,12%	98,35%	96,33%	97,11%	98,12%	97,52%	98,87%	98,62%	100,00%
Desvio Padrão	1,76%	1,46%	2,92%	2,19%	1,65%	2,96%	2,30%	2,03%	2,31%	2,16%	2,43%	2,18%	1,97%	1,75%

**Tabela 15. Desempenho de classificação do C1-D2. (continua)**

Experim.	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
1	92,45%	99,75%	93,80%	98,87%	97,93%	96,62%	86,78%	94,95%	94,63%	96,24%	93,80%	98,50%	95,87%	91,32%
2	89,15%	99,26%	90,08%	97,37%	99,17%	96,62%	85,54%	97,25%	94,63%	95,11%	92,56%	88,72%	95,41%	89,67%
3	95,75%	99,50%	98,76%	94,74%	99,59%	91,73%	88,02%	95,41%	90,91%	95,86%	98,35%	97,74%	94,95%	96,28%
4	92,45%	98,76%	95,04%	96,62%	98,76%	97,37%	86,78%	95,41%	93,80%	96,24%	97,93%	98,12%	96,79%	94,21%
5	91,51%	99,50%	93,80%	97,37%	93,80%	95,11%	88,84%	96,79%	96,69%	96,99%	98,76%	93,98%	96,79%	93,39%
6	93,87%	99,01%	93,39%	98,87%	98,76%	97,74%	88,84%	95,87%	95,04%	98,12%	96,69%	97,37%	97,71%	92,56%
7	92,45%	99,26%	94,21%	96,99%	100,00%	93,23%	88,02%	93,58%	95,45%	93,61%	96,28%	96,62%	97,71%	93,39%
8	90,57%	98,76%	100,00%	97,37%	94,63%	96,99%	88,43%	97,25%	96,69%	95,86%	98,35%	90,60%	95,41%	93,39%
9	93,40%	99,26%	95,45%	98,50%	98,76%	97,37%	87,19%	93,58%	93,80%	99,25%	91,74%	93,98%	96,79%	94,21%
10	91,51%	99,01%	92,98%	96,99%	99,17%	96,24%	87,60%	95,41%	95,04%	98,12%	92,15%	98,12%	96,33%	93,39%
11	94,34%	99,01%	95,45%	96,99%	99,17%	96,99%	88,02%	95,87%	91,32%	96,99%	97,11%	97,37%	94,95%	94,21%
12	94,34%	99,01%	93,80%	96,62%	97,52%	97,74%	88,43%	96,33%	94,21%	97,37%	96,69%	95,49%	97,25%	95,45%
13	92,45%	99,26%	92,56%	96,99%	97,93%	95,86%	88,02%	94,50%	94,21%	95,11%	92,56%	96,99%	96,33%	91,74%
14	94,81%	99,50%	96,69%	97,74%	99,17%	96,24%	90,91%	98,17%	94,21%	98,12%	98,35%	98,87%	98,17%	96,28%
15	91,98%	99,50%	95,45%	94,74%	99,59%	95,49%	85,12%	94,04%	93,80%	98,50%	96,69%	95,86%	98,62%	91,74%
16	91,98%	98,76%	94,21%	96,99%	98,35%	93,98%	88,02%	96,33%	93,80%	97,74%	92,56%	98,50%	98,17%	93,39%
17	91,04%	99,01%	91,74%	98,12%	97,11%	95,86%	85,54%	94,95%	90,50%	89,10%	90,91%	95,11%	97,25%	89,26%
18	92,92%	99,50%	92,98%	96,99%	99,59%	95,49%	84,71%	95,41%	89,67%	96,62%	89,67%	90,60%	93,58%	93,39%
19	94,81%	98,51%	96,28%	96,62%	99,59%	92,11%	89,67%	97,71%	94,63%	97,74%	97,11%	95,86%	96,79%	95,04%
20	89,15%	99,50%	92,15%	96,62%	99,17%	97,74%	84,71%	94,95%	94,21%	93,98%	90,91%	99,25%	94,04%	90,91%
21	92,45%	97,77%	98,35%	93,61%	98,76%	90,23%	90,08%	96,33%	95,04%	97,74%	99,17%	88,35%	95,87%	93,80%
22	93,87%	99,26%	95,04%	97,37%	99,17%	96,99%	88,43%	96,79%	92,15%	98,50%	97,11%	96,99%	98,17%	94,63%
23	91,98%	98,76%	92,56%	96,62%	97,93%	97,37%	84,71%	95,87%	94,21%	96,99%	93,80%	94,74%	97,25%	92,56%
24	91,51%	97,03%	93,39%	96,62%	99,59%	95,86%	89,26%	96,33%	96,28%	93,23%	98,35%	96,24%	95,41%	94,21%

**Tabela 15. Desempenho de classificação do C1-D2. (continuação)**

Experim.	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
<b>25</b>	99,53%	99,26%	97,11%	98,12%	99,17%	96,24%	90,50%	95,41%	93,39%	97,74%	92,15%	96,99%	95,87%	96,28%
<b>26</b>	91,98%	99,01%	93,80%	96,24%	99,59%	96,24%	86,36%	92,20%	94,21%	96,24%	98,35%	97,37%	94,50%	95,04%
<b>27</b>	90,57%	99,50%	97,93%	97,37%	98,35%	96,99%	85,12%	94,50%	92,56%	96,62%	96,28%	90,98%	93,12%	91,32%
<b>28</b>	93,40%	99,50%	100,00%	96,99%	98,76%	94,74%	88,84%	96,79%	95,87%	97,74%	100,00%	98,50%	96,79%	95,87%
<b>29</b>	93,87%	99,01%	100,00%	97,37%	99,59%	95,86%	88,43%	96,79%	92,56%	97,37%	99,59%	97,74%	95,41%	95,04%
<b>30</b>	96,23%	99,01%	94,63%	98,12%	99,17%	97,74%	88,43%	96,79%	90,08%	97,74%	92,15%	97,74%	99,54%	97,11%
<b>31</b>	92,45%	99,26%	95,45%	97,74%	93,39%	96,62%	88,84%	95,41%	95,04%	98,50%	98,35%	99,25%	97,25%	93,80%
<b>32</b>	91,51%	99,01%	92,98%	97,74%	99,17%	95,49%	89,26%	98,17%	96,28%	96,99%	97,52%	89,10%	94,95%	92,98%
<b>33</b>	92,92%	99,26%	93,39%	96,62%	98,76%	95,86%	89,67%	94,95%	95,45%	97,74%	97,11%	97,74%	98,62%	93,80%
<b>34</b>	89,62%	99,75%	92,56%	96,99%	98,35%	95,49%	87,19%	95,41%	92,98%	96,24%	90,91%	95,86%	96,79%	90,08%
<b>35</b>	89,15%	99,50%	92,98%	97,74%	99,59%	91,35%	89,26%	95,87%	94,63%	96,99%	98,35%	95,11%	94,95%	91,74%
<b>36</b>	94,81%	99,01%	96,69%	95,49%	94,21%	89,47%	90,50%	98,17%	94,63%	97,74%	95,45%	92,11%	96,79%	94,21%
<b>37</b>	92,92%	99,26%	93,80%	98,12%	99,17%	96,99%	89,26%	95,87%	95,87%	97,74%	92,15%	97,74%	96,33%	93,39%
<b>38</b>	87,74%	99,26%	91,74%	96,99%	98,76%	96,99%	84,71%	94,04%	94,21%	95,49%	90,08%	91,35%	95,41%	90,08%
<b>39</b>	93,87%	98,76%	99,17%	96,99%	98,76%	96,24%	91,74%	96,79%	94,63%	97,37%	98,76%	97,74%	96,33%	95,45%
<b>40</b>	93,87%	99,01%	99,17%	96,24%	100,00%	96,62%	89,67%	96,33%	93,39%	98,50%	93,80%	93,23%	96,79%	95,04%
<b>Média</b>	<b>92,63%</b>	<b>99,10%</b>	<b>94,99%</b>	<b>97,03%</b>	<b>98,45%</b>	<b>95,65%</b>	<b>87,99%</b>	<b>95,81%</b>	<b>94,02%</b>	<b>96,75%</b>	<b>95,46%</b>	<b>95,56%</b>	<b>96,38%</b>	<b>93,49%</b>
<b>Mediana</b>	<b>92,45%</b>	<b>99,26%</b>	<b>94,21%</b>	<b>96,99%</b>	<b>98,97%</b>	<b>96,24%</b>	<b>88,43%</b>	<b>95,87%</b>	<b>94,21%</b>	<b>97,18%</b>	<b>96,69%</b>	<b>96,80%</b>	<b>96,56%</b>	<b>93,60%</b>
<b>Mínimo</b>	<b>87,74%</b>	<b>97,03%</b>	<b>90,08%</b>	<b>93,61%</b>	<b>93,39%</b>	<b>89,47%</b>	<b>84,71%</b>	<b>92,20%</b>	<b>89,67%</b>	<b>89,10%</b>	<b>89,67%</b>	<b>88,35%</b>	<b>93,12%</b>	<b>89,26%</b>
<b>Máximo</b>	<b>99,53%</b>	<b>99,75%</b>	<b>100,00%</b>	<b>98,87%</b>	<b>100,00%</b>	<b>97,74%</b>	<b>91,74%</b>	<b>98,17%</b>	<b>96,69%</b>	<b>99,25%</b>	<b>100,00%</b>	<b>99,25%</b>	<b>99,54%</b>	<b>98,40%</b>
<b>Desvio Padrão</b>	2,19%	0,50%	2,59%	1,06%	1,64%	2,07%	1,87%	1,32%	1,72%	1,84%	3,10%	3,10%	1,42%	1,94%

**Tabela 16. Desempenho de classificação do C2-D2. (continua)**

Experim.	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
1	100,00%	99,75%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	99,59%
2	100,00%	98,51%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	99,59%
3	99,53%	99,01%	100,00%	99,62%	100,00%	100,00%	100,00%	89,45%	100,00%	100,00%	100,00%	100,00%	100,00%	87,60%
4	100,00%	97,52%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
5	100,00%	99,50%	100,00%	100,00%	100,00%	99,62%	99,59%	100,00%	100,00%	99,62%	100,00%	99,62%	100,00%	100,00%
6	100,00%	97,52%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	95,49%	100,00%	100,00%
7	100,00%	99,50%	100,00%	100,00%	100,00%	100,00%	94,63%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
8	100,00%	99,75%	100,00%	100,00%	99,59%	100,00%	92,56%	100,00%	100,00%	100,00%	99,59%	98,87%	100,00%	100,00%
9	100,00%	99,50%	100,00%	100,00%	100,00%	100,00%	95,87%	100,00%	86,36%	99,62%	87,19%	99,62%	99,54%	100,00%
10	100,00%	97,77%	99,59%	100,00%	100,00%	85,34%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
11	100,00%	99,75%	99,17%	99,62%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
12	100,00%	98,02%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%
13	100,00%	96,29%	100,00%	100,00%	100,00%	100,00%	99,17%	100,00%	99,59%	99,62%	100,00%	100,00%	100,00%	100,00%
14	100,00%	99,75%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
15	100,00%	97,52%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
16	100,00%	99,26%	100,00%	100,00%	100,00%	100,00%	99,17%	100,00%	100,00%	99,62%	100,00%	100,00%	100,00%	99,17%
17	99,53%	99,26%	100,00%	100,00%	100,00%	100,00%	98,76%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
18	100,00%	99,26%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
19	100,00%	97,52%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
20	100,00%	99,50%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	94,74%	100,00%	100,00%
21	100,00%	97,77%	99,59%	100,00%	99,59%	100,00%	100,00%	100,00%	93,80%	100,00%	100,00%	100,00%	100,00%	100,00%
22	100,00%	99,75%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
23	99,53%	98,27%	99,59%	100,00%	87,60%	86,84%	100,00%	89,45%	100,00%	86,84%	87,60%	86,84%	100,00%	100,00%
24	99,53%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%

**Tabela 16. Desempenho de classificação do C2-D2. (continuação)**

Experim.	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
25	100,00%	99,75%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
26	83,96%	97,52%	99,59%	84,96%	100,00%	84,96%	99,59%	100,00%	100,00%	84,96%	85,95%	84,96%	86,70%	85,95%
27	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	93,39%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
28	86,79%	99,75%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	88,43%
29	85,38%	98,02%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	88,53%	100,00%
30	99,53%	96,78%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
31	100,00%	99,50%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
32	100,00%	99,01%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
33	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	99,62%	99,54%	100,00%
34	100,00%	97,52%	99,17%	100,00%	100,00%	100,00%	100,00%	100,00%	90,08%	100,00%	100,00%	100,00%	100,00%	100,00%
35	100,00%	99,01%	85,12%	83,83%	85,12%	83,83%	85,12%	87,16%	85,12%	83,83%	85,12%	100,00%	87,16%	85,12%
36	100,00%	98,27%	99,59%	100,00%	100,00%	99,62%	100,00%	100,00%	100,00%	100,00%	100,00%	99,62%	100,00%	100,00%
37	99,06%	100,00%	100,00%	96,24%	100,00%	87,22%	99,59%	100,00%	100,00%	87,59%	100,00%	90,98%	90,37%	100,00%
38	100,00%	98,02%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
39	100,00%	98,02%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
40	100,00%	96,78%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
Média	98,82%	98,71%	99,49%	99,11%	99,30%	98,19%	98,83%	99,15%	98,86%	98,54%	98,63%	98,76%	98,80%	98,64%
Mediana	100,00%	99,01%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
Mínimo	83,96%	96,29%	85,12%	83,83%	85,12%	83,83%	85,12%	87,16%	85,12%	83,83%	85,12%	84,96%	86,70%	85,12%
Máximo	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
Desvio Padrão	3,90%	1,07%	2,34%	3,47%	3,02%	4,82%	2,85%	3,03%	3,55%	4,33%	4,12%	3,47%	3,61%	4,03%
														3,90%

**Tabela 17. Desempenho de classificação do MULT-D2. (continua)**

Experim.	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
1	100,00%	99,75%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
2	100,00%	98,76%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
3	100,00%	99,01%	100,00%	99,62%	100,00%	100,00%	100,00%	98,17%	100,00%	100,00%	100,00%	100,00%	100,00%	87,60%
4	100,00%	98,51%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
5	100,00%	99,50%	100,00%	100,00%	99,62%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
6	100,00%	98,02%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	98,50%	100,00%	100,00%
7	100,00%	99,75%	100,00%	100,00%	100,00%	100,00%	95,04%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
8	100,00%	99,75%	100,00%	100,00%	100,00%	100,00%	92,56%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%
9	100,00%	99,50%	100,00%	100,00%	100,00%	100,00%	95,87%	100,00%	87,19%	99,62%	87,19%	99,62%	100,00%	100,00%
10	100,00%	98,27%	99,59%	100,00%	100,00%	85,34%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
11	100,00%	99,75%	99,59%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
12	100,00%	98,02%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
13	100,00%	97,03%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%
14	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
15	100,00%	97,77%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
16	100,00%	99,50%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	99,62%	100,00%	100,00%	100,00%	100,00%
17	100,00%	99,26%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
18	100,00%	99,26%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
19	100,00%	97,77%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
20	100,00%	99,50%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	95,11%	100,00%	100,00%
21	100,00%	98,27%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	98,76%	100,00%	100,00%	100,00%	100,00%	100,00%
22	100,00%	99,75%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
23	99,53%	98,27%	100,00%	100,00%	87,60%	86,84%	100,00%	89,45%	100,00%	86,84%	87,60%	86,84%	100,00%	100,00%
24	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%

**Tabela 17. Desempenho de classificação do MULT-D2. (continuação)**

Experim.	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
25	100,00%	99,75%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
26	83,96%	97,77%	99,59%	84,96%	100,00%	84,96%	100,00%	100,00%	100,00%	84,96%	85,95%	84,96%	86,70%	85,95%
27	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	93,80%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
28	86,79%	99,75%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	88,43%
29	85,38%	98,02%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	88,53%	100,00%
30	99,53%	97,28%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
31	100,00%	99,50%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
32	100,00%	99,01%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
33	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	99,62%	99,54%	100,00%
34	100,00%	98,51%	99,17%	100,00%	100,00%	100,00%	100,00%	100,00%	94,63%	100,00%	100,00%	100,00%	100,00%	100,00%
35	100,00%	99,26%	85,12%	83,83%	85,12%	83,83%	85,12%	87,16%	85,12%	83,83%	85,12%	100,00%	87,16%	85,12%
36	100,00%	98,76%	99,59%	100,00%	100,00%	99,62%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
37	100,00%	100,00%	100,00%	96,62%	100,00%	87,97%	99,59%	100,00%	100,00%	87,97%	100,00%	94,74%	90,37%	100,00%
38	100,00%	98,02%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
39	100,00%	98,51%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
40	100,00%	96,78%	100,00%	100,00%	100,00%	100,00%	99,59%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
Média	98,88%	98,90%	99,52%	99,13%	99,32%	98,20%	98,94%	99,37%	99,13%	98,57%	98,64%	98,98%	98,81%	98,68%
Mediana	100,00%	99,13%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	99,94%
Mínimo	83,96%	96,78%	85,12%	83,83%	85,12%	83,83%	85,12%	87,16%	85,12%	83,83%	85,12%	84,96%	86,70%	85,84%
Máximo	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
Desvio Padrão	3,91%	0,91%	2,34%	3,47%	3,02%	4,78%	2,84%	2,60%	3,15%	4,31%	4,12%	3,25%	3,61%	3,31%

**Tabela 18. Desempenho de classificação do C1-HÍB. (continua)**

Experim.	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
1	99,53%	92,33%	95,04%	96,99%	93,80%	94,74%	96,28%	94,04%	96,69%	94,36%	95,45%	92,86%	95,87%	97,52%
2	95,28%	94,06%	95,45%	97,37%	98,35%	95,49%	96,69%	96,79%	98,35%	93,98%	94,63%	91,73%	94,50%	97,93%
3	95,28%	93,56%	97,52%	95,86%	98,35%	96,99%	95,04%	94,95%	92,98%	95,49%	93,39%	93,98%	96,33%	99,17%
4	99,53%	94,55%	96,28%	96,99%	97,11%	95,86%	96,28%	100,00%	97,52%	96,62%	95,45%	92,86%	96,33%	98,76%
5	99,06%	93,07%	95,04%	98,12%	99,59%	95,11%	92,56%	95,87%	96,69%	96,24%	95,04%	95,11%	96,33%	97,52%
6	98,11%	92,08%	95,87%	96,24%	93,39%	96,62%	97,93%	98,62%	99,17%	96,62%	94,21%	94,74%	98,17%	97,11%
7	99,53%	93,07%	95,87%	97,37%	95,87%	96,24%	94,21%	99,54%	97,52%	96,99%	94,21%	93,23%	96,79%	97,93%
8	100,00%	94,06%	95,87%	98,12%	95,04%	95,49%	97,11%	98,62%	97,52%	97,74%	95,87%	94,74%	95,87%	98,35%
9	99,53%	94,06%	95,04%	95,86%	98,35%	96,62%	97,11%	100,00%	97,11%	96,62%	93,80%	93,23%	96,79%	97,52%
10	98,11%	94,31%	94,63%	93,61%	92,15%	93,23%	96,28%	98,62%	98,35%	93,61%	95,87%	92,86%	95,41%	99,17%
11	100,00%	95,79%	97,52%	97,37%	97,52%	96,62%	95,04%	94,04%	96,69%	96,24%	92,15%	93,61%	97,71%	97,52%
12	99,53%	93,56%	95,45%	96,62%	95,45%	95,49%	96,69%	94,95%	96,28%	95,11%	93,80%	95,11%	97,71%	97,11%
13	99,06%	94,31%	98,76%	93,98%	98,35%	95,11%	95,45%	94,04%	97,11%	96,62%	92,56%	90,60%	97,71%	99,17%
14	97,64%	89,85%	91,74%	98,50%	98,76%	94,36%	88,84%	94,95%	96,69%	94,74%	95,04%	94,36%	97,25%	97,93%
15	98,58%	93,81%	92,56%	97,74%	97,52%	96,99%	97,52%	100,00%	97,93%	97,74%	93,39%	96,24%	96,79%	97,93%
16	99,06%	95,79%	97,11%	95,86%	97,52%	97,37%	97,52%	99,08%	95,87%	96,24%	92,56%	95,11%	96,33%	99,17%
17	98,58%	94,06%	94,63%	96,99%	94,21%	94,74%	94,21%	94,95%	97,52%	94,36%	93,39%	89,85%	94,04%	97,93%
18	93,40%	92,33%	95,45%	93,61%	97,52%	93,61%	95,45%	94,95%	95,45%	94,36%	93,39%	94,36%	89,91%	98,76%
19	98,58%	94,06%	96,69%	95,11%	99,17%	93,61%	97,52%	94,95%	96,28%	96,62%	93,80%	92,48%	96,33%	95,04%
20	98,58%	93,07%	93,39%	96,24%	91,74%	95,49%	96,69%	94,50%	98,76%	94,36%	93,80%	92,48%	94,04%	93,80%
21	98,11%	94,06%	97,11%	96,62%	97,93%	96,62%	97,93%	99,54%	98,35%	96,99%	95,04%	95,11%	96,33%	98,35%
22	99,53%	93,32%	94,63%	96,24%	98,76%	96,62%	95,87%	99,08%	97,52%	92,48%	94,63%	94,36%	98,62%	97,11%
23	99,06%	96,04%	95,87%	94,36%	95,45%	94,74%	97,93%	95,87%	97,52%	95,86%	94,21%	93,98%	94,50%	97,93%
24	99,06%	94,31%	96,28%	94,74%	97,93%	96,62%	95,87%	94,95%	95,87%	95,86%	94,63%	93,23%	96,79%	99,17%



**Tabela 18. Desempenho de classificação do C1-HÍB. (continuação)**

Experim.	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
25	97,17%	93,32%	96,28%	94,36%	97,93%	96,24%	93,80%	93,12%	92,56%	92,11%	93,39%	90,98%	89,91%	97,52%
26	99,06%	94,06%	96,28%	97,74%	98,35%	95,49%	95,04%	92,20%	97,11%	98,12%	91,32%	92,86%	96,79%	98,76%
27	98,11%	92,08%	94,63%	96,24%	98,35%	98,12%	97,93%	99,08%	97,11%	96,62%	94,21%	94,36%	96,79%	99,17%
28	99,53%	93,32%	94,63%	92,11%	98,35%	94,36%	96,28%	93,58%	91,32%	93,23%	94,63%	90,23%	95,87%	97,93%
29	99,06%	94,31%	95,87%	96,99%	92,15%	95,49%	96,28%	96,33%	97,11%	96,24%	93,39%	94,74%	93,12%	99,17%
30	98,58%	92,33%	96,28%	92,86%	99,17%	95,49%	96,69%	98,62%	97,11%	95,86%	92,98%	92,48%	95,41%	98,35%
31	98,58%	93,32%	94,21%	96,24%	98,35%	95,86%	97,11%	94,95%	97,52%	95,11%	93,39%	90,98%	96,33%	97,93%
32	99,06%	95,05%	96,28%	96,24%	97,93%	95,49%	96,28%	100,00%	97,11%	97,37%	94,63%	94,74%	96,79%	97,52%
33	99,06%	93,81%	97,11%	95,86%	99,17%	95,11%	97,93%	99,08%	97,52%	95,86%	93,39%	91,73%	96,79%	97,93%
34	98,11%	93,81%	95,45%	94,36%	98,35%	96,24%	97,11%	99,08%	98,76%	94,74%	93,39%	92,11%	96,79%	98,76%
35	99,06%	95,05%	94,63%	94,36%	93,39%	95,49%	97,11%	93,58%	98,35%	97,37%	93,80%	95,11%	97,71%	98,35%
36	99,53%	94,06%	95,45%	93,61%	97,93%	94,36%	98,35%	99,54%	96,69%	96,99%	93,80%	93,23%	96,79%	98,35%
37	99,53%	94,31%	92,98%	96,62%	91,32%	95,49%	95,87%	94,50%	97,11%	91,73%	93,80%	93,61%	97,25%	97,11%
38	98,58%	94,06%	95,87%	96,62%	92,98%	95,11%	97,11%	100,00%	97,93%	96,24%	92,98%	93,61%	98,17%	96,28%
39	98,58%	94,80%	94,63%	95,49%	90,91%	95,11%	95,45%	98,17%	95,45%	95,11%	93,39%	93,61%	96,33%	97,11%
40	98,58%	91,34%	94,21%	94,36%	98,35%	95,49%	97,52%	94,50%	96,28%	95,86%	92,98%	92,86%	94,50%	99,59%
<b>Média</b>	<b>98,57%</b>	<b>93,71%</b>	<b>95,46%</b>	<b>95,86%</b>	<b>96,57%</b>	<b>95,58%</b>	<b>96,20%</b>	<b>96,73%</b>	<b>96,87%</b>	<b>95,61%</b>	<b>93,89%</b>	<b>93,34%</b>	<b>96,04%</b>	<b>97,94%</b>
<b>Mediana</b>	<b>99,06%</b>	<b>94,06%</b>	<b>95,45%</b>	<b>96,24%</b>	<b>97,93%</b>	<b>95,49%</b>	<b>96,49%</b>	<b>96,10%</b>	<b>97,11%</b>	<b>95,86%</b>	<b>93,80%</b>	<b>93,42%</b>	<b>96,33%</b>	<b>97,93%</b>
<b>Mínimo</b>	<b>93,40%</b>	<b>89,85%</b>	<b>91,74%</b>	<b>92,11%</b>	<b>90,91%</b>	<b>93,23%</b>	<b>88,84%</b>	<b>92,20%</b>	<b>91,32%</b>	<b>91,73%</b>	<b>91,32%</b>	<b>89,85%</b>	<b>89,91%</b>	<b>91,44%</b>
<b>Máximo</b>	<b>100,00%</b>	<b>96,04%</b>	<b>98,76%</b>	<b>98,50%</b>	<b>99,59%</b>	<b>98,12%</b>	<b>98,35%</b>	<b>100,00%</b>	<b>99,17%</b>	<b>98,12%</b>	<b>95,87%</b>	<b>96,24%</b>	<b>98,62%</b>	<b>98,35%</b>
<b>Desvio Padrão</b>	<b>1,31%</b>	<b>1,20%</b>	<b>1,39%</b>	<b>1,56%</b>	<b>2,57%</b>	<b>1,05%</b>	<b>1,75%</b>	<b>2,47%</b>	<b>1,59%</b>	<b>1,55%</b>	<b>0,99%</b>	<b>1,50%</b>	<b>1,87%</b>	<b>1,13%</b>

**Tabela 19. Desempenho de classificação do C2-HÍB. (continua)**

Experim.	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
1	100,00%	99,50%	99,59%	98,12%	98,76%	96,99%	98,76%	98,62%	97,93%	98,87%	97,93%	99,25%	98,17%	98,76%
2	99,53%	98,76%	99,59%	98,87%	99,17%	99,25%	97,11%	98,17%	97,93%	98,87%	97,93%	99,25%	98,62%	99,59%
3	97,64%	98,51%	100,00%	98,87%	97,11%	99,25%	99,17%	98,17%	99,17%	98,12%	100,00%	99,25%	98,62%	99,59%
4	100,00%	99,26%	98,35%	99,25%	99,17%	96,24%	98,35%	100,00%	98,76%	97,37%	99,17%	88,72%	100,00%	99,17%
5	98,11%	99,01%	97,93%	96,99%	99,59%	98,87%	98,76%	97,71%	98,35%	97,37%	99,17%	98,12%	96,33%	99,17%
6	99,53%	99,26%	100,00%	99,25%	99,17%	99,25%	98,76%	100,00%	99,17%	98,12%	97,52%	98,50%	99,08%	100,00%
7	100,00%	99,75%	99,59%	98,12%	98,76%	100,00%	99,17%	100,00%	99,17%	98,50%	99,17%	99,62%	99,54%	99,59%
8	97,64%	99,01%	99,59%	100,00%	100,00%	97,74%	99,17%	99,08%	97,93%	95,11%	98,35%	98,50%	97,71%	99,17%
9	99,53%	97,77%	99,59%	96,62%	96,69%	99,62%	98,35%	97,71%	98,76%	98,12%	98,76%	100,00%	98,62%	100,00%
10	99,53%	98,51%	100,00%	99,25%	99,59%	96,62%	98,35%	96,79%	98,76%	98,12%	99,17%	98,87%	95,87%	100,00%
11	99,53%	99,26%	100,00%	99,62%	99,17%	98,12%	98,76%	100,00%	98,76%	98,87%	97,93%	98,12%	99,08%	100,00%
12	100,00%	99,26%	99,59%	99,25%	98,35%	95,86%	97,93%	99,08%	98,76%	98,87%	98,76%	98,87%	97,25%	97,52%
13	97,64%	98,27%	98,35%	99,62%	98,35%	98,87%	97,52%	99,08%	97,52%	95,86%	97,93%	98,87%	98,62%	99,59%
14	100,00%	98,51%	98,76%	99,25%	96,69%	98,50%	94,63%	100,00%	94,21%	96,62%	90,08%	98,12%	99,54%	98,76%
15	99,06%	98,51%	89,67%	98,50%	89,67%	88,35%	98,76%	97,71%	89,67%	88,35%	89,67%	88,35%	97,71%	89,67%
16	99,53%	98,51%	99,17%	97,74%	100,00%	94,74%	99,17%	98,62%	97,93%	96,62%	99,59%	98,12%	98,62%	99,59%
17	100,00%	99,01%	99,59%	98,87%	100,00%	98,87%	99,17%	100,00%	99,59%	97,37%	99,17%	98,12%	96,33%	100,00%
18	100,00%	99,01%	99,59%	96,99%	98,76%	99,62%	97,93%	99,54%	97,11%	97,74%	99,17%	100,00%	99,54%	99,59%
19	99,53%	98,76%	100,00%	100,00%	99,59%	96,24%	100,00%	88,99%	99,17%	98,87%	87,60%	99,62%	97,25%	87,60%
20	100,00%	99,26%	86,78%	85,34%	86,78%	85,71%	98,35%	99,54%	86,78%	97,74%	86,78%	100,00%	100,00%	99,17%
21	99,53%	98,02%	100,00%	98,50%	99,17%	99,62%	98,35%	99,54%	97,93%	99,62%	99,17%	99,25%	98,62%	100,00%
22	99,06%	98,51%	100,00%	98,50%	99,17%	97,74%	98,35%	97,71%	98,35%	98,50%	98,35%	99,25%	99,54%	99,59%
23	98,11%	99,26%	100,00%	100,00%	99,17%	98,87%	98,76%	100,00%	98,35%	100,00%	98,76%	98,50%	99,08%	98,76%
24	99,53%	99,26%	100,00%	99,62%	100,00%	94,74%	99,17%	97,71%	98,76%	97,74%	98,35%	99,62%	98,62%	100,00%

**Tabela 19. Desempenho de classificação do C2-HÍB. (continuação)**

Experim.	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
25	100,00%	98,02%	99,59%	97,74%	99,17%	99,25%	96,28%	100,00%	99,17%	97,37%	99,59%	98,50%	99,54%	100,00%
26	99,53%	99,26%	87,60%	99,25%	98,76%	86,09%	87,60%	88,99%	99,17%	100,00%	87,60%	100,00%	98,62%	100,00%
27	100,00%	98,76%	100,00%	99,62%	99,59%	99,62%	98,35%	99,08%	98,76%	98,50%	99,59%	99,25%	99,54%	99,17%
28	99,06%	98,76%	98,76%	98,87%	98,76%	96,24%	96,69%	99,08%	99,59%	96,62%	99,59%	99,25%	99,08%	98,35%
29	99,53%	99,50%	98,76%	99,25%	98,76%	96,24%	97,52%	99,54%	99,59%	96,62%	97,52%	98,12%	99,54%	87,60%
30	99,53%	96,53%	100,00%	99,62%	99,17%	99,62%	98,76%	96,79%	97,93%	99,62%	99,17%	98,87%	98,17%	99,59%
31	99,06%	99,01%	99,59%	98,50%	98,35%	97,74%	97,11%	98,62%	97,52%	97,74%	97,11%	99,62%	99,54%	99,59%
32	99,53%	93,81%	100,00%	99,62%	98,35%	99,25%	98,35%	97,71%	98,76%	96,99%	97,93%	99,62%	97,71%	100,00%
33	99,06%	99,26%	100,00%	98,87%	99,59%	95,86%	98,76%	98,17%	100,00%	99,25%	99,59%	99,25%	98,17%	99,59%
34	99,53%	98,02%	99,17%	98,50%	100,00%	96,24%	97,93%	98,17%	100,00%	97,74%	99,59%	99,25%	97,71%	97,52%
35	99,06%	99,26%	99,59%	97,74%	87,60%	89,10%	87,60%	88,99%	87,60%	97,37%	98,76%	98,87%	99,54%	100,00%
36	100,00%	99,75%	99,17%	98,50%	99,59%	98,87%	98,35%	97,71%	99,17%	97,74%	99,59%	99,25%	100,00%	97,93%
37	99,53%	99,26%	98,76%	98,50%	98,76%	99,25%	98,35%	99,54%	97,52%	96,99%	99,17%	98,87%	99,08%	99,59%
38	99,53%	99,01%	100,00%	98,87%	99,59%	97,37%	97,52%	99,08%	99,17%	98,87%	99,59%	99,25%	99,08%	100,00%
39	99,06%	99,50%	99,59%	100,00%	99,17%	94,36%	99,59%	99,08%	98,35%	98,87%	98,76%	99,62%	99,54%	99,59%
40	100,00%	93,07%	99,59%	99,25%	100,00%	99,25%	97,93%	98,62%	99,17%	98,87%	99,17%	98,87%	99,54%	Média
<b>Média</b>	<b>99,37%</b>	<b>98,59%</b>	<b>98,65%</b>	<b>98,50%</b>	<b>98,20%</b>	<b>96,85%</b>	<b>97,74%</b>	<b>98,07%</b>	<b>97,76%</b>	<b>97,76%</b>	<b>97,52%</b>	<b>98,53%</b>	<b>98,67%</b>	<b>98,57%</b>
<b>Mediana</b>	<b>99,53%</b>	<b>99,01%</b>	<b>99,59%</b>	<b>98,87%</b>	<b>99,17%</b>	<b>97,93%</b>	<b>98,35%</b>	<b>98,85%</b>	<b>98,76%</b>	<b>97,93%</b>	<b>98,76%</b>	<b>99,25%</b>	<b>98,85%</b>	<b>99,59%</b>
<b>Mínimo</b>	<b>97,64%</b>	<b>93,07%</b>	<b>86,78%</b>	<b>85,34%</b>	<b>86,78%</b>	<b>85,71%</b>	<b>87,60%</b>	<b>88,99%</b>	<b>86,78%</b>	<b>88,35%</b>	<b>86,78%</b>	<b>88,35%</b>	<b>95,87%</b>	<b>88,97%</b>
<b>Máximo</b>	<b>100,00%</b>	<b>99,75%</b>	<b>100,00%</b>	<b>100,00%</b>	<b>100,00%</b>	<b>100,00%</b>	<b>100,00%</b>	<b>100,00%</b>	<b>100,00%</b>	<b>100,00%</b>	<b>100,00%</b>	<b>100,00%</b>	<b>100,00%</b>	<b>99,98%</b>
<b>Desvio Padrão</b>	<b>0,68%</b>	<b>1,35%</b>	<b>3,13%</b>	<b>2,29%</b>	<b>3,06%</b>	<b>3,61%</b>	<b>2,54%</b>	<b>2,78%</b>	<b>3,00%</b>	<b>1,88%</b>	<b>3,61%</b>	<b>2,39%</b>	<b>1,04%</b>	<b>3,05%</b>

**Tabela 20. Desempenho de classificação do MULT-HÍB. (continua)**

Experim.	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
1	100,00%	99,50%	99,59%	98,87%	100,00%	97,37%	99,59%	99,08%	99,17%	98,87%	98,76%	99,25%	98,17%	98,76%
2	99,53%	99,01%	99,59%	99,62%	99,59%	99,25%	98,35%	100,00%	99,17%	98,87%	98,76%	99,25%	100,00%	99,59%
3	98,58%	98,76%	100,00%	99,25%	98,76%	99,25%	99,17%	99,54%	99,59%	98,12%	100,00%	99,25%	99,08%	100,00%
4	100,00%	99,26%	99,17%	99,25%	99,59%	96,99%	99,59%	100,00%	99,59%	98,50%	100,00%	88,72%	100,00%	99,59%
5	99,53%	99,01%	99,59%	96,99%	99,59%	98,87%	98,76%	100,00%	99,59%	98,87%	99,17%	98,50%	97,71%	100,00%
6	99,53%	99,26%	100,00%	99,62%	100,00%	99,62%	99,59%	100,00%	100,00%	98,12%	97,93%	98,87%	100,00%	100,00%
7	100,00%	99,75%	100,00%	98,87%	98,76%	100,00%	99,17%	100,00%	99,17%	98,50%	99,17%	99,62%	99,54%	100,00%
8	99,53%	99,26%	99,59%	100,00%	100,00%	97,74%	99,59%	99,54%	98,76%	95,86%	99,59%	99,25%	97,71%	99,17%
9	100,00%	98,27%	100,00%	98,12%	97,93%	100,00%	98,76%	98,62%	99,17%	98,50%	98,76%	100,00%	99,54%	100,00%
10	100,00%	98,76%	100,00%	99,62%	99,59%	96,99%	98,35%	99,08%	99,17%	98,50%	99,59%	99,25%	98,17%	100,00%
11	99,53%	99,75%	100,00%	100,00%	99,17%	98,12%	98,76%	100,00%	98,76%	99,25%	97,93%	98,87%	99,54%	100,00%
12	100,00%	99,50%	100,00%	100,00%	99,59%	97,74%	98,76%	100,00%	99,59%	99,25%	98,76%	98,87%	98,17%	98,35%
13	98,58%	99,26%	99,17%	100,00%	100,00%	99,25%	98,35%	99,08%	99,17%	96,24%	99,17%	99,25%	99,54%	100,00%
14	100,00%	98,76%	98,76%	99,25%	99,59%	98,87%	97,11%	100,00%	98,35%	97,74%	94,21%	98,12%	99,54%	98,76%
15	99,53%	98,51%	89,67%	98,50%	89,67%	88,35%	99,59%	99,54%	89,67%	88,35%	89,67%	88,35%	99,54%	89,67%
16	100,00%	99,50%	99,17%	99,62%	100,00%	97,37%	99,17%	99,54%	98,76%	98,87%	99,59%	99,62%	99,54%	100,00%
17	100,00%	99,01%	99,59%	98,87%	100,00%	98,87%	99,17%	100,00%	100,00%	97,37%	99,17%	98,12%	96,33%	100,00%
18	100,00%	99,01%	99,59%	97,74%	98,76%	99,62%	98,35%	100,00%	98,76%	98,50%	99,17%	100,00%	100,00%	99,59%
19	100,00%	98,76%	100,00%	100,00%	100,00%	97,37%	100,00%	88,99%	99,59%	99,25%	87,60%	99,62%	98,17%	87,60%
20	100,00%	99,26%	86,78%	85,34%	86,78%	85,71%	99,17%	99,54%	86,78%	99,62%	86,78%	100,00%	100,00%	99,17%
21	100,00%	99,01%	100,00%	98,50%	99,59%	99,62%	99,17%	99,54%	98,76%	100,00%	99,17%	100,00%	99,08%	100,00%
22	99,53%	99,01%	100,00%	99,25%	99,59%	98,12%	98,76%	99,08%	99,59%	98,87%	100,00%	99,25%	100,00%	99,59%
23	100,00%	99,75%	100,00%	100,00%	99,59%	99,25%	99,17%	100,00%	98,76%	100,00%	99,17%	99,62%	99,54%	98,76%
24	100,00%	99,26%	100,00%	100,00%	100,00%	96,24%	99,17%	98,62%	99,17%	98,87%	98,35%	100,00%	98,62%	100,00%

**Tabela 20. Desempenho de classificação do MULT-HÍB. (continuação)**

Experim.	P1_inf	P1	P2_inf	P2	P3_inf	P3	P4_inf	P4	P5_inf	P5	P6_inf	P6	P7	P1_bbxm
25	100,00%	99,26%	99,59%	98,50%	99,59%	99,62%	97,93%	100,00%	99,59%	98,50%	100,00%	98,87%	100,00%	100,00%
26	100,00%	99,26%	87,60%	99,62%	98,76%	86,09%	87,60%	88,99%	99,17%	100,00%	87,60%	100,00%	100,00%	100,00%
27	100,00%	99,01%	100,00%	100,00%	99,59%	100,00%	98,35%	100,00%	99,59%	99,62%	99,59%	99,62%	99,54%	99,17%
28	99,06%	99,50%	99,59%	99,25%	98,76%	96,99%	98,35%	99,54%	99,59%	97,37%	99,59%	99,25%	99,54%	99,17%
29	99,53%	100,00%	100,00%	100,00%	99,59%	96,99%	98,76%	99,54%	100,00%	97,37%	98,76%	99,25%	99,54%	87,60%
30	100,00%	96,53%	100,00%	100,00%	100,00%	100,00%	99,17%	97,71%	98,35%	100,00%	99,59%	99,25%	99,08%	99,59%
31	99,53%	99,26%	99,59%	99,25%	99,17%	97,74%	98,35%	99,54%	99,17%	99,62%	98,35%	99,62%	100,00%	99,59%
32	100,00%	93,81%	100,00%	100,00%	99,17%	99,25%	98,76%	99,08%	100,00%	97,74%	98,35%	99,62%	99,08%	100,00%
33	99,53%	99,26%	100,00%	98,87%	99,59%	98,12%	99,17%	99,54%	100,00%	99,25%	100,00%	99,25%	99,08%	99,59%
34	99,53%	98,27%	99,59%	100,00%	100,00%	98,12%	98,35%	99,54%	100,00%	98,50%	99,59%	99,25%	99,08%	98,35%
35	100,00%	99,50%	99,59%	99,25%	87,60%	89,10%	87,60%	88,99%	87,60%	98,50%	98,76%	99,62%	99,54%	100,00%
36	100,00%	99,75%	99,59%	99,62%	99,59%	99,25%	99,17%	98,17%	99,17%	99,25%	99,59%	99,25%	100,00%	99,59%
37	99,53%	99,50%	98,76%	98,50%	99,17%	99,25%	98,76%	99,54%	97,52%	97,37%	99,17%	99,25%	99,08%	99,59%
38	99,53%	99,01%	100,00%	99,62%	100,00%	99,25%	97,93%	100,00%	99,59%	99,25%	99,59%	99,62%	99,08%	100,00%
39	100,00%	99,50%	100,00%	100,00%	99,17%	95,11%	100,00%	99,54%	98,76%	99,62%	99,59%	99,62%	100,00%	99,59%
40	100,00%	93,07%	100,00%	99,62%	100,00%	99,25%	98,76%	99,54%	99,17%	99,62%	99,17%	98,87%	99,54%	99,59%
Média	99,75%	98,84%	98,85%	98,98%	98,65%	97,37%	98,32%	98,73%	98,41%	98,41%	97,94%	98,80%	99,24%	98,75%
Mediana	100,00%	99,26%	99,79%	99,62%	99,59%	98,50%	98,76%	99,54%	99,17%	98,87%	99,17%	99,25%	99,54%	99,33%
Mínimo	98,58%	93,07%	86,78%	85,34%	86,78%	85,71%	87,60%	88,99%	86,78%	88,35%	86,78%	88,35%	96,33%	87,60%
Máximo	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
Desvio Padrão	0,37%	1,38%	3,16%	2,32%	3,12%	3,61%	2,56%	2,86%	3,06%	1,90%	3,53%	2,43%	0,81%	2,44%

# Apêndice B

## Análise Estatística

Neste apêndice, são listadas as questões de pesquisa, acompanhadas das avaliações estatísticas para os resultados obtidos para cada uma das hipóteses levantadas.

A primeira etapa da análise buscou examinar a eficácia de cada sistema. Neste sentido, foram utilizadas as diferenças das médias dos conjuntos dos sinais "Normal" e "Alerta" da validação e avaliados os conjuntos dos resultados dessas classes, investigando a disjunção entre essas.

Em seguida, na segunda etapa, foi determinado o método de classificação e os parâmetros de melhor eficiência, a partir da proporção de acerto para os testes avaliados. Ao fim, foi avaliado qual dos vetores de características obteve maior proporção de acerto para os testes avaliados.

### 1. Eficácia

No quesito eficácia, as seguintes questões de pesquisas foram definidas:

- **C1-D1:** É possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 1, aplicados no Classificador 1?
- **C1-D2:** É possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 2, aplicados no Classificador 1?
- **C1-HÍB:** É possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 1 e 2 em conjunto, aplicados no Classificador 1?

- **C2-D1:** É possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 1, aplicados no Classificador 2?
- **C2-D2:** É possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 2, aplicados no Classificador 2?
- **C2-HÍB:** É possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 1 e 2 em conjunto, aplicados no Classificador 2?
- **MULT-D1:** É possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 1, aplicados no Multiclassificador proposto?
- **MULT-D2:** É possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 2, aplicados no Multiclassificador proposto?
- **MULT-HÍB:** É possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 1 e 2, aplicados no Multiclassificador proposto?

A partir destas, foram definidas as hipóteses nulas.

- **C1-D1-H0:** Não é possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 1, aplicados no Classificador 1.
- **C1-D2-H0:** Não é possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 2, aplicados no Classificador 1.
- **C1-HÍB-H0:** Não é possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 1 e 2 em conjunto, aplicados no Classificador 1.
- **C2-D1-H0:** Não é possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 1, aplicados no Classificador 2.

- **C2-D2-H0:** Não é possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 2, aplicados no Classificador 2.
- **C2-HÍB-H0:** Não é possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos no domínio 1 e 2 em conjunto, aplicados no Classificador 2.
- **MULT-D1-H0:** Não é possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 1, aplicados no Multiclassificador proposto.
- **MULT-D2-H0:** Não é possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 2, aplicados no Multiclassificador proposto.
- **MULT-HÍB-H0:** Não é possível diferenciar os sinais dos motores em 2 estados ("Normal" e "Alerta"), utilizando parâmetros acústicos extraídos do domínio 1 e 2, aplicados no Multiclassificador proposto.

Para responder quais das hipóteses são verdadeiras, duas metodologias foram aplicadas, descritas a seguir.

- **Metodologia 1**

Calcular a diferença das médias dos conjuntos de dados "Normal" e "Alerta" de cada experimento, avaliando se esses valores são maiores que 0,5. Este limiar foi definido baseando-se nos índices de classificação para cada classe (0-Alerta e 1-Normal). Portanto, se essa distância for maior que 0,5, ou seja, a metade da diferença das classes, significa que é possível diferenciar as duas classes. Para cada combinação:

- Avaliar a normalidade dos dados;
- Calcular os Intervalos de Confiança (IC), com confiança de 99%;



- Avaliar se esse IC é maior que 0,5, por meio do teste-t ou Wilcoxon, dependendo da normalidade dos dados.
- Caso  $p\text{-value} < 0,01$ , hipótese nula falsa, constata-se eficácia na combinação das características com classificador avaliado.
  - Caso contrário, hipótese nula verdadeira, tem-se que o método não é eficaz.

• **Metodologia 2**

Calcular as médias dos conjuntos de dados "Normal" e "Alerta".

Para cada combinação:

- Avaliar a normalidade dos dados;
- Calcular o Intervalo de Confiança, com confiança de 99%;
- Avaliar se os IC são disjuntos, a partir do teste-t ou de Wilcoxon, dependendo da normalidade dos dados.

Para a Metodologia 1, a avaliação da normalidade do conjunto de dados das diferenças entre as classes "Normal" e "Alerta", em todos os pontos de captura, organizadas pelos métodos em estudo é apresentada na Tabela 20. Observa-se que todos os conjuntos não são normais, resultado já esperado por considerar que estão sendo examinados todos os pontos em conjunto, em que cada um tem seus próprios intervalos, gerando disparidades entre eles.

**Tabela 20. Testes de normalidade das diferenças entre os resultados das classes "Normal" e "Alerta" para cada sistema avaliado.**

Características (Domínio)	Método de Classificação	Shapiro-Wilk (p-value)	Anderson-Darling (p-value)	Normal
FREQ	C1	5,866e-09	2,362e-09	Não
	C2	< 2,2e-16	< 2,2e-16	Não
	MULT	< 2,2e-16	< 2,2e-16	Não
TEMPO	C1	4,613e-15	< 2,2e-16	Não
	C2	< 2,2e-16	< 2,2e-16	Não
	MULT	< 2,2e-16	< 2,2e-16	Não
HÍB	C1	2,525e-15	5,218e-13	Não
	C2	< 2,2e-16	< 2,2e-16	Não
	MULT	< 2,2e-16	< 2,2e-16	Não

A próxima etapa constituiu-se no cálculo dos IC para cada método avaliado, com confiança de 99%, sendo apresentados na Tabela 21. Para avaliar se os IC são maiores que 0,5, foi aplicado o teste de Wilcoxon, com confiança de 99%, apresentado na Tabela 22. Como todos os *p-values* foram inferiores a 0,01, registrou-se que todos os métodos foram eficazes.

**Tabela 21. Intervalos de confiança das diferenças entre os resultados das classes “Normal” e “Alerta” para cada sistema avaliado.**

Características (Domínio)	Método de Classificação	Média	Lim. Inferior	Lim. Superior
FREQ	C1	0,5842	0,5655	0,6028
	C2	0,7469	0,7262	0,7677
	MULT	0,7508	0,7301	0,7714
TEMPO	C1	0,6637	0,6356	0,6918
	C2	0,9270	0,9000	0,9540
	MULT	0,9282	0,9012	0,9555
HÍB	C1	0,7734	0,7572	0,7895
	C2	0,9975	0,9907	0,9928
	MULT	0,9206	0,8967	0,9444

**Tabela 22. Teste de Wilcoxon para avaliação dos IC das diferenças são maiores que 0,5 e eficácia de cada método avaliado.**

Características (Domínio)	Método de Classificação	Teste de Wilcoxon ( <i>p-value</i> )	Eficaz
FREQ	C1	< 2,2e-16	Sim
	C2	< 2,2e-16	Sim
	MULT	< 2,2e-16	Sim
TEMPO	C1	< 2,2e-16	Sim
	C2	< 2,2e-16	Sim
	MULT	< 2,2e-16	Sim
HÍB	C1	< 2,2e-16	Sim
	C2	< 2,2e-16	Sim
	MULT	< 2,2e-16	Sim

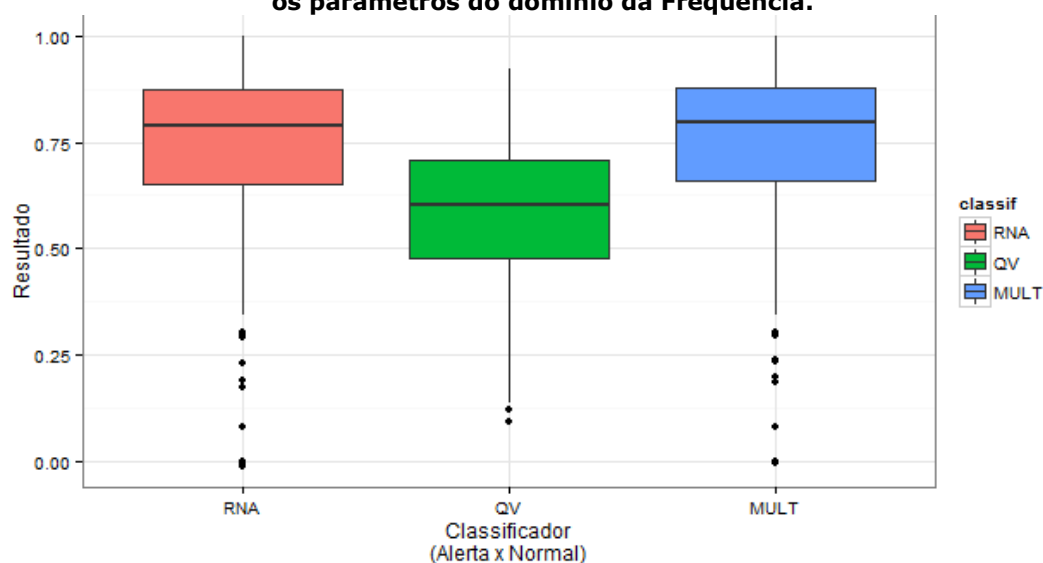
Para uma análise mais adequada, nas Figuras 13, 14 e 15 são trazidos os *boxplots* das diferenças das médias das classes "Normal" e "Alerta" dos métodos estudados.

Pelos gráficos, concluiu-se que todos os sistemas exceto o C1, independente do domínio, têm uma maior variação. Essa observação se justifica pelo algoritmo do método que calcula uma distância a ser comparada com um limiar empírico para definir qual classe será o resultado, ao contrário das outras técnicas cujo resultado já é definido para a classe do *frame* analisado, 0-"Alerta" ou 1-"Normal".

O domínio 1 também gerou uma maior distorção comparando com os outros domínios.


Na Metodologia 2, também se procura definir a eficácia dos sistemas, mas avalia se os dados das duas classes são disjuntos. Na Tabela 23, são colocados os testes de normalidade das médias, restando definir que nenhum dos conjuntos segue uma distribuição Normal, o que se justifica pelo mesmo motivo da primeira metodologia.

**Figura 13. *Boxplot* das diferenças de médias das classes "Normal" e "Alerta" para os parâmetros do domínio da Frequência.**




Os *outliers* foram considerados na pesquisa por serem justificados pelos dados selecionados aleatoriamente na etapa de treinamento, e também pelos casos onde a análise é realizada de forma pareada.

**Figura 14. Boxplot das diferenças de médias das classes "Normal" e "Alerta" para os parâmetros do domínio do Tempo.**



**Figura 15. Boxplot das diferenças de médias das classes "Normal" e "Alerta" para os parâmetros do domínio Híbrido.**



**Tabela 23. Testes de normalidade das médias dos conjuntos "Normal" e "Alerta" dos métodos avaliados.**

Características (Domínio)	Classificador	Classe	Shapiro.Wilk (p-value)	Anderson-Darling (p-value)	Normal
TEMPO	C1	Normal	4.191e-15	< 2,2e-16	Não
		Alerta	< 2,2e-16	< 2,2e-16	Não
	C2	Normal	< 2,2e-16	< 2,2e-16	Não
		Alerta	< 2,2e-16	NA	Não
	MULT	Normal	< 2,2e-16	< 2,2e-16	Não
		Alerta	< 2,2e-16	< 2,2e-16	Não
FREQ	C1	Normal	4.257e-08	2.322e-08	Não
		Alerta	4,605e-09	3,94e-09	Não
	C2	Normal	< 2,2e-16	< 2,2e-16	Não
		Alerta	< 2,2e-16	< 2,2e-16	Não
	MULT	Normal	< 2,2e-16	< 2,2e-16	Não
		Alerta	< 2,2e-16	< 2,2e-16	Não
HÍB	C1	Normal	4.144e-16	< 2,2e-16	Não
		Alerta	< 2,2e-16	< 2,2e-16	Não
	C2	Normal	< 2,2e-16	< 2,2e-16	Não
		Alerta	< 2,2e-16	NA	Não
	MULT	Normal	< 2,2e-16	< 2,2e-16	Não
		Alerta	< 2,2e-16	NA	Não


O passo seguinte foi avaliar a disjunção dos conjuntos "Normal" e "Alerta" para cada método avaliado, com a aplicação do teste de Wilcoxon Pareado, com confiança de 99%. Os resultados são listados na Tabela 24. Constata-se serem todos disjuntos, reafirmando, assim, a eficácia de todos os sistemas, bem como as conclusões da Metodologia 1.

**Tabela 24. Testes de disjunção dos conjuntos "Normal" e "Alerta" de cada método.**

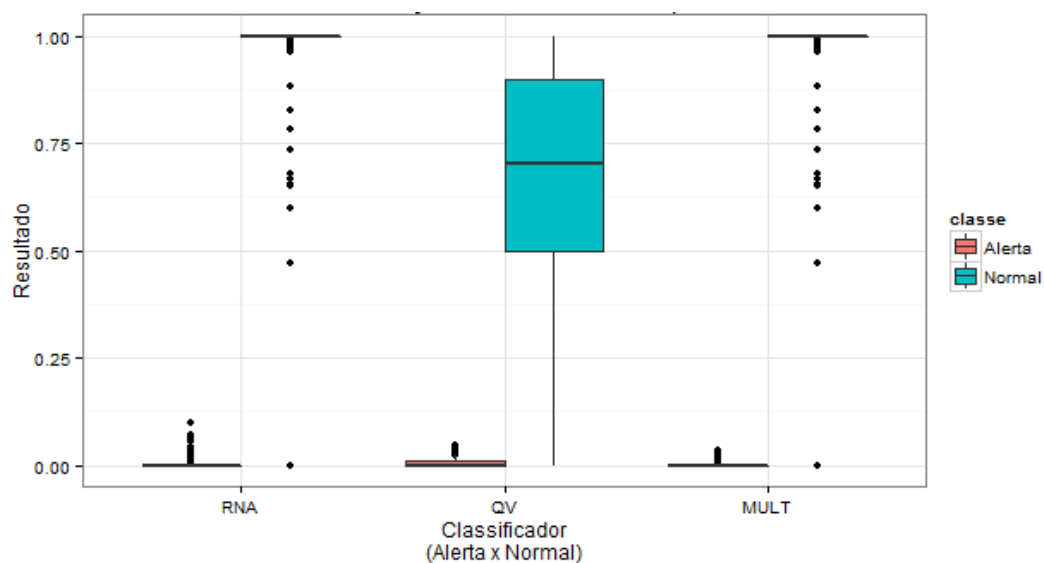
Características (Domínio)	Classificador	Teste de Wilcoxon (p-value)	Disjuntos
FREQ	C1	< 2,2e-16	Sim
	C2	< 2,2e-16	Sim
	MULT	< 2,2e-16	Sim
TEMPO	C1	< 2,2e-16	Sim
	C2	< 2,2e-16	Sim
	MULT	< 2,2e-16	Sim
HÍB	C1	< 2,2e-16	Sim
	C2	< 2,2e-16	Sim
	MULT	< 2,2e-16	Sim

Por fim, conclui-se que todas as hipóteses nulas avaliadas são falsas, confirmação obtida pelas duas metodologias aplicadas.

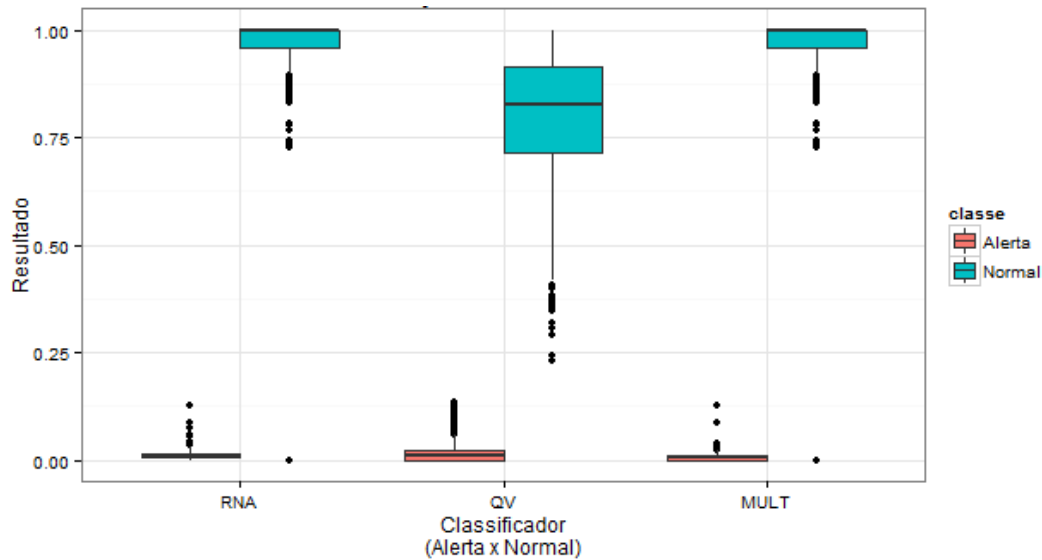
**Figura 16. *Boxplot* das médias das classes "Normal" e "Alerta" para os parâmetros do domínio da Frequência.**



**Figura 17. *Boxplot* das médias das classes "Normal" e "Alerta" para os parâmetros do domínio do Tempo.**



**Figura 18. Boxplot das médias das classes "Normal" e "Alerta" para os parâmetros do domínio Híbrido.**



## 2. Eficiência

Diante das premissas alcançadas anteriormente, procurou-se avaliar os sistemas mais eficientes quanto ao método de classificação e vetor de características. Foram definidas as questões de pesquisa descritas a seguir.

- **Desempenho-Classificador:** Considerando os classificadores eficazes, avaliar se o desempenho do Multiclassificador (C1 + C2) obteve desempenho superior?
- **Desempenho-Características:** Considerando o classificador de melhor desempenho, avaliar qual (quais) vetor (vetores) de características obteve (obtiveram) desempenho superior?

Para responder a questão Desempenho-Classificador, foram examinados os resultados dos testes aplicados em cada sistema investigado. A metodologia aplicada no teste é descrita a seguir.

A partir das médias de acerto para cada combinação classificador/parâmetros eficaz:

- Avaliar a normalidade dos dados;
- A partir do teste de Wilcoxon ou teste-t pareado comparando o desempenho de cada classificador base com o Multiclassificador;

Os resultados estatísticos quanto à normalidade, dos dados para a questão Desempenho-Classificador, são apresentados na Tabela 25. Registra-se que somente o caso do C1 no domínio da frequência obteve uma distribuição Normal, pois os *p-values* são superiores a 0,01. Pela maioria dos dados não seguirem uma distribuição Normal, o teste Wilcoxon será aplicado.

A próxima etapa consistiu em calcular os Intervalos de Confiança, descritos na Tabela 26, avaliando-se a disjunção entre esses. A partir dos resultados, observa-se que, avaliando de maneira global os dados, os Multiclassificadores proporcionaram desempenho superior ao C1. Considerando à C2, a diferença demonstra um pequeno aumento no limite superior.

**Tabela 25. Testes de normalidade para média de acerto cada sistema avaliado.**

Características (Domínio)	Classificador	Shapiro-Wilk (p-value)	Anderson-Darling (p-value)	Normal
FREQ	QV	0,05969	0,04121	Não
	RNA	< 2,2e-16	< 2,2e-16	Não
	MULT	1,878e-05	0,00075	Não
TEMPO	QV	7,909e-15	< 2,2e-16	Não
	RNA	< 2,2e-16	< 2,2e-16	Não
	MULT	< 2,2e-16	< 2,2e-16	Não
HÍB	QV	9,564e-06	6,99e-05	Não
	RNA	< 2,2e-16	< 2,2e-16	Não
	MULT	< 2,2e-16	< 2,2e-16	Não



**Tabela 26. Média e IC de acerto para os testes por sistema analisado.**

Características (Domínio)	Classificador	Média Global	Lim. Inferior	Lim. Superior
FREQ	QV	90,71%	90,43%	90,97%
	RNA	94,16%	93,83%	94,48%
	MULT	94,53%	94,22%	94,84%
TEMPO	QV	95,24%	94,87%	95,59%
	RNA	98,82%	98,46%	99,22%
	MULT	98,93%	98,56%	99,30%
HÍB	QV	95,89%	95,64%	96,12%
	RNA	98,20%	97,91%	98,48%
	MULT	98,65%	98,35%	98,93%

Observa-se uma alta dispersão dos dados, como pode ser observado no *boxplot* da Figura 19. Importante ressaltar a presença de *outliers* para o domínio 2, tanto no Multiclassificador como na C1.

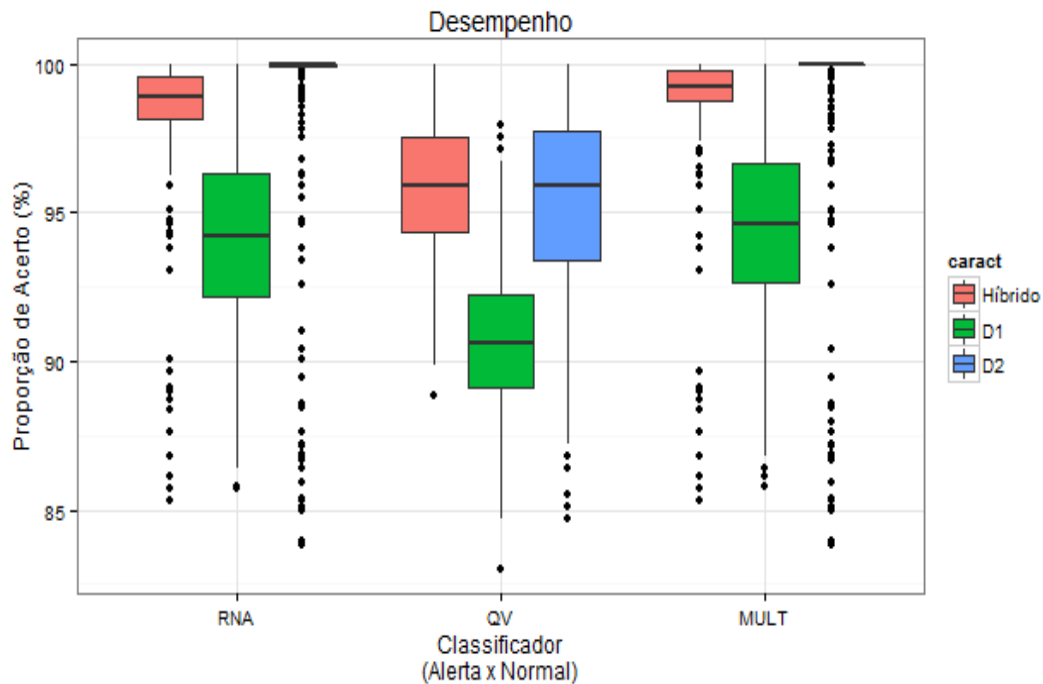
Foi então aplicado o teste de Wilcoxon pareado para considerar dados para cada um dos experimentos que utilizaram os mesmos casos na etapa de treinamento e teste, de forma a avaliar o desempenho nas mesmas condições de cada experimento. A hipótese alternativa aplicada indicava que o desempenho do Multiclassificador seria maior que o segundo classificador avaliado.

Os resultados (Tabela 27) indicam que, em ambos os casos, o Multiclassificador obteve um desempenho superior, pois foram obtidos para os testes *p-values* inferiores a 0,01, rejeitando assim a hipótese nula.

**Tabela 27. Teste de Wilcoxon pareado para avaliação do desempenho do Multiclassificador.**

Classificador	Classificador Comparado	<i>p-value</i>	Hipótese Nula
MULT	C1	< 2.2e-16	Rejeitada
	C2	< 2.2e-16	Rejeitada

Figura 19. *Boxplot* das médias de acerto nos testes.



A segunda questão (Desempenho-Characterísticas), sobre eficiência avaliada foi relacionada aos vetores de características aplicados. A metodologia aplicada é descrita a seguir.

- Aplicar o teste Wilcoxon, devido à não normalidade dos dados, comparando o desempenho dos Multiclassificadores para cada um dos vetores de características avaliado. A hipótese alternativa aplicada indicava a superioridade do domínio 1.

Os resultados obtidos seguem na Tabela 28. Eles indicam que as características no domínio 2 tiveram desempenho superior, enquanto características extraídas do domínio 1 apresentaram desempenho inferior às outras analisadas.

**Tabela 28. Teste de Wilcoxon para avaliação do desempenho dos vetores de características.**

A	B	p-value	Hipótese Nula
HÍB	D1	< 2.2e-16	Rejeitada
D2	HÍB	< 2.2e-16	Rejeitada
	D1	< 2.2e-16	Rejeitada

Os resultados indicam que as características extraídas no domínio 2 proporcionaram desempenho superior em relação às extraídas no domínio 1. Entretanto, ambas representam, de forma eficiente, as condições de funcionamento do motor.

Nas Tabelas 29, 30 e 31 é apresentado o desempenho por ponto para cada uma das classes avaliadas com Multiclassificador. Observa-se melhor desempenho para a classe "Alerta", que pode ser justificado pelo maior número de amostras para esta classe. Como pode ser verificado para o caso do ponto 1, que diferente dos outros pontos, há mais amostras para classe "Normal", demonstrando desempenho superior dessa classe em relação à "Alerta".

**Tabela 29. Desempenho por classe para MULT-D1.**

Ponto	NORMAL (%)		ALERTA (%)	
	Correto	Erro	Correto	Erro
P1_inf	96,16	3,84	98,35	1,65
P1	97,46	2,54	85,99	14,01
P1_bbxm	95,57	4,43	98,14	1,86
P2	73,32	26,68	95,78	4,22
P2_inf	79,67	20,33	97,58	2,42
P3	69,73	30,27	96,33	3,67
P3_inf	72,23	27,77	97,86	2,14
P4	58,00	42,00	96,05	3,95
P4_inf	79,29	20,71	97,14	2,86
P5	79,20	20,80	96,93	3,07
P5_inf	76,52	23,48	97,18	2,82
P6	85,35	14,65	97,81	2,19
P6_inf	68,47	31,53	97,60	2,40
P7	68,82	31,18	98,00	2,00
<b>Média:</b>	<b>78,56</b>	<b>21,44</b>	<b>96,48</b>	<b>3,52</b>

**Tabela 30. Desempenho por classe para MULT-D2.**

Ponto	NORMAL (%)		ALERTA (%)	
	Correto	Erro	Correto	Erro
P1_inf	92,41	7,59	99,97	0,03
P1	99,09	0,91	98,69	1,31
P1_bbxm	89,57	10,43	100,00	0,00
P2	93,87	6,13	99,99	0,01
P2_inf	97,07	2,93	99,88	0,12
P3	87,12	12,88	100,00	0,01
P3_inf	94,60	5,40	99,99	0,01
P4	94,38	5,62	99,99	0,01
P4_inf	92,72	7,28	99,83	0,17
P5	89,78	10,22	99,99	0,01
P5_inf	93,63	6,37	99,99	0,01
P6	93,05	6,95	99,99	0,01
P6_inf	89,31	10,69	99,99	0,01
P7	89,48	10,52	99,99	0,01
<b>Média:</b>	<b>92,58</b>	<b>7,42</b>	<b>99,88</b>	<b>0,12</b>

**Tabela 31. Desempenho por classe para MULT-HÍB.**

Ponto	NORMAL (%)		ALERTA (%)	
	Correto	Erro	Correto	Erro
P1_inf	99,50	0,50	99,79	0,21
P1	99,29	0,71	98,38	1,62
P1_bbxm	92,72	7,28	99,61	0,39
P2	94,81	5,19	99,64	0,36
P2_inf	92,38	7,62	99,78	0,22
P3	84,79	15,21	99,34	0,66
P3_inf	90,26	9,74	99,83	0,17
P4	90,11	9,89	99,79	0,21
P4_inf	91,51	8,49	99,28	0,72
P5	94,44	5,56	99,03	0,97
P5_inf	89,22	10,78	99,72	0,28
P6	94,86	5,14	99,41	0,59
P6_inf	88,06	11,94	99,35	0,65
P7	97,00	3,00	99,52	0,48
<b>Média:</b>	<b>92,78</b>	<b>7,22</b>	<b>99,46</b>	<b>0,54</b>

# Anexo A

## Descrição Geral do Projeto REPARAI

A seguir, será apresentado um resumo do projeto REPARAI, com destaque para o seu principal produto.

### 1. Identificação

**Denominação:** REPARAI (*REPair over AiR using Artificial Intelligence*), código ANEEL PD-6471-0002/2012/Fundo Setorial de Energia Elétrica.

**Parceiros:** BORBOREMA ENERGÉTICA S.A., MARACANAÚ Geradora de Energia S.A., Pesquisas BELADIA e a Fundação Parque Tecnológico da Paraíba/UFCG.

**Produto:** O objeto do REPARAI é o desenvolvimento de um Protótipo de um instrumento para diagnóstico acústico automático, em condições extremas de ruído, de falhas mecânicas em motores, embarcando técnicas de Inteligência Artificial.

### 2. Direção e Supervisão

Usina Térmica (UTE)

Gustavo de Brito Espínola – UTE Borborema Energética S. A.  
Coordenador do Programa de Pesquisa e Desenvolvimento (P&D).  
BORBOREMA ENERGÉTICA S.A.  
MARACANAÚ GERADORA DE ENERGIA S.A.  
TERMELETRICA PERNAMBUCO III S.A.  
<http://borboremaenergetica.com.br>  
[Gustavo.Espinola@bolognesienergia.com.br](mailto:Gustavo.Espinola@bolognesienergia.com.br)

Diretoria BELADIA

BELADIA – grupo de pesquisas em BioEnergia, Arquiteturas Dedicadas e Inteligência Artificial  
<http://beladia.ufcg.edu.br> [diretoria@beladia.ufcg.edu.br](mailto:diretoria@beladia.ufcg.edu.br)  
<http://beladia.sergiodbe.net>

- Diretor de Pesquisas Me. Sérgio de Brito Espinola – Consultor em TIC, Mestre e Doutorando em Ciência da Computação/UFCG
- Profa. Dra. Joseana Macêdo Fachine Régis de Araújo – UFCG

### **3. Laboratórios Parceiros**

- LAD – Laboratório de Arquiteturas Dedicadas  
Prof. Elmar Melcher  
<http://lad.dsc.ufcg.edu.br>
- LIA – Laboratório de Inteligência Artificial  
Profa. Dra. Joseana Macedo Fachine Régis de Araújo

### **4. Equipe Técnica do Projeto**

- Profa. Dra. Joseana Macêdo Fachine Régis de Araújo  
(Coordenadora e Pesquisadora – Unidade Acadêmica de Sistemas e Computação/UFCG)
- MSc. Sérgio de Brito Espinola  
(Gerente e Doutorando em Ciência da Computação/UFCG)
- Prof. Dr. Elmar Uwe Kurt Melcher  
(Pesquisador – Unidade Acadêmica de Sistemas e Computação/UFCG)
- Profa. Dra. Silvana Luciene do Nascimento Cunha Costa  
(Pesquisador – Departamento de Engenharia Elétrica/IFPB)
- Adalberto Gomes Teixeira Júnior  
(Mestrando em Ciência da Computação)
- Ana Lúcia Silva
- Matheus Batista
- Samir Trajano Feitosa  
(Graduandos em Ciência da Computação)