

DISSERTAÇÃO DE MESTRADO Nº 876

**AUMENTO DE CONFIABILIDADE DE SISTEMAS EMBUTIDOS USANDO
REDUNDÂNCIA E ALGORITMOS DE DECISÕES BASEADOS EM
RECONHECIMENTO DE PADRÕES**

Emerson Maurício de Almeida Alves

DATA DA DEFESA: 01/07/2015

Universidade Federal de Minas Gerais

Escola de Engenharia

Programa de Pós-Graduação em Engenharia Elétrica

**AUMENTO DE CONFIABILIDADE DE SISTEMAS EMBUTIDOS
USANDO REDUNDÂNCIA E ALGORITMOS DE DECISÕES
BASEADOS EM RECONHECIMENTO DE PADRÕES**

Emerson Maurício de Almeida Alves

Dissertação de Mestrado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do Título de Mestre em Engenharia Elétrica.

Orientador: Prof. Frank Sill Torres

Belo Horizonte - MG

Julho de 2015

“Aumento de Confiabilidade de Sistemas Embutidos Usando Redundância e Algoritmos de Decisões Baseados em Reconhecimento de Padrões”

Emerson Maurício de Almeida Alves

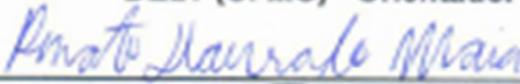
Dissertação de Mestrado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do grau de Mestre em Engenharia Elétrica.

Aprovada em 01 de julho de 2015.

Por:



Prof. Dr. Frank Sill Torres
DELT (UFMG) - Orientador



Prof. Dr. Renato Dourado Maia
DCC (Universidade Estadual de Montes Claros)



Prof. Dr. Antônio de Pádua Braga
DELT (UFMG)



Prof. Dr. Ricardo de Oliveira Duarte
DELT (UFMG)

AGRADECIMENTOS

A Deus, que sempre providenciou tudo em minha vida.

Especial agradecimento à minha esposa Wilma e aos meus filhos: Gutenberg, Nayla e Max por terem tido paciência e ajudar a suportar os momentos de dificuldades.

À minha mãe Aracy e ao meu Irmão Cláudio, pelo apoio e motivação, mesmo que à distância.

Ao meu cunhado Ezequias, pelo apoio na manutenção do veículo para suportar as longas viagens de Pirapora - MG a Belo Horizonte - MG.

Ao meu sogro, senhor Wilson, e à minha sogra Efigênia, pelo apoio.

Ao Professor Frank Sill Torres, meu orientador, pela oportunidade, paciência, apoio e dedicação durante todo o meu período de estudo.

Ao Professor Renato Dourado Maia, meu coorientador, pelas contribuições que me proporcionaram chegar até aqui.

Ao Professor Antônio de Pádua Braga, pelo apoio que foi fundamental no meu desenvolvimento.

Aos professores e funcionários do PPGEE, pela atenção e apoio fundamentais para o meu sucesso.

RESUMO

Com o avanço tecnológico, cada vez mais os sistemas embutidos estão presentes em nosso dia a dia. A confiabilidade é um tópico importante, pois os sistemas críticos são controlados pelos sistemas embutidos cada vez mais. Esses sistemas interagem com o mundo que nos rodeia, por meio de informações oriundas da aquisição de dados através de sensores. A correta tomada de decisão desses sistemas depende de uma aquisição de dados confiável. Falhas podem ocorrer em qualquer sistema, entretanto é possível criar mecanismos que impeçam que essas falhas possam trazer danos ou até gerar catástrofes. Este trabalho aborda a melhoria da confiabilidade dos sistemas embutidos através não só de técnicas de redundância, mas também com técnicas de detecção de anormalidades utilizando reconhecimento de padrões. A proposta é unir duas metodologias distintas - redundância e inteligência artificial - que se conectam para contribuir no desenvolvimento de sistemas embutidos mais confiáveis. Desenvolveu-se uma planta-piloto de aquecimento para a geração dos dados para os experimentos. Estes foram realizados com dados on-line para as técnicas de redundância, e off-line para as técnicas de reconhecimento de padrões. Os resultados foram satisfatórios e demonstraram que a proposta abordada nesta pesquisa contribui para o aumento de confiabilidade de sistemas embutidos.

Palavras-Chave: Sistemas Embutidos, Confiabilidade, Redundância, Reconhecimento de Padrões.

ABSTRACT

The continuous progress in integrated circuit technologies leads to a constant increase of the number of embedded systems surrounding us. Amongst the several challenges accompanying this trend, system robustness has an outstanding role. This is even more true for critical applications that are being controlled by embedded systems. Most of these systems interact with the world by means of information coming from data acquisition from sensors. Consequently, the correct system behavior depends on a reliable data acquisition. In case of faulty data, it is mandatory to possess solutions that prevent that these faults harm the system or even generate disasters. This dissertation presents an approach that improves the reliability of embedded systems that apply sensor data. The proposed technique uses a mixture of redundancy techniques and detection of abnormalities based on Pattern Recognition. In order to verify the proposed approach, a heating pilot plant has been developed. The experiments were performed with online data for redundancy techniques and offline for pattern recognition techniques. The results indicate the feasibility of the proposed methods.

Key Words: Embedded Systems, Reliability, Redundancy, Pattern Recognition.

SUMÁRIO

LISTA DE FIGURAS	xi
LISTA DE TABELAS	xiv
LISTA DE ALGORITMOS	xvi
1. INTRODUÇÃO	1
1.1. Sistemas embutidos em nossa vida.....	1
1.2. Sistemas embutidos na indústria.	1
1.3. Motivação do trabalho.....	2
1.4. Exemplo de identificação de falha na indústria.....	2
1.5. Objetivo do trabalho	3
1.6. Considerações sobre o trabalho	4
1.7. Organização da dissertação	4
2. REVISÃO BIBLIOGRÁFICA	5
2.1. Sistemas embutidos.....	5
2.2. Confiabilidade	6
2.3. Redundância.....	7
2.4. Reconhecimento de padrões	10
2.5. Detecção de novidades.....	12
2.6. Distância de Mahalanobis	13
2.7. Modelo Gaussiano multivariado	14
2.7.1. Função de distribuição Gaussiana multivariada	14
3. METODOLOGIA	16
3.1. Ideia principal.....	16

3.2.	TMR Analógico.....	19
3.2.1.	Voter.....	19
3.4.	Treinamento.....	22
3.4.1.	Reconhecimento de Estados.....	22
3.4.2.	Extração de Curvas.....	25
3.4.3.	Treinamento.....	25
3.5.	Detecção de novidades.....	28
3.6.	Resumo da metodologia.....	30
4.	PLANTA-PILOTO.....	31
4.1.	Justificativa.....	31
4.2.	Descrição.....	31
4.2.1.	Estrutura.....	31
4.2.2.	Sensores.....	33
4.2.3.	Software.....	36
5.	EXPERIMENTOS.....	39
5.1.	Geração das curvas.....	39
5.1.1.	Curvas sem novidades.....	39
5.1.2.	Curvas mistas.....	41
5.1.3.	Experimentos com redundância.....	44
5.1.4.	Média dos três.....	44
5.1.5.	Média da menor diferença.....	45
5.2.	Experimentos com reconhecimento de padrões.....	47
5.2.1.	Extração das curvas.....	47
5.2.2.	Treinamento.....	51

5.2.3. Detecção de novidades	52
6. RESULTADOS E DISCUSSÕES	53
6.1. Métodos de extração e tratamento de curvas	53
6.2. Média dos três sinais x média da menor diferença.	55
6.1. Experimentos com reconhecimento de padrões	66
6.1.1. Quantidade de curvas para treinamento	66
6.1.2. Verificação do método	69
6.2. Considerações finais sobre os experimentos	77
7. CONCLUSÕES	79
8. REFERÊNCIAS	83

LISTA DE FIGURAS

Figura 1- Curvas de balanças dosadoras, em (A) curvas sem variações anormais e em (B) curvas com variações anormais.	3
Figura 2- Diagrama de TMR proposto por von Newman [28].	9
Figura 3- Projeção da sombra da mão com redução de atributos: 3 dimensões para 2 dimensões [31].	10
Figura 4- Histograma do comprimento e luminosidade do salmão e badejo [31].	11
Figura 5- Redução de atributos dos peixes para um ponto no gráfico [31].....	12
Figura 6- Estrutura de detecção de novidades [34].	13
Figura 7 - Diagrama estrutural com a proposta deste trabalho.....	18
Figura 8- A técnica do valor do meio para o sistema de votação [50].	20
Figura 9- Planta-piloto, composta por forno (A), bancada eletrônica com sistemas embutidos (B);(C) e notebook (D)	32
Figura 10- Esquemático da planta-piloto com equipamento e barramento ethernet de comunicação.....	33
Figura 11- Imagens do sensor LM35 em (A) e sensores PT100 em (B).....	34
Figura 12 - Localização dos sensores de temperatura dentro do forno.....	34
Figura 13- Tabela de indicação de erro do PT100(A) e do LM35 em (B)	35
Figura 14- Fluxograma do sistema de controle da planta-piloto.	37
Figura 15- Tela do software supervisor que controla a planta-piloto.....	38
Figura 16- Grupo de curvas sem novidades dos sinais dos três sensores PT100, respectivamente temp1, temp2 e temp3.....	40
Figura 17 - Grupo de curvas sem novidades de três sensores PT100 em intervalo com 3500 segundos.	40
Figura 18- Curvas sem novidades dos sinais sem tratamento por média móvel nos microcontroladores dos sistemas embutidos de aquisição de dados.	41

Figura 19- Grupo de curvas mistas dos sensores PT100, (A) ruído em temp 2 na cor azul, (B) sem ruído e (C) ruído em temp 1 na cor preta, temp 2 na cor azul.	43
Figura 20- Gráfico com curvas dos três PT100 em cinza e a curva da média dos três sensores em preto.	44
Figura 21- Gráfico com as curvas dos 3 PT100 em cinza, a curva da média em preto.....	45
Figura 22 - Curvas com os valores dos 3 PT100 em cinza e a curva de saída do Voter em preto.....	46
Figura 23- Curvas dos PT100 e incidência de fortes ruídos em cores. Na cor preta, a curva do sinal de saída do Voter sem influência do ruído mais forte.....	46
Figura 24- Sinal digital de comando do forno e sinais analógicos dos sensores de temperatura	48
Figura 25- Efeito da alteração do tamanho da janela e limiar.....	49
Figura 26- Gráfico com as curvas crescentes da operação de aquecimento	49
Figura 27 – Grupo de curvas mistas dos sinais sem filtro no microntrolador e após a média móvel no software supervisorio.	50
Figura 28- Curvas com grande variabilidade extraídas do grupo de curvas mistas, consideradas curvas com novidades.....	51
Figura 29- Demonstração gráfica da aplicação das distâncias de Mahalanobis como métrica para detecção de novidades.....	52
Figura 30- Curvas das temperaturas temp1, temp2 e temp3 do banco de dados.	53
Figura 31- Curvas normalizadas.....	54
Figura 32- Curvas com amplitudes diferentes (A) curvas de 40 °C a 100 °C e em (B) curvas de 40 °C a 70 °C.....	55
Figura 33- Curvas das temperaturas dos 3 sensores; as setas (A), (C) e D indicam ciclo no qual existem curvas com maior ruído; a seta (B) indica o segundo ciclo sem ruído. Entre as retas tracejadas, estão os demais ciclos ou bateladas.....	57
Figura 34- Curva do ciclo com afastamento da curva T2 (temp2) em (A) e (B) em relação às curvas T1(temp1) e T3(temp3).	59
Figura 35- Gráfico (A) do ciclo 1 com entrada do sinal ruidoso e saídas dos dois métodos. Em (B) os três sinais de entrada; em ambos os gráficos, na parte inferior, a distância euclidiana do sinal de saída do Voter em relação ao sinal mais ruidoso.....	63

Figura 36- Gráfico (A) do ciclo 2 com entrada do sinal ruidoso e saídas dos dois métodos. Em (B), os três sinais de entrada; em ambos os gráficos, na parte inferior, a distância euclidiana do sinal de saída do Voter em relação ao sinal mais ruidoso.	64
Figura 37- Boxplot com as distâncias das curvas dos ciclos 1 e ciclos 2	65
Figura 38- Experimento 1 de detecção de novidades com base de curvas para treinamento (A), curvas para treinamento (B), curvas para validação cruzada (C) e curvas para avaliação (D).....	71
Figura 39- Gráfico com as distâncias do treinamento, validação e detecção do sistema de detecção de novidades.	72
Figura 40- Experimento 2, detecção de novidades com base de curvas para treinamento (A), curvas para treinamento (B), curvas para validação cruzada (C) e curvas para detecção oriundas de sinais sem tratamento (D).	74
Figura 41-Gráfico com os resultados da detecção de novidades das curvas sem falhas oriundas dos sinais sem tratamento.	74
Figura 42- Gráfico com os pontos azuis (A) que indicam uma distância muito grande em relação ao limiar para o grupo de curvas ruidosas sem tratamento de sinais pelo microcontrolador (B).	75
Figura 43- Gráfico com o grupo de curvas-base(A), curvas de treinamento (B), curvas de validação(C) formadas pelo grupo de curvas sem novidades e o grupo de curvas de sinais ruidosos (D).	76
Figura 44-Gráfico com as distâncias do grupo de curvas ruidosas em relação ao grupo de treinamento, ambas oriundas de sinais sem tratamento pelo microcontrolador.	77

LISTA DE TABELAS

Tabela 1- Teste de verificação de confiabilidade [19].	6
Tabela 2-IEC 61508 Nível de integridade de segurança (SIL).	7
Tabela 3- Determinação de sinal ruidoso através dos valores das médias (avg) e desvios-padrão (sd) dos resíduos de temp11 (T1), temp2 (T2) e temp3 (T3). Em negrito, indicação dos sinais com maior ruído.	43
Tabela 4- Determinação de sinal ruidoso através dos valores das médias (avg) e desvios-padrão (sd) dos resíduos da curva 1 (T1), curva 2 (T2) e da curva 3 (T3). Em negrito, os maiores valores de média e desvio- padrão. Ciclo 3 com comportamento diferente, em vermelho itálico.	58
Tabela 5-Resultado dos desvios-padrão (sd) e das médias das distâncias (avg) das curvas dos métodos do voto em relação às n temperaturas de entrada (V-Tn) e do método da média(M-Tn) em relação às n curvas de entrada das temperaturas. Em itálico vermelho, os maiores valores sem ruído.	60
Tabela 6- Resultado dos desvios-padrão (sd) e das médias das distâncias (avg) das curvas dos métodos do voto em relação às n temperaturas de entrada (V-Tn) e do método da média(M-Tn) em relação às n curvas de entrada das temperaturas. Em negrito, os maiores valores quando há ruído. A coluna T ruído indica qual sensor de temperatura possui maior ruído.	61
Tabela 7- Relação entre as médias e desvios-padrão das distâncias dos métodos. Valores maiores indicam o quanto os sinais de saída do método do voto estão mais distantes que os sinais do método da média. Quanto maior a porcentagem, maior a robustez do método do voto em relação ao método da média.	62
Tabela 8- Média (avg) e desvios-padrão (sd) das distâncias da curva de saída dos métodos de seleção em relação às curvas dos sinais de entradas dos sensores de temperatura.	64
Tabela 9- Estrutura da matriz de confusão	66
Tabela 10- Matriz de confusão para o treinamento com 3 curvas, experimento 1	67
Tabela 11- Matriz de confusão para o treinamento com 10 curvas, experimento 2	67
Tabela 12- Matriz de confusão para o treinamento com 20 curvas, experimento 3	68
Tabela 13- Matriz de confusão para o treinamento com 30 curvas, experimento 4	68

Tabela 14- Matriz de confusão para o treinamento com 40 curvas, experimento 5.....	68
Tabela 15- Matriz de confusão para o treinamento com 60 curvas, experimento 6.....	68
Tabela 16- Mostra a taxa de erro total T_{et} para as quantidades de curvas de treinamento. ...	69

LISTA DE ALGORITMOS

Algoritmo 1- Algoritmo do Voter, média dos dois sinais com menor diferença	21
Algoritmo 2- Pseudocódigo de detecção de estados	24
Algoritmo 3- Validação cruzada e cálculo das distâncias das curvas sem novidades.	27
Algoritmo 4- Cálculo do modelo Gaussiano multivariado, através da matriz de covariância. .	27
Algoritmo 5- Cálculo do limiar, baseado nas distâncias das curvas sem novidades.	28
Algoritmo 6- Cálculo da distância de Mahalanobis para as curvas em análise.....	29
Algoritmo 7- Detecção de novidade pela comparação das distâncias das curvas em análise com o valor de limiar.....	30
Algoritmo 8- Algoritmo de média móvel.	42

1. INTRODUÇÃO

1.1. Sistemas embutidos em nossa vida

A tecnologia rodeia nossa vida de maneira que, em grande parte das vezes, não nos damos conta de que a funcionalidade e a operação de vários equipamentos são controladas por pequenos e específicos sistemas computadorizados embutidos [1].

Sistemas embutidos nos rodeiam controlando vários equipamentos não só para o trabalho, mas também para o entretenimento. Dentre esses sistemas, podemos citar: cafeteira, máquinas de lavar roupa, televisores, receptores via satélite de televisão e celulares. Na indústria automotiva, os sistemas embutidos contribuem para maior conforto e segurança no controle dos sistemas de freio ABS, controle de estabilidade, injeção eletrônica, ar condicionado e outros [1].

1.2. Sistemas embutidos na indústria

Sistemas embutidos têm contribuído para o controle e automação de processos em vários segmentos industriais. Esses sistemas são constituídos por equipamentos desenvolvidos tanto por grandes fabricantes quanto por engenheiros que trabalham diretamente no processo industrial. A aquisição de dados utilizando sistemas embutidos na indústria tem sido uma ferramenta fundamental para o desenvolvimento tecnológico. No caso do desenvolvimento da central eletrônica do carro híbrido da Ford [2], foi necessário controlar as tensões dos módulos de controle das células de combustíveis por meio das medidas de vários parâmetros do funcionamento do veículo, como rotação do motor, solicitação de torque determinada pela posição do pedal do acelerador e demais parâmetros envolvidos no sistema de injeção eletrônica. Através disso, todas as leituras foram realizadas com sistema de aquisição de dados. Na pesquisa sobre a fadiga dos plásticos dos painéis veiculares da Fiat [3], foi utilizado um sistema de aquisição de dados com vários sensores de temperatura fixados no painel do veículo, com o objetivo de determinar a fadiga térmica dos plásticos utilizados nos painéis. Nos trabalhos de perfuração de poços de petróleo pela Petrobrás na Bahia [4], os parâmetros de operação, como profundidade da broca, vazões de líquido, gás e

pressão resultante de fundo, foram lidos, tratados e processados por sistemas de aquisição de dados. Os dados são lidos, oriundos de sinais de tensão gerados pelos sensores, e tratados para expressar uma relação com a grandeza medida. O processamento realiza as conversões para que os valores sejam disponibilizados não só para tomadas de decisões, mas também para visualização.

1.3. Motivação do trabalho

A motivação deste trabalho é contribuir para o aumento da confiabilidade, de forma geral, em qualquer processo em que seja possível a entrada redundante de três sinais representados por números reais não aleatórios. Levando-se em conta essas especificações, pode-se considerar os sinais oriundos de sistemas de aquisição de dados analógicos. Utilizou-se a aquisição de dados para mostrar a aplicação e o funcionamento das metodologias abordadas. A análise e o melhoramento de confiabilidade em sistemas de aquisição de dados utilizados em sistemas embutidos foram o foco da pesquisa.

1.4. Exemplo de identificação de falha na indústria

Como exemplo, tem-se o estudo realizado nos sinais de um sistema de automação em uma metalúrgica de grande porte. A automação foi do sistema de carregamento dos fornos. O controle era realizado por computador industrial [5], com a utilização de sistemas embutidos de aquisição de dados. Embora houvesse um plano de manutenção preventiva, ocorreram falhas não previstas, devido ao ambiente ser muito agressivo [6]. Em análises dos sinais dos equipamentos, foi possível identificar variabilidades que apareciam de forma aleatória, antes dos equipamentos apresentarem falhas que comprometessem o processo.

A Figura 1 mostra curvas de carga e descarga das balanças dosadoras. Esses valores foram gerados a partir da aquisição de dados, diretamente da operação do sistema de carregamento dos fornos. As curvas, em (A), são classificadas como “sem falhas”. As curvas, em (B), no processo de descarga, apresentam uma alteração do padrão e uma variabilidade maior, o que indicou uma anormalidade. As razões da anormalidade poderiam ser defeito nas células de carga, nos módulos de conversão de sinais, interferências

eletromagnéticas nos cabos de comunicação e outros. Nesse caso específico, foi detectado problema na célula de carga. As variabilidades em (B) são indicadas pelas setas.

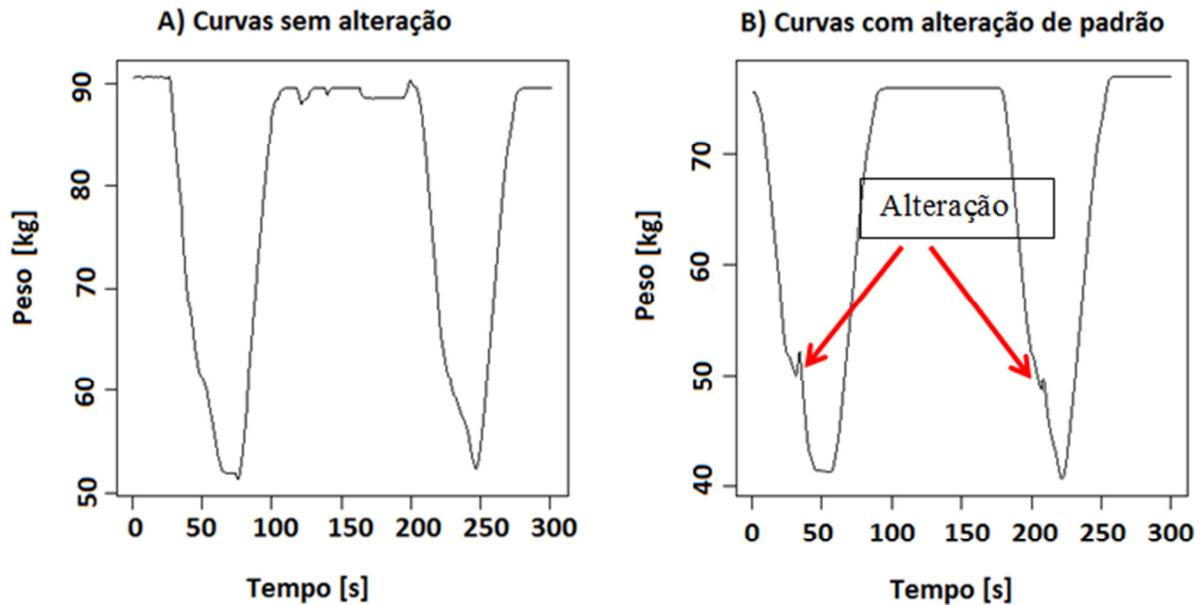


Figura 1- Curvas de balanças dosadoras, em (A) curvas sem variações anormais e em (B) curvas com variações anormais.

1.5. Objetivo do trabalho

O presente trabalho tem como objetivo um aumento de confiabilidade no sistema de aquisição de dados analógicos para sistemas embutidos. A proposta é que essa melhoria seja alcançada com duas técnicas distintas, que estão diretamente conectadas. A primeira técnica utiliza a redundância tripla para os sensores do sistema de aquisição de dados, através de um sistema de votação, para ser robusta a falha de um sensor. A segunda analisa os sinais de todos os sensores e busca detectar uma mudança no comportamento que poderia indicar uma anormalidade no sinal. O objetivo da segunda técnica é completar a primeira, que poderia falhar quando mais de um sinal redundante apresentar falha semelhante.

Este trabalho propõe a melhoria de confiabilidade para sistemas embutidos de aquisição de sinais analógicos, de forma geral. O estudo é para processo de aquisição de

sinais analógicos e busca dar uma contribuição ao padrão internacional IEC 6158. Esse padrão refere-se a sistemas eletrônicos complexos e programáveis cujas falhas poderiam ter um impacto na segurança de pessoas ou ambientes. O padrão descreve métodos para classificar riscos e especifica requerimentos para evitar, detectar e controlar falhas [7].

1.6. Considerações sobre o trabalho

Os sinais usados neste trabalho são de baixa frequência, ou seja, na faixa de dezenas de Hertz. Essa frequência atende a vários processos industriais em que exista uma inércia natural para a mudança de valores da grandeza medida, como, por exemplo, controle de nível de reservatórios, controle de refrigeração em câmeras frias e outros.

Os dados empregados são reais e foram gerados em um processo de aquecimento de um forno residencial em uma planta-piloto.

A dissertação considera um processo dinâmico, no qual é possível identificar o comportamento dos sinais em um intervalo de tempo. Esse comportamento deve ser semelhante, quando o processo é repetido, mantendo-se todas as características.

1.7. Organização da dissertação

No Capítulo 2, são mostrados alguns conceitos úteis ao entendimento deste trabalho.

As metodologias e as propostas para melhoria da confiabilidade, sendo abordado um conjunto de técnicas em blocos funcionais, estão no Capítulo 3.

O Capítulo 4 descreve a planta-piloto utilizada para a geração dos dados que foram utilizados nos estudos desta dissertação.

O Capítulo 5 detalha os experimentos realizados não só para aquisição de dados, mas também para aplicações das técnicas estudadas aqui.

O Capítulo 6 exhibe algumas discussões que ocorreram ao longo do desenvolvimento dos experimentos e analisa os resultados dos experimentos.

As conclusões e sugestões para trabalhos futuros são apresentadas no Capítulo 7.

2. REVISÃO BIBLIOGRÁFICA

2.1. Sistemas embutidos

Os sistemas embutidos são normalmente definidos como uma combinação de hardware e software, projetados para realizar funcionalidades específicas [8]. O hardware de processamento normalmente inclui microcontroladores, microprocessadores e processadores de sinais digitais (DSPs), integrados de aplicações específicas, cada um com suas propriedades [9] [10].

Sistemas embutidos são diferenciados dos sistemas de computadores de uso geral, uma vez que são projetados para fins especiais e não oferecem programação para usuários finais. Apesar de sistemas embutidos serem diferentes, devido a esse motivo, muitos deles compartilham características comuns: baixo custo, baixo consumo de energia, baixo a médio desempenho, operam em tempo real e possuem curto tempo de colocação no mercado [11]. Quando comparados à plataforma de computador, sistemas embutidos normalmente apresentam muito menos potência de processamento e capacidade de memória muito limitada. No entanto, para realizar tarefas específicas em tempo real, as desvantagens acima tornam-se méritos: sistemas embutidos são mais baratos e muito mais fáceis de projetar [9].

Na indústria, tem aumentado muito o interesse nos sistemas de aquisição de dados [12], [13], [14], uma vez que o controle dos processos produtivos depende da leitura de grandezas físicas que podem ser realizadas através dos sistemas de aquisição de dados. Os sinais analógicos indicam sinais contínuos cuja variação em relação ao tempo é a representação proporcional de outra variável temporal. Esses sinais são utilizados para medição das grandezas que devem ser amostradas e quantizadas em sinais discretos, ou seja, sinais digitais. Essa conversão dos sinais analógicos para digitais são tarefas comumente realizadas por sistemas embutidos [15].

Sinais analógicos são expressos em números reais, que são usualmente representados por meio de ponto flutuante. Representação de ponto flutuante é semelhante à notação científica, no qual se usa a base dois, em vez da base dez. Embora vários formatos semelhantes estejam em uso, o mais comum é ANSI / IEEE 754-1985. Esta norma

define o formato dos números de 32 bits chamados de precisão única, bem como os números de 64 bits chamados de precisão dupla [15] [16].

2.2. Confiabilidade

Confiabilidade é a probabilidade de um equipamento trabalhar sem falhas ou defeitos por um determinado período de tempo, considerando as condições ambientais e operacionais especificadas [17], [18].

A confiabilidade $R(t)$ deve ser entendida como a probabilidade de um sistema realizar o desejado, até o instante de tempo t . A confiabilidade $R(t)$ pode ser estimada com base na distribuição de probabilidade exponencial para a probabilidade de falhas $e^{-\lambda t}$ (eq. 1) [19].

$$R(t) = e^{-\lambda t} \quad (1)$$

A taxa de falha λ expressa a probabilidade de um sistema falhar em um determinado intervalo de tempo. A taxa de falhas λ é a relação entre a quantidade de falhas f em um intervalo de tempo T (eq. 2) [19].

$$\lambda = \frac{f}{T} \quad (2)$$

Considere um exemplo em que dez unidades de um produto são testadas ao longo de um período de 100 horas e ocorrem quatro falhas individuais distintas. As falhas ocorreram da seguinte maneira: produto 1 em 5 horas, produto 2 em 30 horas, produto 3 em 55 horas, produto 4 em 80 horas, e os 6 outros produtos funcionaram durante as 100 horas sem falhas. As falhas e o período de funcionamento de cada produto são organizados na tabela de teste de verificação de confiabilidade - Tabela 1.

Tabela 1- Teste de verificação de confiabilidade [19].

	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	Total
Falhas	1	0	0	1	0	1	1	0	0	0	4
Horas	5	100	100	30	100	55	80	100	100	100	770

Considerando a equação 2.

$$\begin{aligned}
 f &= 4 \\
 T &= 770 \\
 \lambda &= \frac{f}{T} = \frac{4}{770} = 0,005195
 \end{aligned}
 \tag{3}$$

Assim, a taxa de insucesso do produto é estimada em 0,005195 falhas por hora [19]. Aplicando o λ na equação (eq. 1), pode-se determinar a confiabilidade para qualquer intervalo de tempo. Para 1000 horas, tem-se:

$$R(1000h) = e - 0,005195 * 770 = 0,00269866 \tag{4}$$

Todos os sistemas têm possibilidade de falhar, já que é impossível projetar um sistema com taxa zero de falha. Assim, cada aplicação deve ser projetada com uma taxa de falha aceitável. A norma IEC 61508 especifica taxas de insucesso aceitáveis para uma variedade de níveis SIL (Safety Integrity Level), com base nas consequências de uma falha do sistema, conforme especificado na Tabela 2 [20].

Tabela 2-IEC 61508 Nível de integridade de segurança (SIL).

Nível SIL	Probabilidade de Falhas	Consequência	Exemplo de Aplicação
4	1 falha em 110.000 anos	Potencial de fatalidade na comunidade.	Controle de usina nuclear.
3	1 falha em 11.000 anos	Potencial de fatalidade local múltipla.	Área de risco de caldeiras.
2	1 falha em 1.100 anos	Potencial de prejuízos locais.	Medição de vazão de líquidos perigosos.
1	1 falha em 110 anos	Potencial para prejuízos menores.	Medição térmica.

2.3. Redundância

Cada vez mais são exigidas melhorias na confiabilidade e robustez dos sistemas embutidos, uma vez que estão no controle de sistemas críticos. Essas melhorias podem ser alcançadas por meio de projetos de hardware e de software [17], [21].

Na engenharia, a redundância é não só a duplicação de componentes críticos, mas também a duplicação de informações e de tempo, com o objetivo de aumentar a

confiabilidade do sistema. Isto significa que, se uma parte do sistema falhar, existe um caminho alternativo para o sucesso. Existem quatro formas principais de redundância, que são: (1) redundância de hardware, como a *redundância modular dupla* e *redundância modular tripla*; (2) redundância de informações, tais como paridade e códigos de correção; (3) redundância de tempo, realizando a mesma operação várias vezes, como diversas execuções de um programa ou várias cópias dos dados transmitidos; e (4) redundância de software, tais como N-versão de programação [22].

Existem duas funções de redundância: passiva e ativa. Redundância passiva usa excesso de capacidade para reduzir o impacto de falhas de componentes. Uma forma comum de redundância passiva é a força extra de cabos e suportes utilizados em pontes [23]. Redundância ativa evita a diminuição de desempenho por meio de monitoramento de um dispositivo individual, e esse monitoramento é usado em uma lógica de votação [24].

Cada componente duplicado, adicionado ao sistema, diminui a probabilidade de falha deste, considerando a independência entre eles (eq. 4).

$$p = \prod_{i=1}^n p_i \quad (5)$$

O termo n é o número de componentes, p_i é a probabilidade do componente i falhar e p é a probabilidade de falha conjunta de todos os componentes, ou seja, falha do sistema [22].

Sistemas computadorizados de controle, em que há risco de vida, devem ser projetados para atender às especificações estritas de confiabilidade, que são muitas vezes conseguidas através da introdução de redundâncias de hardware e de software [17]. A redundância é um conceito utilizado no padrão internacional IEC 61508, que estabelece os requisitos para fornecer o exigido nível de integridade de segurança (SIL). Em sistemas críticos de segurança, a redundância é obrigatória para operar corretamente em caso de um fracasso. Redundância Modular Dupla (DMR) e Redundância Modular Tripla (TMR) são técnicas bem conhecidas e amplamente utilizadas. No caso de DMR, projetos duplicados trabalham em paralelo. TMR utiliza três módulos, e os resultados das saídas são apresentados a um circuito de votação [20].

Redundância é representada tipicamente como uma expressão " M de n ". A expressão " M de n " significa que um sistema tem " n " canais redundantes, em que " M " saídas desses " n " canais" têm que concordar em fornecer uma saída válida para o sistema [25]. TMR é uma técnica bem explorada de redundância, sendo um conceito originalmente proposto por von Neumann [26]. Utiliza três sinais de entrada e um sistema de escolha, através de votação, para determinar o sinal de saída. Historicamente, TMR tem sido uma importante técnica em projetos de confiabilidade de sistemas digitais [27]. A saída do TMR é determinada pela maioria dos votos de três componentes idênticos. Se apenas um dos componentes está em erro, a saída do sistema não será o erro, uma vez que a maioria dos componentes são corretos [26]. O conceito é ilustrado pela imagem da Figura 2, em que os três módulos ou caixas pretas, de 1 a 3, são idênticos e têm uma única saída. Caixa preta pode ser um computador completo ou pode ser uma unidade menos complexa, como, por exemplo, um somador ou uma porta lógica. O círculo Voter é chamado de *Majority Organ* por von Neumann. O Voter aceita a entrada das três fontes e fornece a opinião da maioria como uma saída [28].

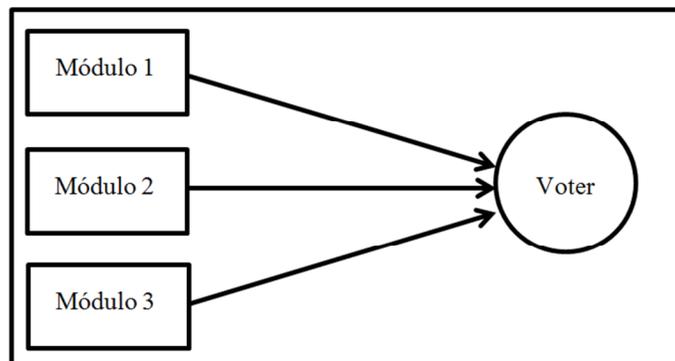


Figura 2- Diagrama de TMR proposto por von Newman [28].

TMR foi desenvolvida para utilização em sistemas digitais, em que a escolha do sinal de saída é definida pelo valor da maioria dos sinais [26]. A ocorrência da entrada de dois valores errados leva o sistema de votação por maioria à falha. Sabe-se que vários artigos estudam técnicas para melhorar a capacidade do sistema de votação [27]. Uma vez que as saídas dos módulos de 1 a 3 são binárias e o número de entradas no Voter é ímpar, poderá ocorrer um resultado incorreto pela votação da maioria [29]. Existem vários trabalhos que propõem maior confiabilidade nos módulos de entrada e Voter do TMR [30] [27] [29].

2.4. Reconhecimento de padrões

O reconhecimento de padrões pode ser escalado como o problema de encontrar categorias e propriedades essenciais. Procura identificar um número reduzido de características ou atributos para que seja possível determinar a hipótese mais provável de um conjunto de hipóteses. Essa característica o difere do teste de hipótese estatística clássica, em que os dados são usados para decidir se deve ou não rejeitar uma hipótese nula em favor da hipótese alternativa [31].

Como um exemplo intuitivo, considere a projeção da sombra de uma mão na parede. Esse é um exemplo de uma projeção incompleta e de redução de atributos; nesse exemplo, a dimensão. A mão possui três dimensões e será projetada em duas dimensões. Dada uma sombra, não é possível reproduzir a mão inteira. Portanto, a mão deve ser girada de forma que duas dimensões sejam suficientes para identificá-la através da sombra na parede, como mostrado na Figura 3 [32].



Figura 3- Projeção da sombra da mão com redução de atributos: 3 dimensões para 2 dimensões [31].

Um exemplo do trabalho de Duda [31] é a tentativa de classificação automática dos peixes badejo e salmão, em uma correia transportadora. Utilizou-se uma câmera para capturar as imagens e foram selecionados alguns parâmetros: largura, comprimento, brilho, posição da boca e número de nadadeiras. O comprimento e o brilho (luminosidade) foram os atributos que se destacaram. A Figura 4 mostra o histograma deles. O gráfico em (A)

apresenta o histograma do comprimento, e em (B), do brilho. Considerando-se os dois histogramas, não é possível definir com precisão um limiar para separação das espécies [31].

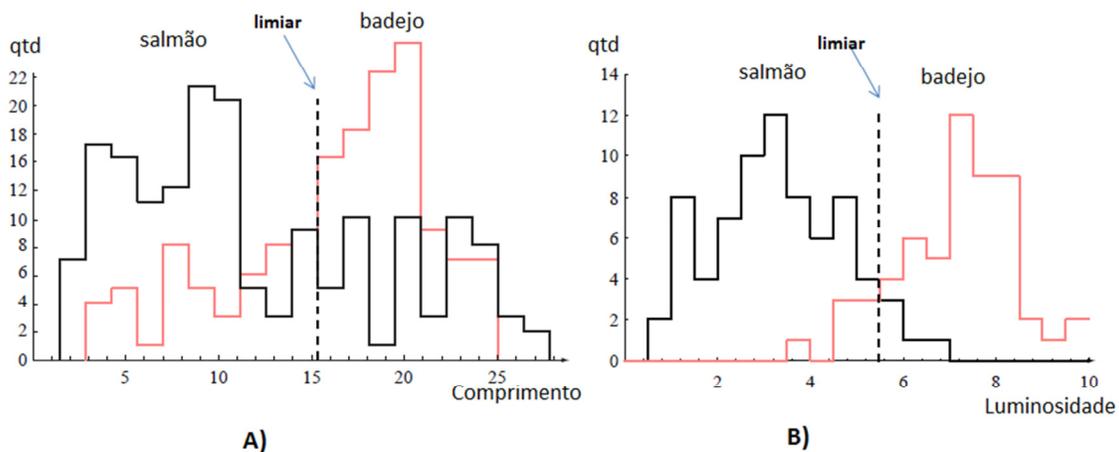


Figura 4- Histograma do comprimento e luminosidade do salmão e badejo [31].

Com o limiar, indicado pela linha tracejada, a classificação apresentou alguns erros, e uma segunda tentativa utilizou os dois atributos juntos. A Figura 5 mostra o gráfico formado pelo comprimento e luminosidade; assim, cada peixe é representado por um ponto no gráfico. De acordo com o gráfico (A), observa-se que não houve uma completa separação, mas esta é melhor do que a separação com somente um atributo. No gráfico (B), com um modelo mais complexo, é possível ter a superfície separadora, com um limiar separando completamente as espécies.

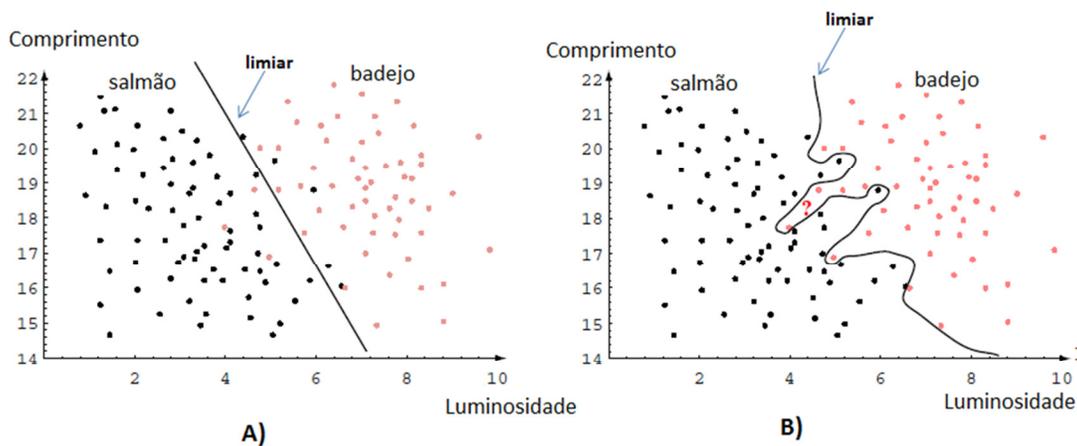


Figura 5- Redução de atributos dos peixes para um ponto no gráfico [31].

Dessa forma, cada peixe será representado por dois atributos em uma matriz (eq. 6).

$$X = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \quad (6)$$

Os recursos podem ter diferentes escalas, embora se refiram a objetos comparáveis. Considerando-se, por exemplo, um padrão de $X = [x_1, x_2]$, no qual x_1 é uma largura medida em metros e x_2 é uma altura medida em centímetros. Ambas podem ser comparadas, adicionadas ou subtraídas, mas não seria razoável fazê-las antes da normalização adequada. A normalização com média zero e desvio-padrão 1 pode ser realizada pela equação de centralização dos dados (eq. 7) [33].

$$x_n = \frac{(x_i - \mu)}{\sigma} \quad (7)$$

Os termos μ e σ são a média e o desvio-padrão do elemento x_i em relação ao conjunto amostral x_n . Como exemplo, considerando a matriz X (eq. 6), x_n assume os valores de x_1 e x_2 ; portanto, uma normalização para cada atributo.

2.5. Detecção de novidades

Detecção de novidades pode ser útil na detecção de padrões potencialmente diferentes, ou seja, padrões que podem indicar falhas ou defeitos. Esse método também é aplicado para identificar fenômenos anormais ou falhas incorporadas em grandes quantidades de dados sem falhas [34]. Detecção de novidades deve ser definida dentro do contexto de nosso conhecimento. Então, é necessário saber o que não é anormal na dinâmica de um processo ou fenômeno específico [35].

O conceito em detecção de novidade é descobrir novos eventos que aparecem no ambiente [36]. Em sua formulação clássica, é a identificação de dados que se desviam de um padrão, usando apenas o conhecimento do padrão sem anormalidade [37].

Detecção de novidades consiste na comparação de um grupo de dados que expressam o comportamento do sistema sem falhas, com grupos novos de entrada [28].

Esse modelo é considerado como um sistema de classe única, pois é desenvolvido para descrever dados sem falhas no treinamento [38].

Métodos de detecção de novidades, na maioria dos casos, são baseados em estatística e redes neurais. Os métodos avaliam a variabilidade e *outliers*. *Outliers*, em termos simples, representam as observações que não seguem o padrão geral da maioria das amostras de dados [39]. O diagrama, na Figura 6, descreve a estrutura de detecção de novidades utilizando cinco grandes categorias: probabilística, baseada em distância, baseada em domínio, baseada em reconstrução e teoria da informação, para as diversas aplicações nas áreas de segurança de informação, saúde e industrial [34].

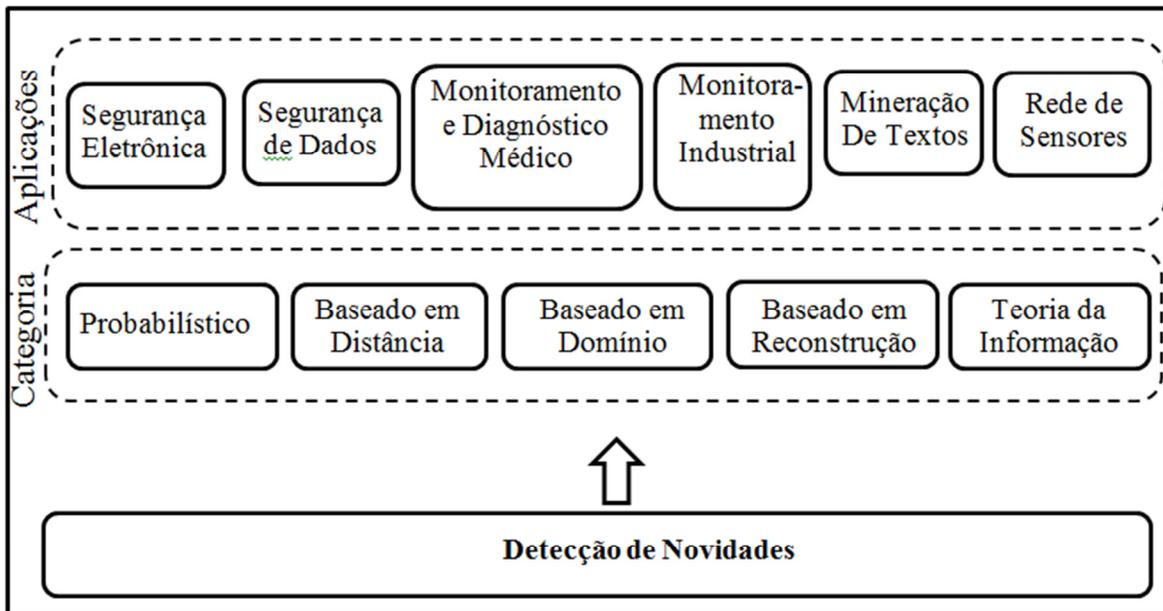


Figura 6- Estrutura de detecção de novidades [34].

2.6. Distância de Mahalanobis

A Distância de Mahalanobis é um método que mede a semelhança entre duas amostras por meio do cálculo da distância entre os conjuntos de dados de covariância da amostragem [40]. $M_D(X)$ é a distância de Mahalanobis, em que $X=(x_1, x_2, \dots, x_i)$ é a matriz com n objetos e variáveis p ; Σ^{-1} é a matriz de covariância da população; e μ o centroide do p espaço dimensional. Quanto menor a distância de Mahalanobis M_D , maior é semelhança entre duas amostras (eq. 8).

$$M_D(X, \mu) = \sqrt{(X - \mu)^T \Sigma^{-1} (X - \mu)} \quad (8)$$

A equação 8 é a norma de X .

$$M_S(X, 0) = \|x\|_S = \sqrt{(X)^T \Sigma^{-1} (X)} \quad (9)$$

$$\|x\|_S = c^2 \quad (10)$$

$$X^T \Sigma^{-1} X = c^2 \quad (11)$$

A norma de X (eq. 10) é igual à equação geral de um elipsoide, em que c define o foco da elipse (eq. 11). A equação geral de um elipsoide centrado na origem satisfaz a equação da distância de Mahalanobis (eq. 12). Em geral, o centro das observações será diferente da origem, e o interesse é na distância de uma observação a seu centro μ .

$$M_D(X, \mu) = \sqrt{(X - \mu)^T \Sigma^{-1} (X - \mu)} \quad (12)$$

Se a matriz de covariância é uma matriz unitária, a distância de Mahalanobis tem o mesmo valor da distância euclidiana [41]. A detecção de *outliers* é um dos usos mais comuns da distância de Mahalanobis [39], [42].

2.7. Modelo Gaussiano multivariado

O modelo Gaussiano multivariado (GMM) tem diversas aplicações, incluindo a estimativa da densidade, detecção de *outlier*, classificação estatística supervisionada e agrupamento não supervisionado [43]. No trabalho proposto por Dimitris [44], a abordagem emprega uma representação estatística das medições dos sinais recebidos por meio de um modelo Gaussiano multivariado, que considera uma forma do tipo grade discretizada e calcula a distribuição de probabilidade em cada ponto da grade.

2.7.1. Função de distribuição Gaussiana multivariada

A função de distribuição Gaussiana multivariada é uma função estatística definida sobre o espaço de probabilidade baseado em variáveis aleatórias. O espaço discreto avaliado pode ser descrito aproximadamente por um modelo paramétrico utilizado para

decisões estatísticas. No trabalho de Machado [45], para determinar a similaridade entre as imagens de um banco de dados, considera-se existência de k classes, cada uma com d características. Sendo assim, o modelo Gaussiano multivariado da classe pode ser definido pela variável aleatória $X_i \sim N_d(\mu_i, \Sigma_i)$, em que μ_i é vetor médio, e Σ_i a matriz de covariância, sendo N_d espaço de características. Assim, é possível representar um conjunto de pontos pertencentes a uma ou mais regiões como uma variável aleatória (eq. 13), distribuída de acordo com:

$$P(x | \Theta) = \frac{1}{(2\pi)^{d/2} |\Sigma|^{1/2}} \exp\left(-\frac{1}{2}(x - \mu)\Sigma^{-1}(x - \mu)^t\right) \quad (13)$$

Na equação, $x \in N_d$ é um ponto do espaço, $\Theta = (\mu, \Sigma)$, μ é a média, Σ é a matriz de covariância de P , t indica transposta, e d é a dimensão espacial do espaço de características. As distâncias entre as variáveis aleatórias, que representam as imagens do banco, foram determinadas por distâncias que permitiram a obtenção dos melhores resultados: euclidiana, Mahalanobis e Fréchet [46].

3. METODOLOGIA

Este estudo propõe uma nova metodologia, para o aumento da confiabilidade de sistemas embutidos de aquisição de dados, baseada no uso de duas técnicas distintas e que estão diretamente conectadas. A primeira é baseada na redundância dos sinais dos sensores do sistema de aquisição de dados; portanto, uma proposta de ações on-line [47]. A segunda técnica fundamenta-se na detecção de anomalias ou novidades dos sinais dos sensores. A segunda técnica está conectada à primeira, pois, em caso de falha da primeira, em função de dois ou dos três sinais redundantes com anormalidades, a anomalia pode ser sinalizada pela técnica de detecção de novidades, ou seja, ações off-line. Além disso, nessa nova metodologia propõe-se uma nova técnica para o sistema de votação do TMR.

3.1. Ideia principal

A ideia principal baseia-se na utilização de dois métodos distintos, que estão diretamente interligados, para a melhoria da confiabilidade de sistemas embutidos de aquisição de dados. Um método aborda a utilização da redundância tripla de sensores ou módulos de medição. Nesse método, os três sinais de leitura são avaliados por um sistema de decisão on-line denominado Voter, que define o sinal de saída. O outro método avalia o comportamento das curvas dos sinais após um procedimento completo, como, por exemplo, o procedimento de aquecimento de um forno. O objetivo da avaliação das curvas é detectar mudança no comportamento baseada em curvas históricas consideradas sem falhas. Em resumo, um método define o sinal de saída em relação aos três sinais de entrada, e o outro visa preencher a lacuna deixada pelo método da redundância - essa lacuna está relacionada à ocorrência de falha em mais de um sinal redundante.

Os métodos descritos no parágrafo anterior podem ser visualizados no diagrama da Figura 7. Na parte superior da figura, destacado na cor laranja, é mostrado o grupo do método que utiliza a redundância, denominado TMR Analógico. Esse grupo possui o núcleo de tomada de decisão denominado Voter. O método de tomada de decisão do Voter é uma nova técnica, proposta por esse trabalho, para sinais representados pelos números reais. O

Voter é composto pelo bloco de votação de sinais e bloco de média dos sinais votados. Os demais grupos, indicados pela cor azul, fazem parte do método que avalia o comportamento. O grupo Armazenamento é composto pelos blocos de Banco de Dados e de Extração de Curvas. Este grupo é fundamental, pois toda avaliação de comportamento é baseada em dados históricos. O grupo Treinamento utiliza as curvas históricas, classificadas como “sem falhas”, como referência para a detecção de comportamento alterado de outras curvas. O grupo Detecção de Novidades utiliza os parâmetros de referência para classificar as curvas em: sem falhas ou com falhas. Como podem ocorrer falhas desconhecidas, utiliza-se o termo detecção de novidades.

A conexão entre os dois métodos é realizada no sinal de saída, do grupo TMR Analógico, interligado com a classificação determinada pelo bloco Detecção de Novidades. A interligação é mostrada pela seta tracejada na cor vermelha na Figura 7. A validação do sinal de saída é objetivada com a conexão entre os dois métodos. Nessa abordagem, os sinais que apresentarem comportamento anormal não serão tratados, entretanto o comportamento vai sinalizar a necessidade de uma intervenção nos módulos de geração desses sinais. A detecção dessa falha será utilizada para evitar a utilização, em bateladas futuras, de sinais com problemas ou para indicar que sensores possuem defeitos intermitentes.

Os métodos são justificados pela proposta de aplicação da nova técnica de votação no TMR para sinais analógicos e também pela conexão da técnica de detecção de novidades, como prevenção de decisão errada do sistema de votação do TMR, quando a maioria dos sinais falhar. As propostas somam-se aos esforços da indústria em aumentar o exigido nível de integridade de segurança definido na norma internacional IEC 61508 [48].

A ideia principal, abordada na proposta deste trabalho, é não só manter o sinal de saída do Voter robusto à entrada de um sinal ruidoso ou com falhas, mas também detectar falhas que possam ocorrer em dois sinais, que são classificadas como novidades, uma vez que muitas não são conhecidas.

Nos próximos subcapítulos, será detalhado o funcionamento de cada grupo.

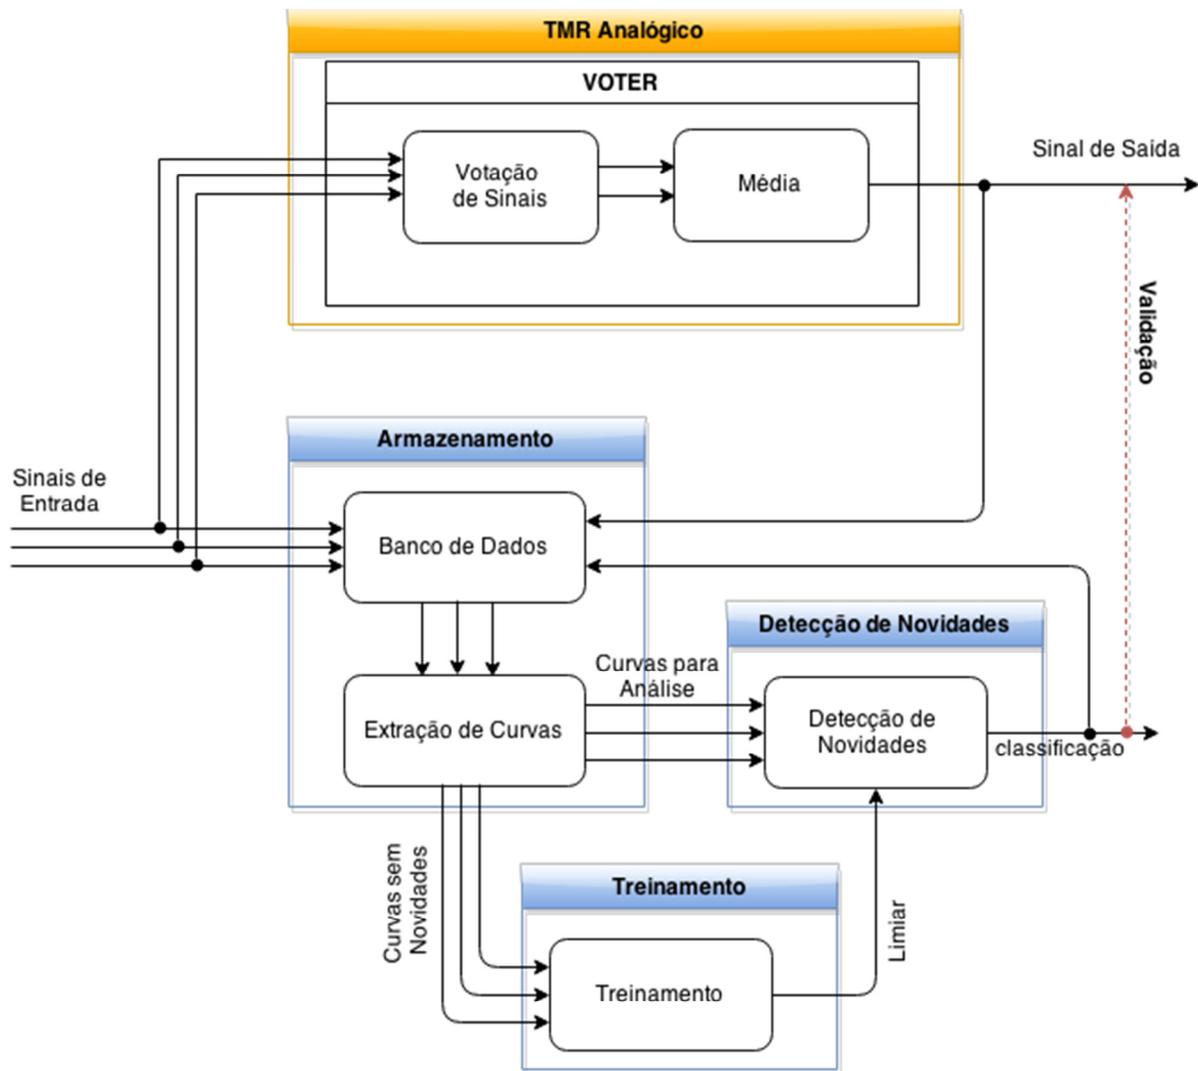


Figura 7 - Diagrama estrutural com a proposta deste trabalho

3.2. TMR Analógico

O grupo TMR Analógico é composto pelo bloco Voter, que define o sinal de saída após análise de três sinais redundantes de entrada. Os sinais de entrada no Voter devem ser sinais analógicos e, portanto, sendo um sinal analógico a saída do Voter.

3.2.1. Voter

Os três sinais analógicos entram no bloco Voter, que vai determinar o sinal de saída. O critério de escolha para o sinal de saída considera a diferença entre os valores dos três sinais. Trabalhos com sistema de votação têm sido amplamente utilizados para corrigir falhas de comportamento de componentes e alcançar alta confiabilidade para circuitos digitais [49]. Técnicas baseadas em redundância foram raramente empregadas em circuitos analógicos [49].

Existem várias técnicas para o sistema de votação para sinais de valores analógicos [49], como as técnicas de sistema de votação de escolha do valor do meio, nos quais os valores máximo e mínimo são descartados, e o valor mediano é selecionado. No gráfico da Figura 8, é possível visualizar as linhas nas cores azul, vermelha e verde, correspondendo aos sinais de 1 a 3 de entrada e a linha preta ao sinal selecionado, ou seja, o sinal de saída do sistema de votação. No intervalo entre t_0 e t_1 , o sinal selecionado corresponde ao sinal 3, cor verde. No tempo t_1 , o sinal selecionado passa a ser o sinal 1, cor azul. A partir de t_2 , o sinal escolhido é o sinal 2, cor vermelha, e, finalmente, a partir de t_3 , o sinal selecionado é o sinal 1, cor azul, conforme a Figura 8 .

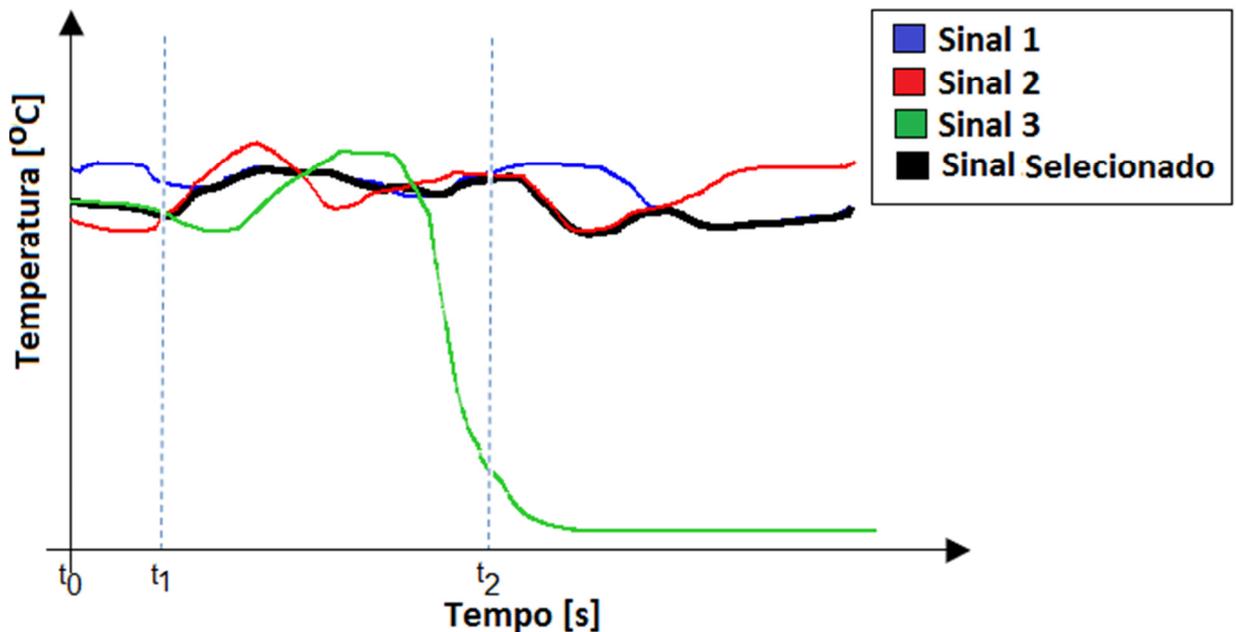


Figura 8- A técnica do valor do meio para o sistema de votação [50].

TMR diversitário é outra técnica que considera três módulos diferentes de medição [51], ou seja, sensores diferentes, o que não é aplicável a este estudo. Essa técnica considera um limiar de erro. Assim, saída seria qualquer valor dentro desse limiar, ou seja, seria necessário um sistema calibrado de referência. Essa técnica não se aplica a esta pesquisa, já que os três módulos de sensores são idênticos e, para sua utilização, seriam necessários módulos completamente diferentes de sensores, além do sistema calibrado de referência.

Outra técnica, no conceito de voto da maioria para sinais analógicos, consiste da verificação da diferença entre os valores de dois sinais ΔV . Caso a diferença seja menor que um valor pré-definido, os valores são considerados iguais, e a saída é a média dos sinais. Caso contrário, os sinais são descartados [49].

Em relação aos Voter digitais, os pesquisadores mostraram que, para alto fator de redundância, ou seja, mais que 7 módulos redundantes, os Voter medianos podem ser mais eficientes que os Voter da maioria [52]. Esse princípio foi utilizado para Voter em sistemas analógicos no trabalho de Askari [49]. No mesmo estudo, Askari mostra que existem diferentes mecanismos de Voter para sistemas analógicos baseados na votação da maioria e

na média, sendo o Voter da maioria mais eficiente quando a redundância é menor ou igual a 3. Redundância implica em aumento de módulos, o que pode ocasionar um custo elevado. Os custos estão relacionados com a implantação de equipamentos, necessidade de estruturas e consumo de recursos [53].

A nova técnica proposta por este trabalho aplicou os dois princípios mais utilizados na literatura: votação da maioria e média, conforme citado anteriormente. Uma diferença importante na nova técnica é a ausência de um limiar para a escolha do sinal de saída, uma vez que a definição do sinal de saída é baseada na média dos dois sinais de maior similaridade. A técnica consiste em selecionar os dois sinais com menor diferença entre si, e o sinal de saída é o valor médio desses sinais. Assim, o sinal de saída do Voter é a média dos sinais da menor diferença.

O algoritmo seleciona dois sinais com menor diferença entre si, em módulo, e calcula a saída com o valor médio dos dois sinais. Dessa forma, entram no algoritmo três sinais denominados: input1, input2 e input3, e, após o processo de seleção e média dos dois sinais, tem-se o sinal de saída na variável “*media*”, conforme Algoritmo 1.

Algoritmo 1 - Média da menor diferença

Entrada input1, input2, input3;

define **media**

dif1 = **modulo**(input1-input2)

dif2 = **modulo**(input1-input3)

dif3 = **modulo**(input2-input3)

Se (dif1 < dif2) **E** (dif1 < dif3) **Então**

media = (input1+input2)/2

Senão (dif2 < dif1) **E** (dif2 < dif3) **Então**

media = (input1+input3)/2

Senão

media =(input2+input3)/2

Saida **media**

Algoritmo 1- Algoritmo do Voter, média dos dois sinais com menor diferença

3.3. Armazenamento

O grupo Armazenamento organiza o registro dos dados do processo nas tabelas do banco de dados. O banco de dados armazena os três sinais de entrada, o sinal de referência e o sinal de saída do Voter.

3.4. Treinamento

O Treinamento determina o valor de limar para a detecção de novidades. A determinação é realizada por meio da análise de um grupo de curvas, nas quais não ocorreram falhas no processo de medição da grandeza física de interesse.

3.4.1. Reconhecimento de Estados

Os três sinais entram no bloco de Reconhecimento de Estados, cuja função é identificar o estado da operação. O estado indica se os valores dos sinais estão sem variação, aumentando ou diminuindo. Esse método descreve curva parada, crescente e decrescente. A determinação do estado é realizada em duas etapas.

A primeira etapa é para determinar o estado da variação pontual entre dois sinais. Essa variação é calculada pela equação (14), em que Δx_i é a diferença entre os valores consecutivos, $x(t_i)$ é o valor da grandeza medida em um determinado tempo discreto t_i e $x(t_{i+1})$ é o valor da grandeza medida no tempo discreto consecutivo t_{i+1} .

$$\Delta x_i = [x(t_{i+1}) - x(t_i)] \quad (14)$$

O resultado de cada operação de diferença será: +1 para diferença positiva, -1 para diferença negativa ou zero (eq. 14). O valor absoluto do sinal não é considerado. Esse algoritmo foi proposto para que uma grande variação no sinal, devido a um ruído ou mau funcionamento, tenha o mesmo peso da variação de um sinal normal. O objetivo era verificar se a curva era crescente ou decrescente por meio da diferença - respectivamente representada por +1 e -1. Caso o sistema utilizasse o valor em módulo da diferença, um ruído ou mau funcionamento, com amplitude três vezes maior, iria erroneamente contribuir

com um peso 3, ou seja, poderia ter uma falsa indicação de mudança de uma curva crescente para decrescente. Se o pico do ruído fosse negativo, nesse caso o pico contribuiria com o valor -3. Com o método de representação de ± 1 , -3 significa que 3 posições são negativas e, nessa situação, indicaria uma tendência decrescente. Essa estratégia minimiza a perturbação do ruído ou do mau funcionamento na definição da curva.

O próximo passo do algoritmo é calcular a diferença entre os valores consecutivos de todos os elementos do vetor da aquisição de dados. O vetor V (eq. 15) é composto pelos valores discretizados x , no qual $x(t_i)$ é o valor medido no tempo t_i .

$$V = [x(t_0), x(t_1), x(t_2), x(t_3), \dots, x(t_i)] \quad (15)$$

O passo seguinte é realizar a soma de todas as diferenças consecutivas pontuais Δx_i no intervalo t_i e armazenar o resultado na variável S (eq. 16). Considerando-se a expressão de Δx_i (eq. 13), pode-se expressar o valor resultante em S (eq. 15), pela equação 16.

$$S = \sum_{i=0}^{i=n-1} [x(t_{i+1}) - x(t_i)] \quad (16)$$

Na próxima etapa, o valor resultante em S é comparado ao intervalo definido por um limiar positivo e negativo. O limiar possui o mesmo valor em módulo e deve ser ajustado para cada processo, que é um sistema que possui características próprias de sinais - neste caso, um sistema de aquecimento. O estado é crescente quando o valor de R é maior que o limiar positivo, decrescente quando menor que o limiar negativo e parado quando está entre os limiares. O pseudocódigo do Algoritmo 2 mostra a implementação da lógica de detecção de estados.

Algoritmo 2 – Detecção de estados

Entrada R

estado = “parado”

Se ($R >$ limiar positivo) **Então**

estado = “crescente”

Se ($R <$ limiar negativo) **Então**

estado = “decrecente”

Fim se

saida estado

Algoritmo 2- Pseudocódigo de detecção de estados

O algoritmo precisa ser calibrado, ou seja, é necessário definir a quantidade de elementos discretizados no vetor e o valor limiar. A quantidade de elementos no vetor é denominada de tamanho da janela. Aqui, a calibração foi manual. Com uma pequena janela e um valor alto limiar, o valor do estado será "*parado*". Por outro lado, se o tamanho da janela é muito grande e o limiar é alto, o sistema perde a sensibilidade na detecção de alterações do estado. Outra situação ocorre quando uma janela é pequena com limiar adequado; o sistema detecta várias mudanças de estados que não correspondem à realidade. É importante analisar essas situações no momento da calibração.

As definições para valores alto e baixo, tanto para limiar quanto para tamanho de janela, são relativas e dependentes das taxas de amostragem e do comportamento dos sinais de cada sistema. Como exemplo, considere a medição de harmônicas. Para medir até a décima harmônica (600 Hz), nos sinais senoidais da energia elétrica, que tem frequência fundamental de 60 Hz, seriam necessárias 1200 amostras por segundo, considerando o teorema de Nyquist [54]. A análise do aquecimento, realizada nesta pesquisa, utiliza a taxa de amostragem de 2 amostras por segundo. Assim, uma janela com tamanho 50 seria adequada ao presente trabalho e considerada muito pequena para o exemplo de medição de harmônica. A definição do tamanho da janela e do valor de limiar foi por tentativa e observação dos resultados.

3.4.2. Extração de Curvas

O módulo Extração de Curvas tem o objetivo de criar grupos de curvas da mesma etapa do processo: crescente, decrescente ou curva completa. As curvas classificadas como paradas não são agrupadas, pois o objetivo do estudo é analisar as curvas dinâmicas - por exemplo, curvas que expressam um aquecimento ou resfriamento do forno.

A extração de curva consiste em agrupar curvas do mesmo estado, ou seja, mesma etapa do processo. O agrupamento das curvas de mesmo estado tem o objetivo unir curvas com mesmo comportamento: crescente, decrescente, ou seja, curvas de mesmo padrão. O agrupamento é organizado em uma matriz. A matriz M (eq. 17) é estruturada pelas linhas formadas pelas curvas e pelas colunas representando tempo discreto. Nessa transformação, o eixo x da série temporal tornou-se o índice da coluna, x_i é a amostra de ordem i no intervalo de tempo, dentro de uma janela indicada pela letra J de tamanho determinado [38].

$$M = \begin{bmatrix} x_1(t), x_1(t+1) \dots (x_1(t+J-1)) \\ x_2(t), x_2(t+1) \dots (x_2(t+J-1)) \\ \dots \\ x_i(t), x_i(t+1) \dots (x_i(t+J-1)) \end{bmatrix} \quad (17)$$

3.4.3. Treinamento

Este bloco usa o modelo Gaussiano multivariado para encontrar o limiar, que será utilizado para detecção de novidades. O modelo Gaussiano multivariado foi proposto para ser usado em problemas que possuem variabilidade e correlação [46]. Considere cada ponto como uma variável aleatória, e cada ponto tem correlação com outros pontos, de modo que o modelo Gaussiano multivariado possa ser aplicado. Os modelos Gaussianos são utilizados em tratamento de sinais, baseados na propriedade ótima da distribuição de Gauss [55]. O modelo foi escolhido, pois tem diversas aplicações, incluindo estimativa da densidade e detecção de *outliers*.

As curvas sem novidades são uma janela com pontos, e existe uma variabilidade em cada ponto. Além disso, cada ponto é considerado como uma variável aleatória, em que

existe correlação entre os pontos. Esta deve-se à sequência no processo de aquecimento e resfriamento. A matriz é usada para criar um modelo multivariado em que cada linha é uma curva do processo, e cada coluna é um ponto ou uma variável. O modelo multivariado é composto por um centroide, que é um vetor de médias das variáveis e uma matriz de covariância.

O método consiste em criar o modelo Gaussiano multivariado com a matriz de curvas sem novidade. Em seguida, realiza o cálculo da distância de cada amostra em relação ao centroide do modelo. A distância vai orientar sobre limiar para detectar novidade. Para cálculo da distância, utiliza-se a distância de Mahalanobis, pois ela não é afetada pela dimensão e é independente de métricas de medição, que são capazes de considerar a associação entre características diferentes e excluem interferência causada pela associação de variáveis. Por isso, o método tem muitas vantagens em comparação à tradicional distância euclidiana [41]. Existem outras técnicas para cálculo das distâncias, como: euclidiana, Mahalanobis e Fréchet. A distância de Mahalanobis é a distância utilizada em vários trabalhos de detecção de *outliers* em que os dados são considerados variáveis aleatórias [39], [41], [42], [46].

O primeiro passo é a criação de uma validação cruzada entre todas as curvas que compõem o modelo Gaussiano multivariado. Utilizando-se as curvas sem novidade, ou sem falhas, o objetivo é calcular a distância de cada curva em relação ao centroide do modelo com outras curvas. A validação é realizada com o cálculo da distância de cada curva em relação ao centroide formado pelas demais curvas. A validação tem como saída um vetor com as distâncias de todas as curvas em relação às demais. A técnica de validação pode ser visualizada no Algoritmo 3.

Algoritmo 3 – Validação cruzada

Entrada matriz.curvas.boas;

num.Curvas = **calcule.quantidade.linhas**(matriz.curvas.boas);

define vetor.distancia.boas **tamanho** = num.Curvas;

define vetor.media **tamanho** = num.Curvas;

Para (i = 1 até num.Curvas) **faça**

{

vetor.media[i] = **calcule.média**(matriz.curvas.boas[-i,]);

covar = **calcule.covariância**(matriz.curvas.boas[-i,]);

vetor.distancia.boas[i] = **calcule.distancia.mahalanobis**(matriz.curvas.boas,
matriz.media[i],
covar) ;

}

Saida vetor.distancia.boas;

Algoritmo 3- Validação cruzada e cálculo das distâncias das curvas sem novidades.

O segundo passo é calcular o modelo Gaussiano multivariado, considerando todas as curvas sem novidades. O pseudocódigo do Algoritmo 4 utiliza como entrada a matriz com curvas sem novidades, e tem como saída a média e a matriz de covariância, que são calculadas levando-se em conta todas as curvas que formam o modelo Gaussiano multivariado.

Algoritmo 4 – Cálculo do GMM

Entrada matriz.curvas.boas;

modelo.media = **média**(matriz.curvas.boas);

modelo.covar = **covariância**(matriz.curvas.boas);

Saida modelo.covar, modelo.media;

Algoritmo 4- Cálculo do modelo Gaussiano multivariado, através da matriz de covariância.

A terceira etapa consiste em determinar um valor de limiar para um determinado intervalo de confiança, utilizando as distâncias calculadas na primeira etapa. Para a determinação do limiar, é encontrado o quantil para o intervalo de confiança desejado; neste estudo, de 95%. Quantis ou frações são essencialmente equivalentes ao termo mais familiar: percentil [56]. O Algoritmo 5 mostra como é implementado o cálculo de limiar.

Algoritmo 5 – Cálculo do Limiar

Entrada vetor.distancia.boas;

confiança = 0.95;

limiar = quantil(vetor.distancia.boas, confiança);

Saida limiar;

Algoritmo 5- Cálculo do limiar, baseado nas distâncias das curvas sem novidades.

3.5. Detecção de novidades

O objetivo deste bloco é detectar novidades nos sinais dos três sensores, ou seja, nos sinais de entrada do Voter. A detecção de novidades consiste em calcular a distância de Mahalanobis das curvas em análise, em relação ao centroide do modelo Gaussiano formado pelas curvas de treinamento. Existem outras distâncias que poderiam ser usadas como métrica - por exemplo, a distância euclidiana e de Fréchet. No entanto, a literatura tem mostrado que, para sistemas de detecção de outliers, a distância de Mahalanobis é a mais indicada, conforme citado no capítulo 3.4.3. A motivação é detectar curva de sinal de entrada do Voter com comportamento diferente, quer dizer, com variabilidade em relação à variabilidade média de um grupo de curvas consideradas sem falhas; como já foi citado anteriormente, detecção de novidades. Os resultados da detecção de curvas com novidades serão utilizados para sinalizar possível falhas de sensores ou módulos de medição. Essa está diretamente conectada à ideia do TMR, ou seja, valida o TMR, já que, neste trabalho, não há uma temperatura de referência.

O procedimento para detecção de novidades é iniciado pelo cálculo da distância de Mahalanobis. A distância de cada curva é em relação à média e à matriz de covariância do modelo, ambas anteriormente calculadas. Como as curvas estão agrupadas nas linhas, em uma matriz de curvas a serem avaliadas, a ideia é calcular a distância de cada linha, que corresponde a uma curva, e armazenar esse valor em um vetor de distâncias. O procedimento é mostrado utilizando o pseudocódigo do Algoritmo 6. A saída do pseudocódigo é a variável: “vetor.distancia.analise”, que é o vetor com a distância de Mahalanobis correspondente a cada curva que está sendo analisada.

Algoritmo 6 – Cálculo das distância das curvas para análise

Entrada matriz.curvas.analise, modelo.media, modelo.covar;

num.Curvas = **quantidadeLinhas**(matriz.curvas.analise);

define vetor.distancia.analise **tamanho** = num.Curvas;

Para (i = 1 até num.Curvas) **Faça**

```
{  
vetor.distancia.analise[ i ] = mahalanobis(matriz.curvas.analise[i],  
                                         modelo.media,  
                                         modelo.covar );  
}
```

Saida vetor.distancia.analise;

Algoritmo 6- Cálculo da distância de Mahalanobis para as curvas em análise.

O próximo passo consiste em comparar as distâncias de cada curva, com a distância limiar. A curva que, em relação ao centroide do modelo, possuir distância maior que a definida pelo valor da distância limiar, é considerada como curva com novidades. A curva cuja distância, em relação ao centroide, é menor ou igual à distância limiar, é classificada como curva sem novidades. O método descrito para detecção de novidades, por meio da comparação das distâncias, é mostrado no pseudocódigo do Algoritmo 7.

Algoritmo 7– Detecção de novidades com uso do limiar

Entrada limiar, vetor.distancia.analise

num.Curvas = **quantidade**(vetor.distancia.analise);
define vetor.novidade **tamanho** = num.Curvas;

Para (i = 1 até num.Curvas) **faça**

{

Se (vetor.distancia.analise[i] > limiar) **Então**

 vetor.novidade[i] = "Verdadeiro";

Senão

 vetor.novidade[i] = "Falso";

Fim-se

}

Saida vetor.distancia.analise;

Algoritmo 7- Detecção de novidade pela comparação das distâncias das curvas em análise com o valor de limiar.

3.6. Resumo da metodologia

A metodologia apresentada tem a intenção de contribuir para a melhoria da confiabilidade de sinais de sensores analógicos, por meio das técnicas propostas. O resultado esperado é um sistema mais robusto às falhas, indicadas pelos sinais em sistemas de aquisição de dados. A metodologia apresenta uma grande vantagem, que é a conexão de duas técnicas distintas para a melhoria da confiabilidade: TMR analógico e detecção de novidades. Outro destaque está na nova abordagem proposta para o sistema de votação do TMR para sinais analógicos. Essa abordagem utiliza os princípios de duas técnicas já estudadas para redundância para sinais analógicos, com a perspectiva de conseguir unir as vantagens de ambas as técnicas.

4. PLANTA-PILOTO

Este capítulo tem como foco a descrição e apresentação da planta-piloto utilizada nos experimentos realizados neste estudo.

4.1. Justificativa

A ideia principal da planta-piloto é ter um sistema composto por um conjunto de hardware e softwares para a geração de dados reais a serem utilizados neste trabalho. O sistema possui um circuito de aquisição de dados e um circuito de potência para comando do forno elétrico. Todo sistema é controlado, de forma automática, por um software de supervisão, que é encarregado de tratar e armazenar os dados.

A principal justificativa da construção da planta-piloto é a geração de dados reais a serem utilizados no presente estudo. Além disso, a planta proporciona não só a replicação dos experimentos realizados, mas também a utilização e alteração do ambiente para futuros trabalhos. As replicações e alterações na planta podem ser realizadas de forma simples e fácil, devido às dimensões dos equipamentos que a compõem.

Foram observados padrões nas formas das curvas de operação do forno elétrico utilizado na planta. Com esses padrões, é possível aplicar os métodos propostos por esta dissertação.

4.2. Descrição

A planta-piloto é dividida nas seguintes partes: estrutura, software, aquisição de dados, circuito de comando, sensores e circuitos.

4.2.1. Estrutura

A planta é composta por um forno residencial (A), circuitos eletrônicos de geração, amplificação de sinais (B), sistemas embutidos de aquisição de dados e comando (C) e computador com software supervisor e banco de dados (D), de acordo com a Figura 9.

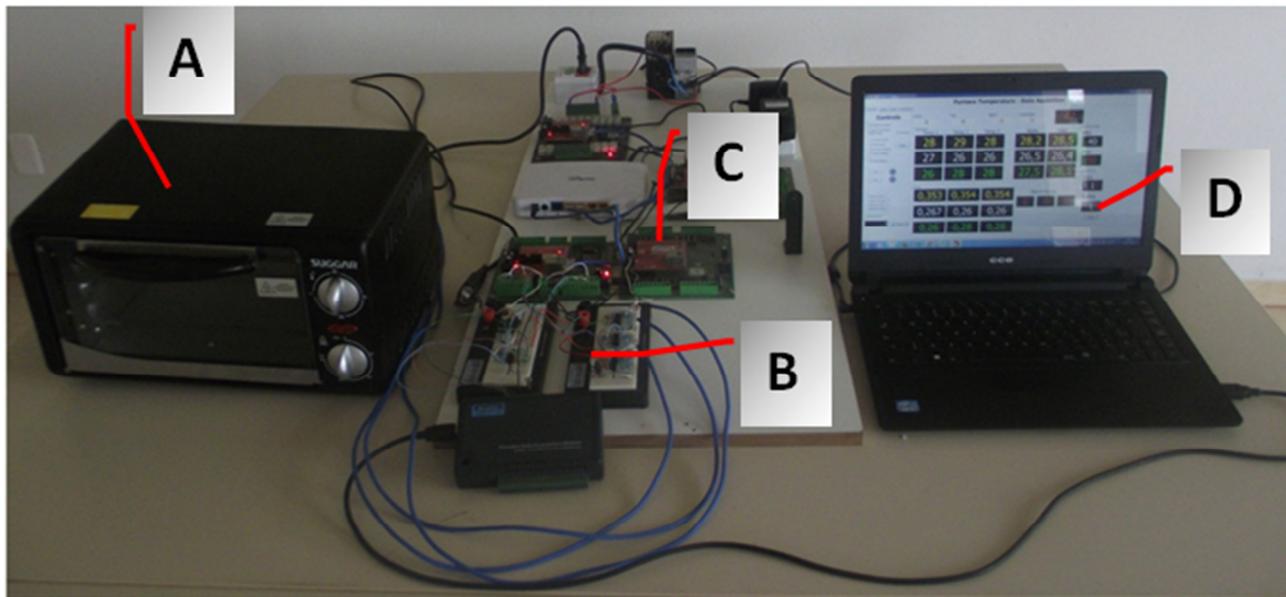


Figura 9- Planta-piloto, composta por forno (A), bancada eletrônica com sistemas embutidos (B);(C) e notebook (D)

Os sistemas embutidos de aquisição de dados e comando estão interligados com o software supervisor por meio do barramento ethernet Modbus TCP/IP. O sistema embutido de aquisição de dados converte os sinais analógicos em digitais, que são enviados para o software supervisor. O sistema embutido de comando é controlado pelo software supervisor e realiza o acionamento do forno. O banco de dados armazena informações de controle e da leitura das temperaturas e está diretamente interligado ao software supervisor, conforme é mostrado na Figura 10.

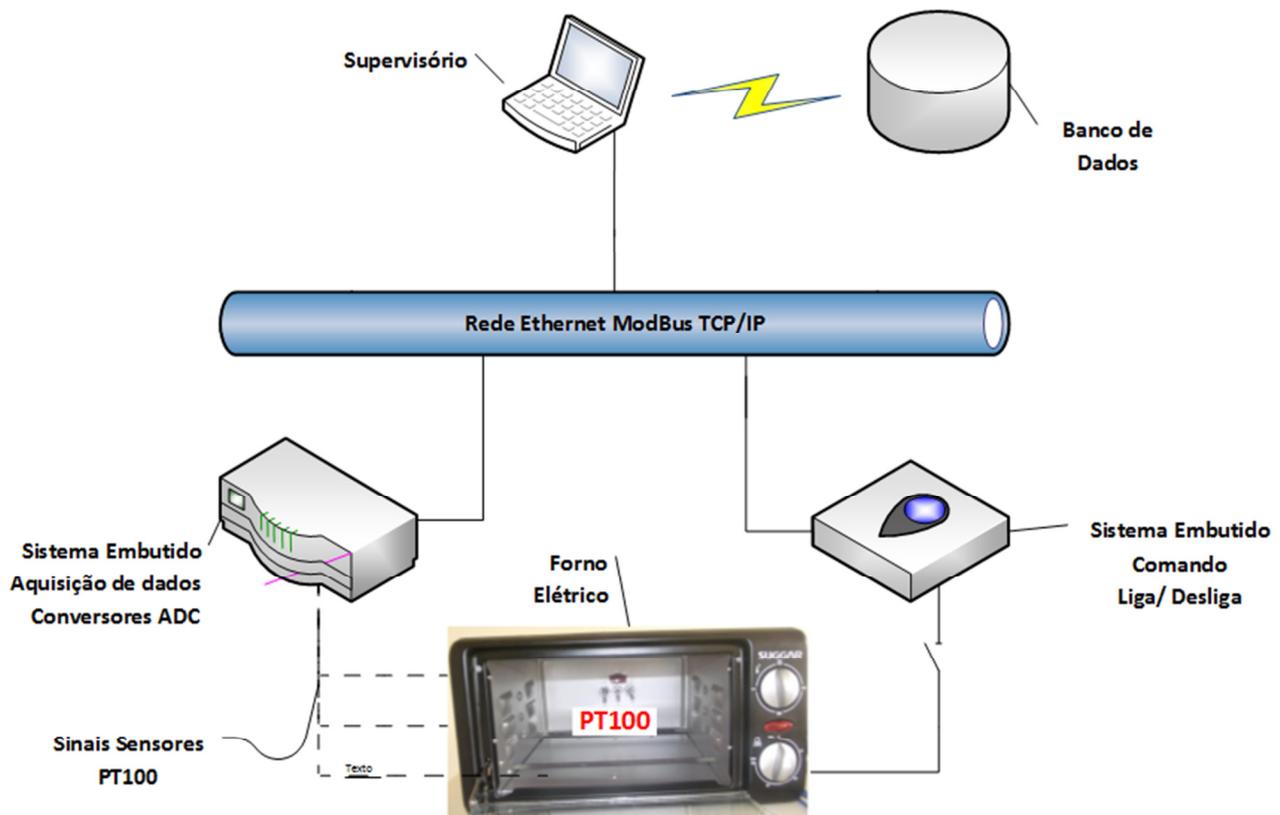


Figura 10- Esquemático da planta-piloto com equipamento e barramento ethernet de comunicação

4.2.2. Sensores

A medição da temperatura é realizada através de dois tipos de sensores: RTD e circuito integrado. O medidor RTD é um acrônimo derivado do termo em inglês “*Resistance Temperature Detector*”, que é uma resistência que varia com a temperatura [57]. PT100 é um nome comercial de um tipo de RTD que, a 0 °C, apresenta uma resistência de 100 Ω e tem coeficiente de temperatura positivo de 0,385/°C [58] . O circuito integrado é o sensor de temperatura LM35 que gera um sinal de 10 mV/°C [59]. A Figura 11 mostra em (A) um sensor LM35 e em (B) um PT100.



Figura 11- Imagens do sensor LM35 em (A) e sensores PT100 em (B)

Os sensores PT100 foram utilizados na montagem do TMR e geraram os dados de temperatura, que foram utilizados em todos os experimentos. O sensor LM35 foi incluído na planta para ser utilizado como um sensor de referência da temperatura. Foi escolhido o sensor LM35 por apresentar uma maior precisão em relação ao sensor RTD. Com o sensor de referência, objetivou-se indicar a temperatura mais provável, uma vez que não foi possível utilizar um sensor de temperatura certificado. A temperatura de referência auxilia nas análises dos experimentos. Os três sensores utilizados para construir o TMR foram fixados na parte da traseira do forno. Houve uma preocupação em relação ao posicionamento dos sensores, ou seja, menor distância entre os sensores e fixação mais centralizada possível em relação à tampa traseira do forno, como na Figura 12.

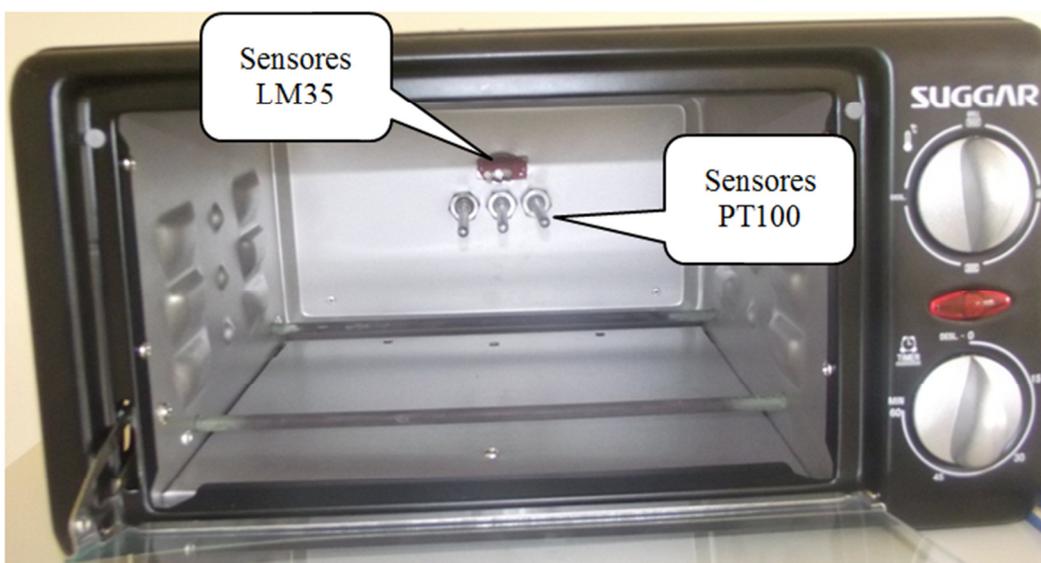


Figura 12 - Localização dos sensores de temperatura dentro do forno.

PT100 é RTD de classe A e possui erro de $\pm 1^\circ\text{C}$ [60], o intervalo de erro está entre as curvas de cor azul no gráfico (A), na Figura 13; as curvas na cor verde não se aplicam ao PT100. O LM35 utilizado foi o LM35AH, que possui um erro de $\pm 0,25^\circ\text{C}$ à temperatura ambiente e $\pm 0,75^\circ\text{C}$ no intervalo de -55°C a 150°C - gráfico (B) na Figura 13 [59] .

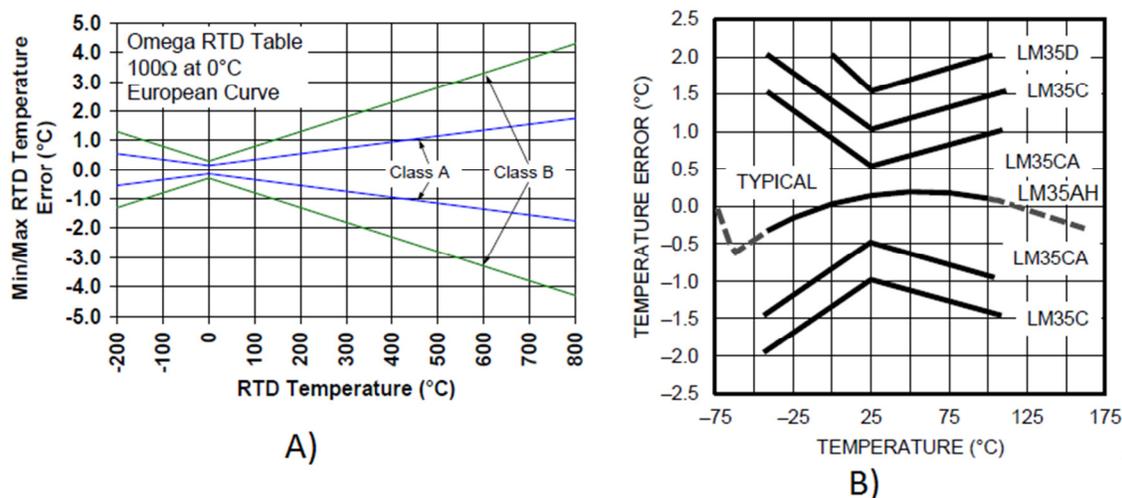


Figura 13- Tabela de indicação de erro do PT100(A) e do LM35 em (B)

A técnica utilizada para a medição de temperatura consiste em passar uma corrente constante através da resistência do PT100. Então, é possível ler a tensão gerada entre os terminais do PT100 [61]. Foi utilizado sensor PT100 com dois cabos - configuração usada quando a resistência parasita dos fios de ligação é pequena. O cabo não pode ter comprimento maior que 3 m [62].

4.2.3. Software

O software de supervisão, desenvolvido em C++, realiza todo o controle do sistema. O software é um sistema supervisório que tem comunicação on-line com os sistemas embutidos de aquisição de dados e de comando do forno elétrico. O sistema de controle inicia a comunicação ethernet com a placa de aquisição de dados, e essa placa realiza a conversão analógica para digital dos valores de tensão gerados pelos sensores de temperatura.

O supervisório realiza o tratamento dos dados convertendo os valores de tensão para valores de temperatura e aplicando o algoritmo de média móvel. O bloco de tratamento de sinais recebe como parâmetro o tamanho da janela, e a passagem de parâmetro é indicada pela linha tracejada na Figura 14. A janela define o tamanho da fila circular da média móvel. São recebidos sinais de três sensores; na sequência, é verificado se o sinal de saída será por votação - nesse caso TMR - se não, é realizada a média aritmética dos três sinais. Na sequência, o sinal de saída é utilizado pelo controle automático, se ele estiver habilitado. Tanto o controle automático quanto o controle manual resultarão em ações de comando de liga ou desliga. Esses comandos são enviados para o sistema embutido responsável pelo acionamento do circuito de potência do forno. O banco de dados registra os dados de entrada após tratamento, o valor do sinal de saída oriundo dos três sinais de entrada e o valor do sinal de comando. A operação descrita neste parágrafo pode ser visualizada no fluxograma da Figura 14.

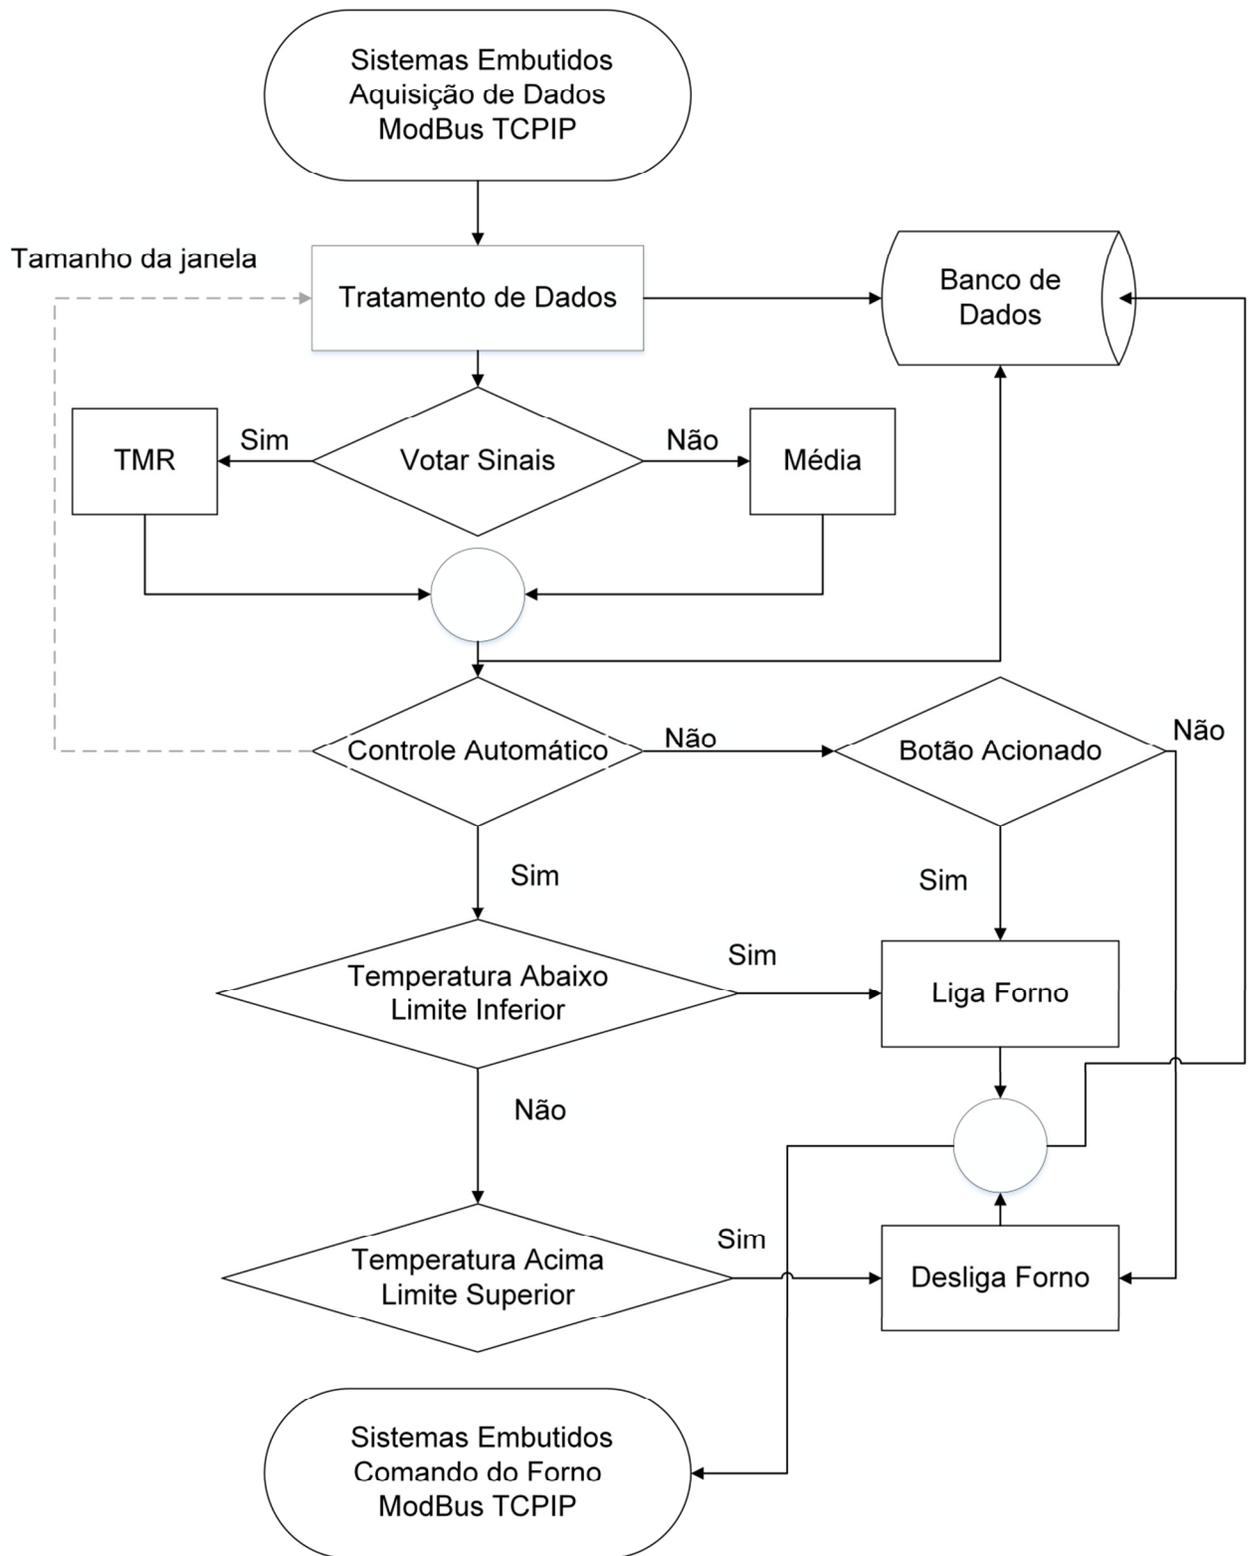


Figura 14- Fluxograma do sistema de controle da planta-piloto.

Na tela do software supervisorio, Figura 15, é possível não só verificar todos os valores das grandezas medidas, como também o funcionamento do sistema. No bloco (A) estão os valores das tensões geradas nos sensores de temperatura. Os três displays superiores na cor amarela são do PT100, e os seis restantes são valores do LM35. No bloco (B) estão os valores da temperatura, sendo que, após o tratamento dos dados, a organização é a mesma do bloco (A). No bloco (C), a coluna à esquerda corresponde à saída da média aritmética, e a coluna da direita, à saída da votação no TMR. Além disso, é possível visualizar o início, o fim e o número de cada batelada de aquecimento em (D) e também configurar os limites inferiores e superiores de temperatura de aquecimento. O lado esquerdo da tela (E) possui a parte de configuração dos modos de operações manual e automático e a habilitação da comunicação ethernet.

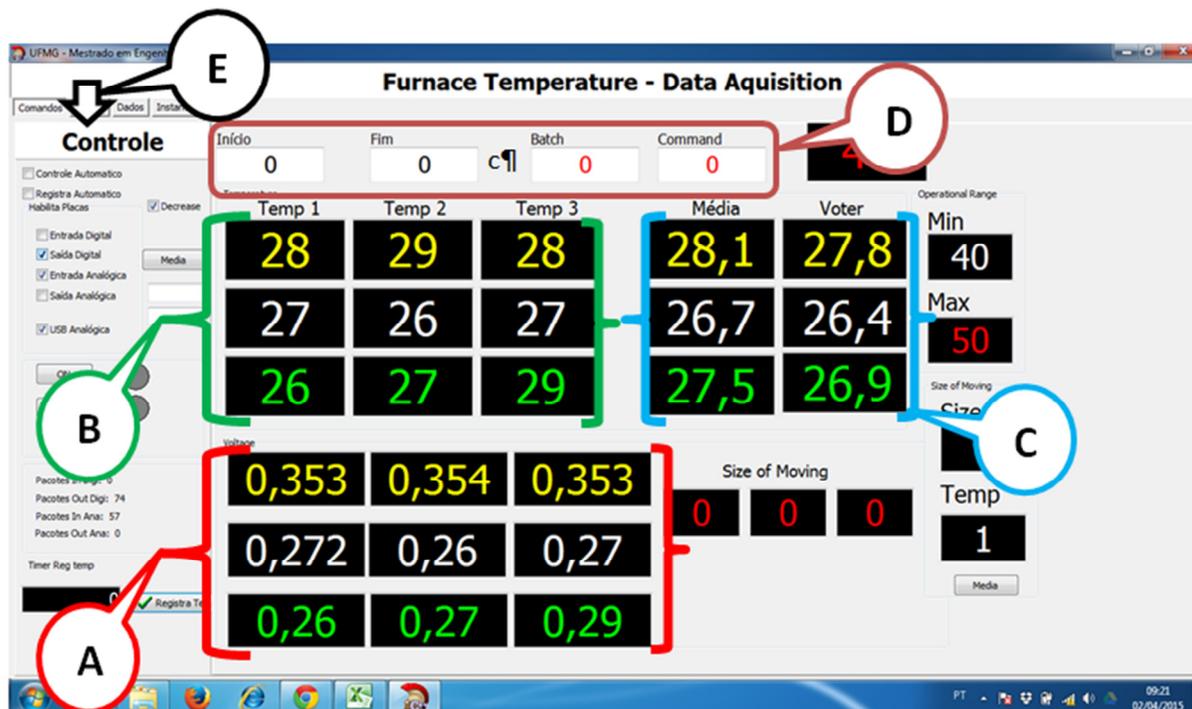


Figura 15- Tela do software supervisorio que controla a planta-piloto

A planta-piloto utiliza dois tipos de comunicação entre o computador e os sistemas embutidos: ethernet, com protocolo Modbus TCP/IP [63], e USB. Os sistemas embutidos que utilizam o protocolo ethernet são de desenvolvimento próprio e têm como núcleo um microcontrolador core ARM7 de 32 bits [64]. A placa de aquisição que utiliza a comunicação USB é de fabricação da empresa Advantech®.

5. EXPERIMENTOS

Neste capítulo são demonstrados os experimentos realizados na planta-piloto com a aplicação das técnicas e métodos apresentados. Os experimentos tiveram as seguintes etapas: geração das curvas, experimentos com redundância e experimentos com reconhecimento de padrões. Mostra-se somente a aplicação das técnicas, pois os resultados, as decisões e análises serão apresentados no próximo capítulo.

5.1. Geração das curvas

As curvas de aquecimento foram geradas por meio do sistema automatizado da planta-piloto. O comando do forno, tratamentos e armazenamentos dos dados foram realizados pelo software supervisor. Para a geração das curvas, foi definido um intervalo com uma diferença de 30 °C a 60 °C na operação do forno, sendo a temperatura inicial de 40 °C. Definiu-se 40 °C de temperatura inicial, em função das temperaturas da região onde foram gerados os experimentos - Pirapora MG – que, no verão, atingem médias de 35 °C na sombra. O intervalo de 30 a 60 °C, para diminuir o tempo de resfriamento.

5.1.1. Curvas sem novidades

As curvas sem novidades foram geradas considerando-se o processo em operação sem anormalidades. Foi possível acompanhar o processo de criação de curvas por meio de um gráfico no software supervisor. O gráfico possibilitou a observação visual de um padrão entre as várias curvas do processo. A Figura 16 mostra o gráfico das curvas geradas pelos três sensores PT100 no intervalo de 10.000 segundos, ou seja, 20.000 registros, sendo possível verificar um padrão na ordem das temperaturas.

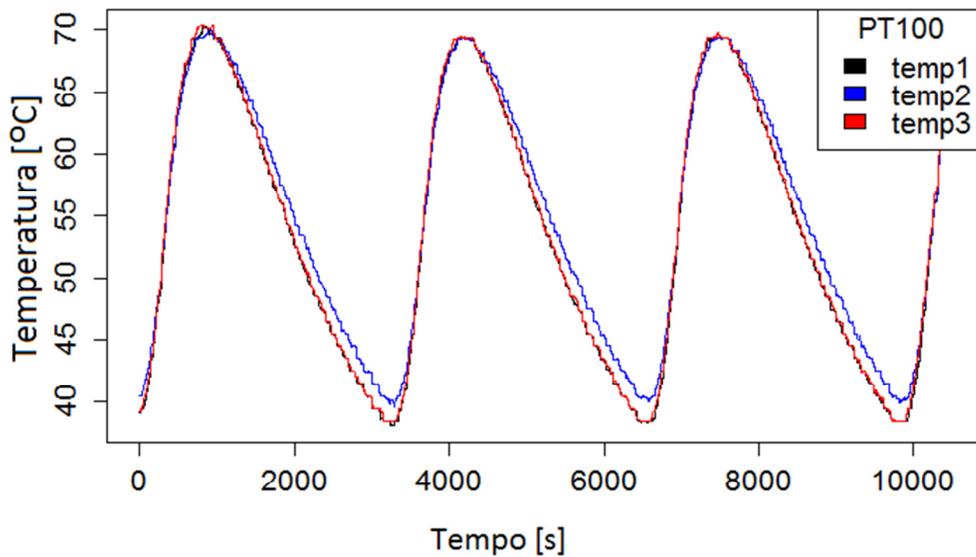


Figura 16- Grupo de curvas sem novidades dos sinais dos três sensores PT100, respectivamente temp1, temp2 e temp3.

A Figura 17 mostra o gráfico com um grupo de curvas de três PT100, no intervalo de 3500 segundos.

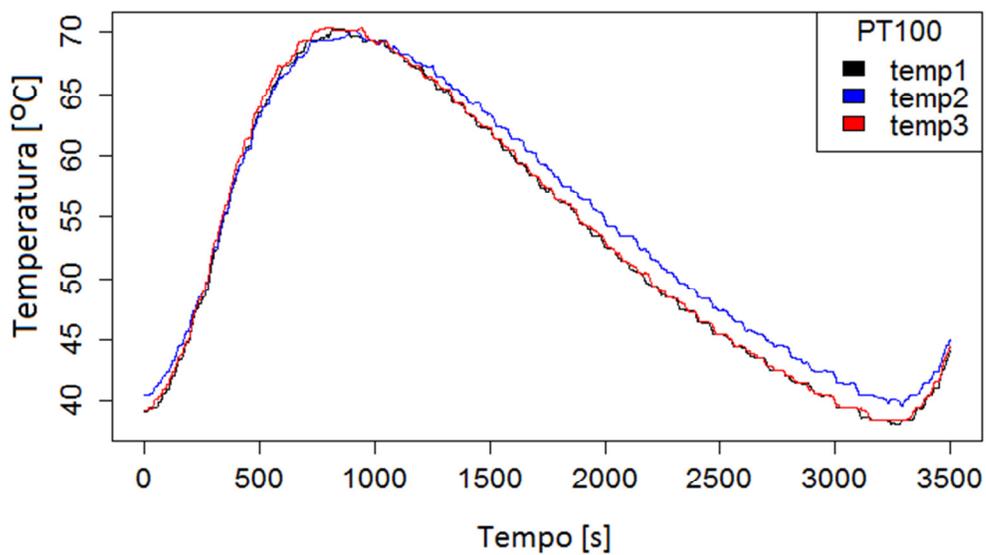


Figura 17 - Grupo de curvas sem novidades de três sensores PT100 em intervalo com 3500 segundos.

Um grupo de curvas sem novidades foi gerado diminuindo o tamanho da janela da média móvel que trata os sinais dentro do microcontrolador da placa de aquisição de dados. A diminuição do tamanho da janela aumentou o nível de ruído dos sinais enviados para o *software* supervisor. As curvas dos sinais dos PT100 *temp1* e *temp2*, após a diminuição da janela da média móvel, podem ser visualizadas na Figura 18.

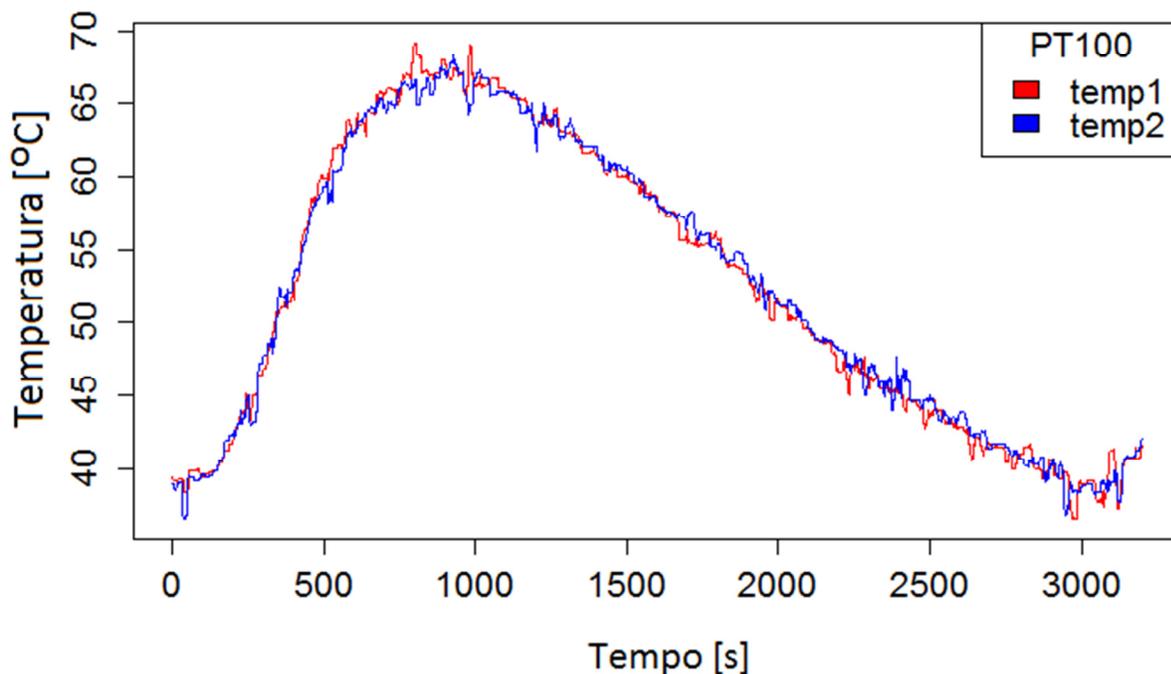


Figura 18- Curvas sem novidades dos sinais sem tratamento por média móvel nos microcontroladores dos sistemas embutidos de aquisição de dados.

5.1.2. Curvas mistas

Um grupo de curvas com e sem novidades foi criado, denominado grupo com curvas mistas. O grupo foi gerado com a utilização dos sinais com menor nível de tratamento de dados pelos microcontroladores das placas de aquisição de dados. O único tratamento de dados foi realizado pelo *software* supervisor, sendo que o tratamento dos sinais é feito por meio da média móvel, em que o tamanho da janela é uma variável global que pode ser

alterada em tempo de execução do software. O pseudocódigo do Algoritmo 8 mostra a implementação da média móvel.

Algoritmo 8 – Média móvel

Variáveis Globais

```
define tamanho.Janela = 40;  
define vetor.Janela tamanho = tamanho.Janela;  
define controle;
```

Entrada valor

```
vetor.Janela [controle] = valor
```

```
  Para ( i = 1 até tamanho.Janela) faça  
  {  
    acumulador = acumulador + vetor.valores[ i ];  
  }
```

```
  Se (controle >= tamanho.Janela) então  
    controle = 0;
```

```
  Senão  
    controle = controle + 1;
```

```
media.movel = acumulador / tamanho.Janela;
```

Saida media.movel ;

Algoritmo 8- Algoritmo de média móvel.

De forma automática, em cada batelada, o tamanho da janela foi diminuído para o sinal de um PT100, mantendo os outros dois sinais com tamanho de janela maior. Esse método possibilitou a formação das curvas mistas, quer dizer, um sinal muito ruidoso com dois sinais com menor nível de ruído. A variação do tamanho das janelas foi alternada em cada batelada do processo. Com esse método, a cada batelada ou ciclo, um sensor tinha seu nível de tratamento de sinal reduzido, enquanto que, para os outros dois sensores, era aumentado. A Figura 19 mostra o comportamento da alternância do tamanho da janela entre os PT100 *temp1* e *temp2*. É possível observar a alternância do sinal com ruído, que inicia

com o sinal de *temp2*, cor azul, ciclo 1 (A); no próximo ciclo não há ruído (B); no terceiro ciclo(C), o sinal de *temp1* apresenta um ruído maior e, assim, de forma alternada, exceto para o sinal de *temp3* em vermelho.

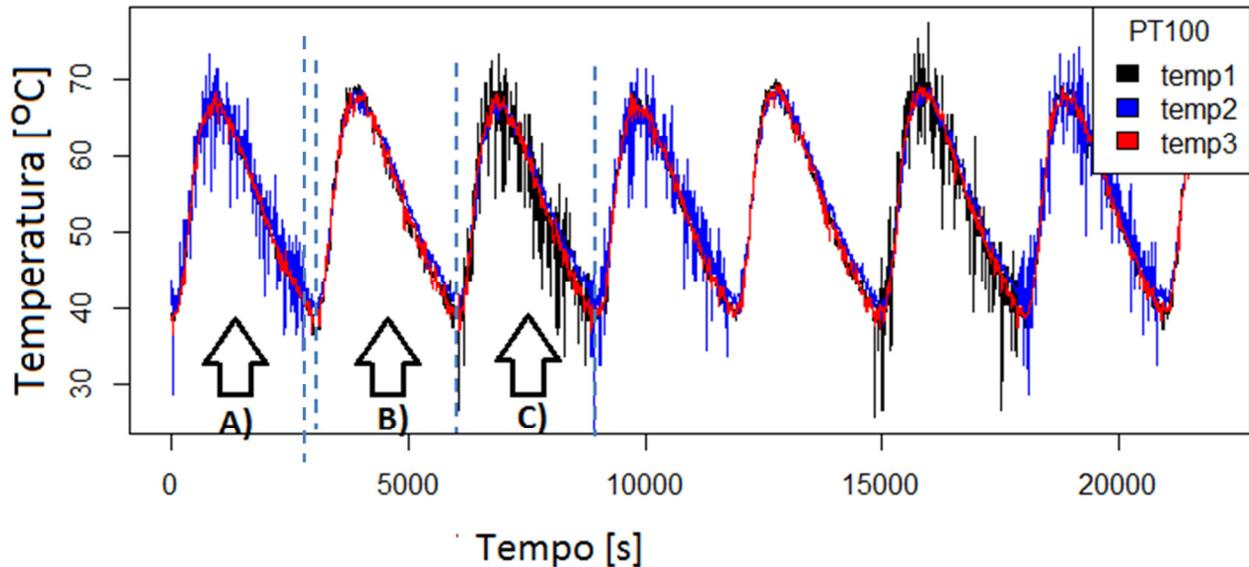


Figura 19- Grupo de curvas mistas dos sensores PT100, (A) ruído em temp 2 na cor azul, (B) sem ruído e (C) ruído em temp 1 na cor preta, temp 2 na cor azul.

Os resíduos [65] foram utilizados para identificar o sinal com maior ruído no ciclo. Resíduos serão detalhados no capítulo 6.2 (eq. 21). A Tabela 3 mostra, em cada linha, o valor das médias (avg) e desvios-padrão (sd) dos sinais de cada ciclo. O maior ruído, por ciclo ou linha, é indicado pelos maiores valores em negrito.

Tabela 3- Determinação de sinal ruidoso através dos valores das médias (avg) e desvios-padrão (sd) dos resíduos de temp1 (T1), temp2 (T2) e temp3 (T3). Em negrito, indicação dos sinais com maior ruído.

ciclo	T1		T2		T3	
	avg	sd	avg	sd	avg	sd
1	0,77	1,34	1,96	4,64	0,62	1,50
2	0,62	0,93	0,99	1,12	0,46	0,76
3	2,47	7,80	1,78	3,78	0,93	1,98

5.1.3. Experimentos com redundância

Os experimentos foram realizados com a aplicação das técnicas de redundância existentes com TMR e também a nova técnica proposta para o algoritmo de decisão do Voter. As técnicas de redundância utilizam o TMR para sinais digitais. Fez-se uso do software supervisor, no qual foram implementadas as duas técnicas para o algoritmo de decisão do Voter: média dos três e média da menor diferença. Esta última é a nova técnica aqui proposta.

5.1.4. Média dos três

A técnica denominada média dos três é a média aritmética dos três sinais de entrada. Ela é aplicada em trabalhos de redundância de sinais de circuitos analógicos anteriormente citados. Também é baseada no conceito estatístico de que a média indica o valor mais provável do grupo de valores. A técnica foi aplicada nos dados das curvas sem novidade. Na Figura 20, as curvas em cinza-claro são os sinais dos PT100, e a curva preta indica a curva resultante da aplicação da técnica.

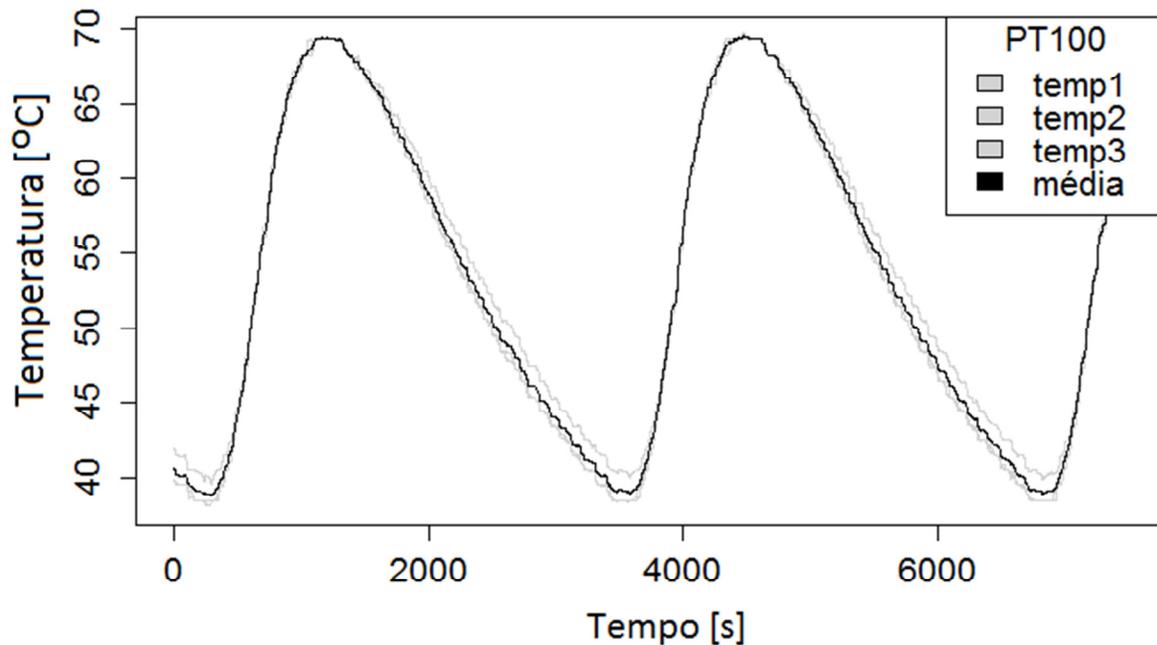


Figura 20- Gráfico com curvas dos três PT100 em cinza e a curva da média dos três sensores em preto.

A outra aplicação da técnica foi em dados em que havia curvas com sinais ruidosos que foram gerados com a diminuição da média móvel dos sinais nas placas de aquisição de dados. O comportamento dos sinais e a curva resultante, em preto, são mostrados na Figura 21. É possível observar que a curva resultante é fortemente influenciada pelos picos dos sinais ruidosos.

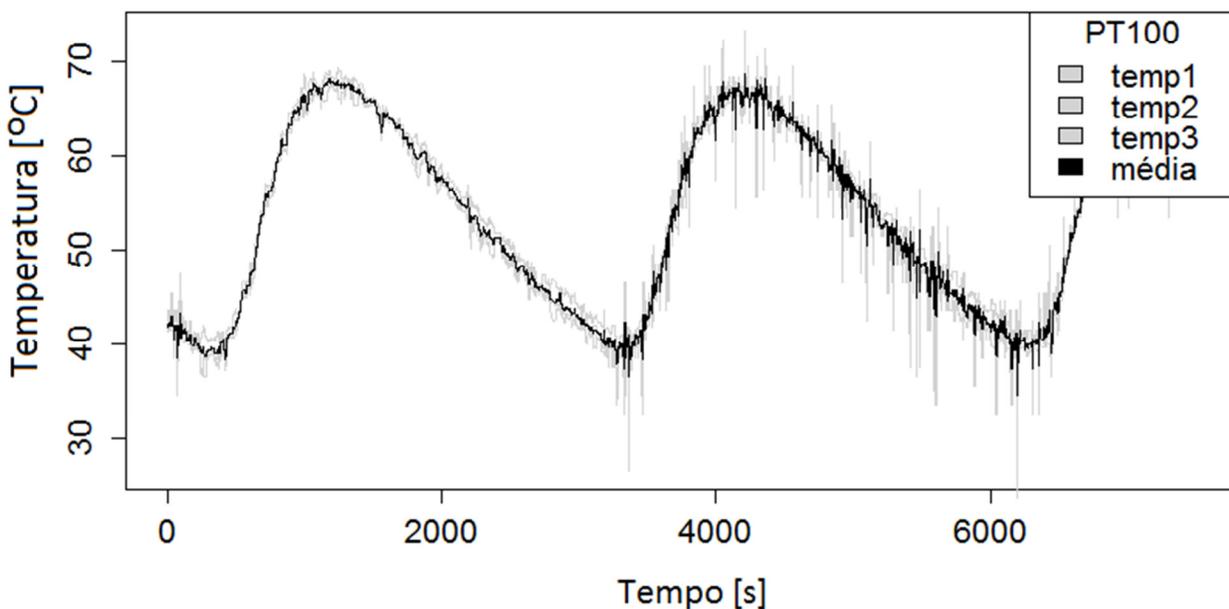


Figura 21- Gráfico com as curvas dos 3 PT100 em cinza, a curva da média em preto.

5.1.5. Média da menor diferença

A técnica da menor diferença, que é proposta neste estudo, consiste em realizar a média de dois dos três sinais com menor diferença entre si, e foi utilizada nos mesmos grupos de curvas em que foi aplicada a técnica média dos três. A Figura 22 mostra o comportamento das curvas, em que as curvas cinza são dos sensores PT100, e a curva preta é a resultante.

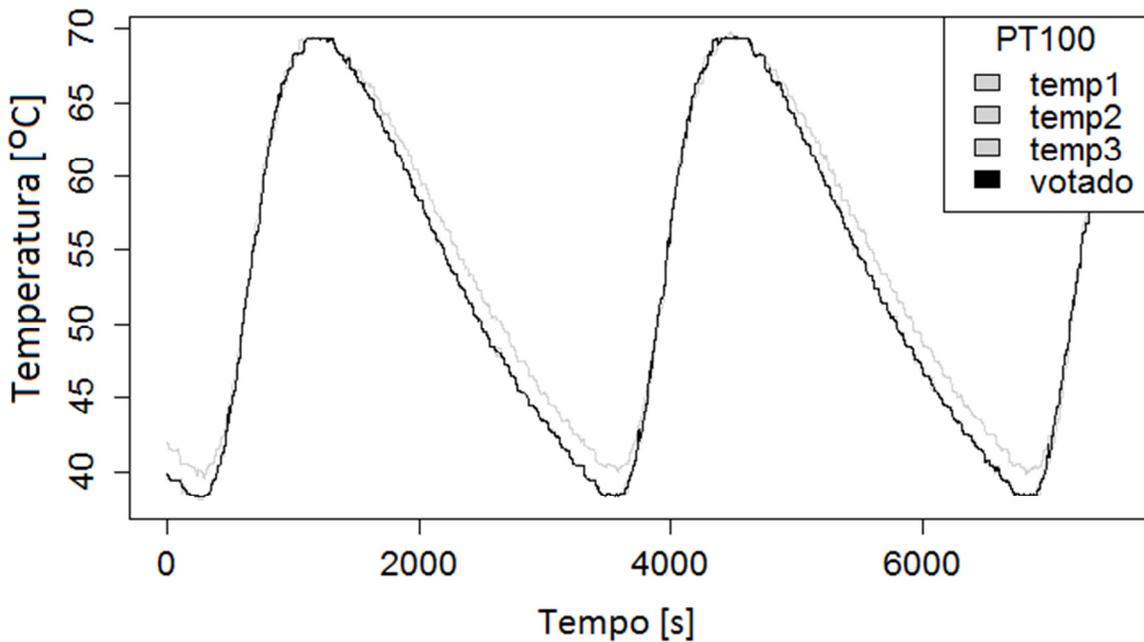


Figura 22 - Curvas com os valores dos 3 PT100 em cinza e a curva de saída do Voter em preto.

A técnica foi aplicada aos dados com sinais ruidosos. O comportamento dos sinais e a curva resultante, em preto, são mostrados na Figura 23. Observa-se que ela sofre pouca influência dos picos dos sinais ruidosos.

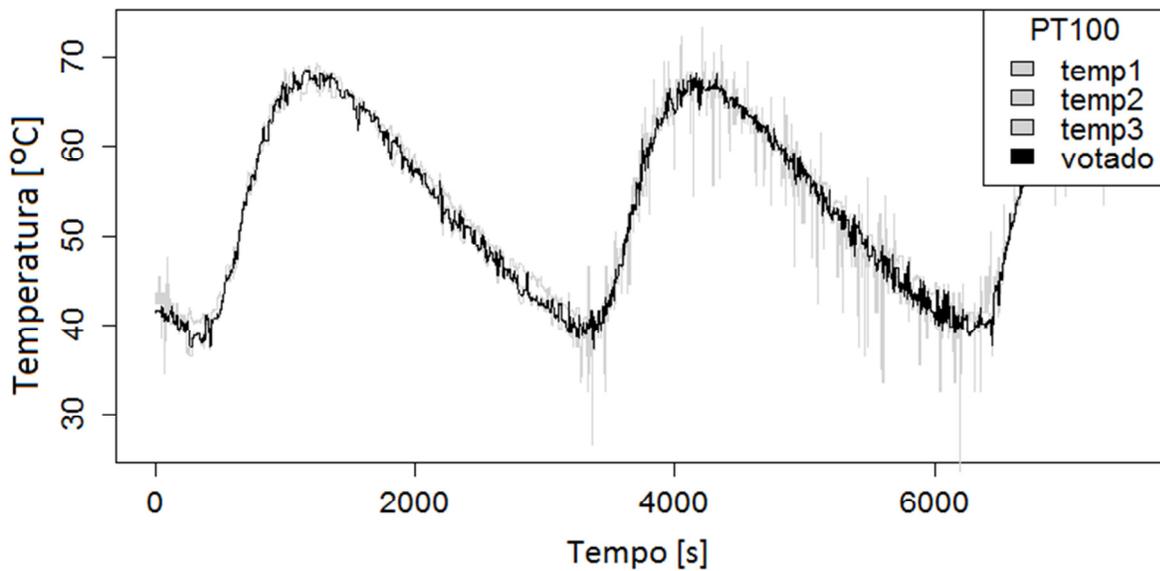


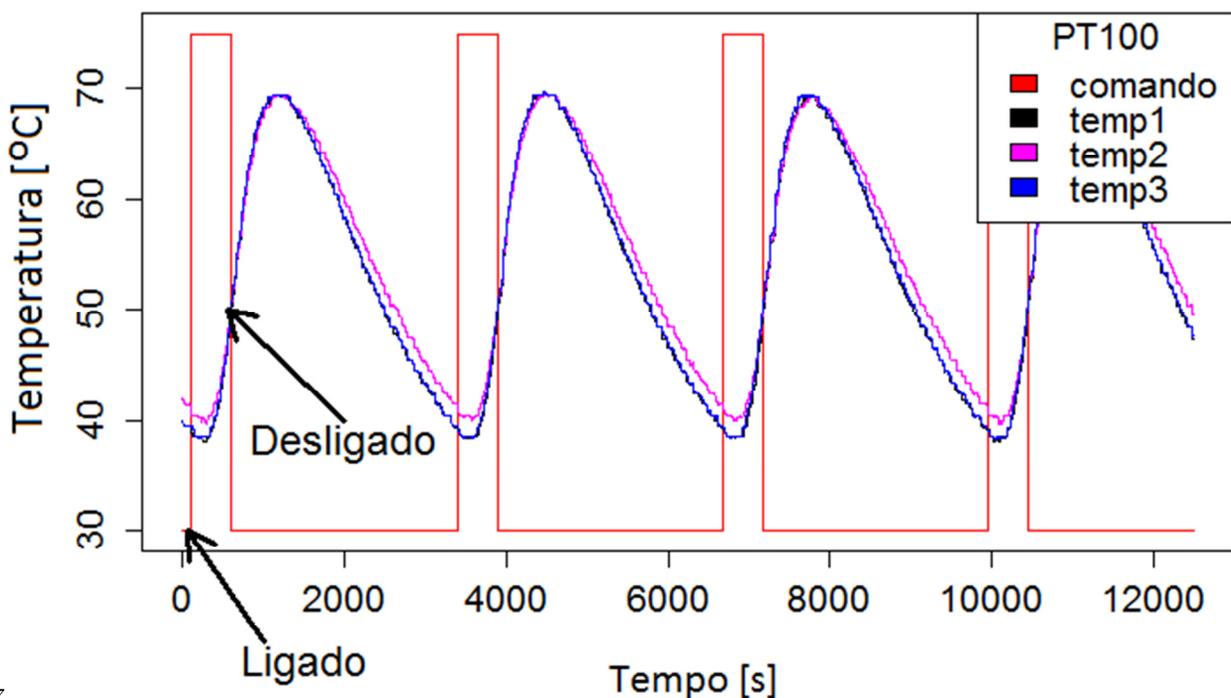
Figura 23- Curvas dos PT100 e incidência de fortes ruídos em cores. Na cor preta, a curva do sinal de saída do Voter sem influência do ruído mais forte.

5.2. Experimentos com reconhecimento de padrões

A aplicação das técnicas de reconhecimento de padrões foi realizada utilizando-se os dados históricos do banco de dados. O software de estatística R [66] foi empregado para realização dos experimentos, que consistiram nas seguintes etapas: extração de curvas, montagem do modelo Gaussiano multivariado, cálculo das distâncias e detecção de novidades.

5.2.1. Extração das curvas

O objetivo da extração das curvas é extrair aquelas do mesmo estado e agrupá-las, sendo uma das possibilidades usar a posição do acionamento do forno. Com esse princípio, seria possível determinar o início e o fim de uma curva crescente de aquecimento, respectivamente pela alternância das posições de ligado e desligado. Mas este método não é eficiente, pois existe uma inércia natural da variação de temperatura. Quando o forno é desligado, as resistências ainda estão quentes, provocando o aumento da temperatura por um determinado tempo. A figura 24 mostra o comportamento das curvas de temperatura, em azul e rosa. A curva na cor vermelha indica da posição do comando do forno, que é um sinal digital, ou seja, 0 ou 1. É possível observar que existe uma inércia de aquecimento após o desligamento do forno, que ocorre devido às altas temperaturas das resistências que operam na potência máxima em controle ligado/desligado.



^z Figura 24- Sinal digital de comando do forno e sinais analógicos dos sensores de temperatura

Para esse procedimento, foi necessário realizar a calibração do algoritmo de extração de curvas. Realizou-se a calibração para determinar os seguintes parâmetros: tamanho da janela e limiar do acumulador. A calibração é um procedimento necessário antes de iniciar a extração de curvas de um novo processo. Com esses parâmetros definidos, o algoritmo de extração de curvas trabalhou satisfatoriamente.

O comportamento da variação desses parâmetros pode ser visualizado na Figura 25. As curvas são mostradas em cores para dar um contraste e melhorar a visualização devido à maior quantidade de curvas. Em ambos os gráficos (A) e (B), foi empregado o tamanho da janela de 400 - determinado por tentativa. Observou-se, com a diminuição da janela, que houve uma diminuição na quantidade de curvas extraídas para esses sinais. O gráfico (A) possui duas curvas, indicadas pela seta, que se distanciam das demais; esse gráfico utiliza um limiar com valor 19. No gráfico (B), com o limiar de 28 não é possível visualizar as curvas que distanciam das demais. Elas possuem um elevado número de ruído que impede que o acumulador tenha valores absolutos altos, ou seja, com o aumento do limiar, as curvas ruidosas são eliminadas.

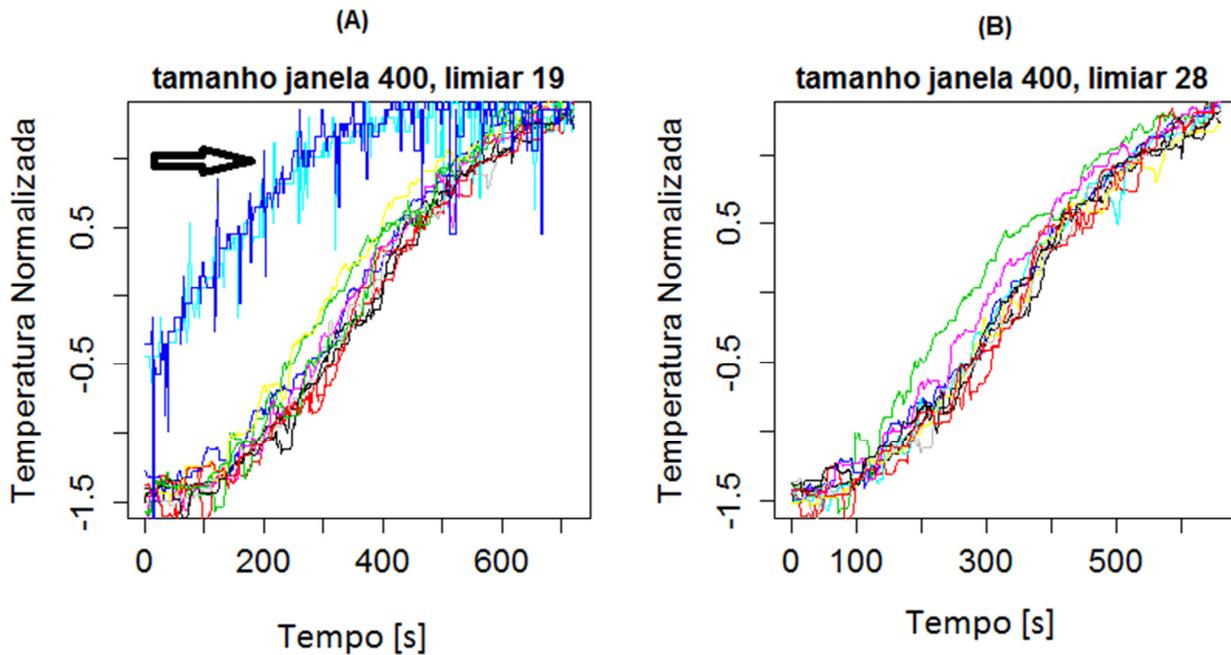


Figura 25- Efeito da alteração do tamanho da janela e limiar

O treinamento é realizado com grupo de curvas que não possuem novidades. A Figura 26 mostra o resultado da extração das curvas para treinamento, mostradas em cores variadas.

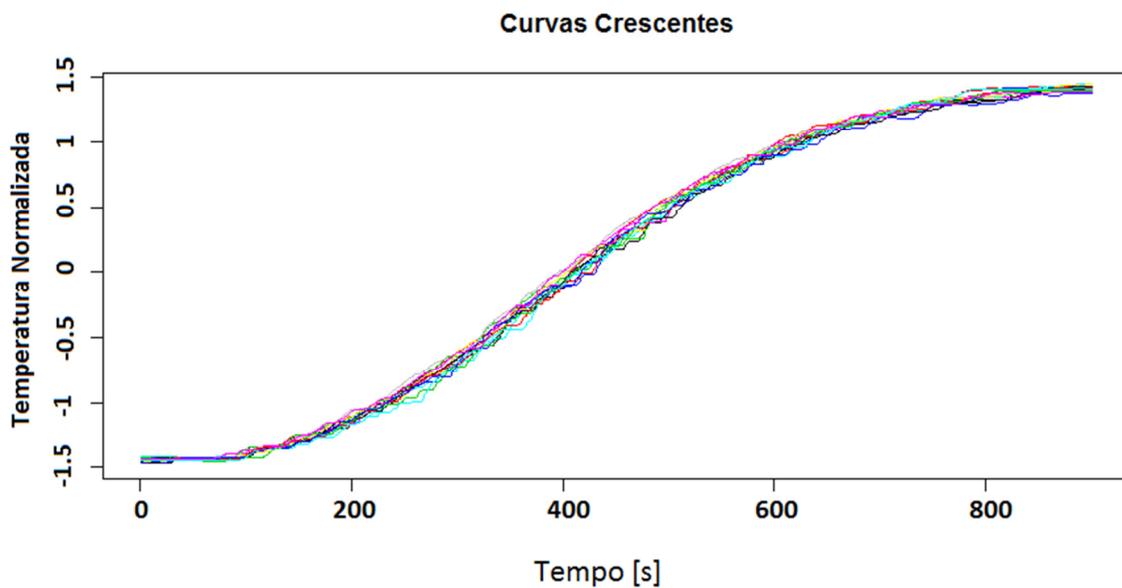


Figura 26- Gráfico com as curvas crescentes da operação de aquecimento

Outro grupo é criado com curvas sem novidades, formadas por sinais com menor nível de filtragem de ruídos no microcontrolador e que recebem tratamento por meio da média móvel no software supervisor. Esse grupo é denominado grupo de curvas mistas. A Figura 27 mostra o resultado da extração das curvas para treinamento do grupo de curvas mistas, mostradas em cores variadas.

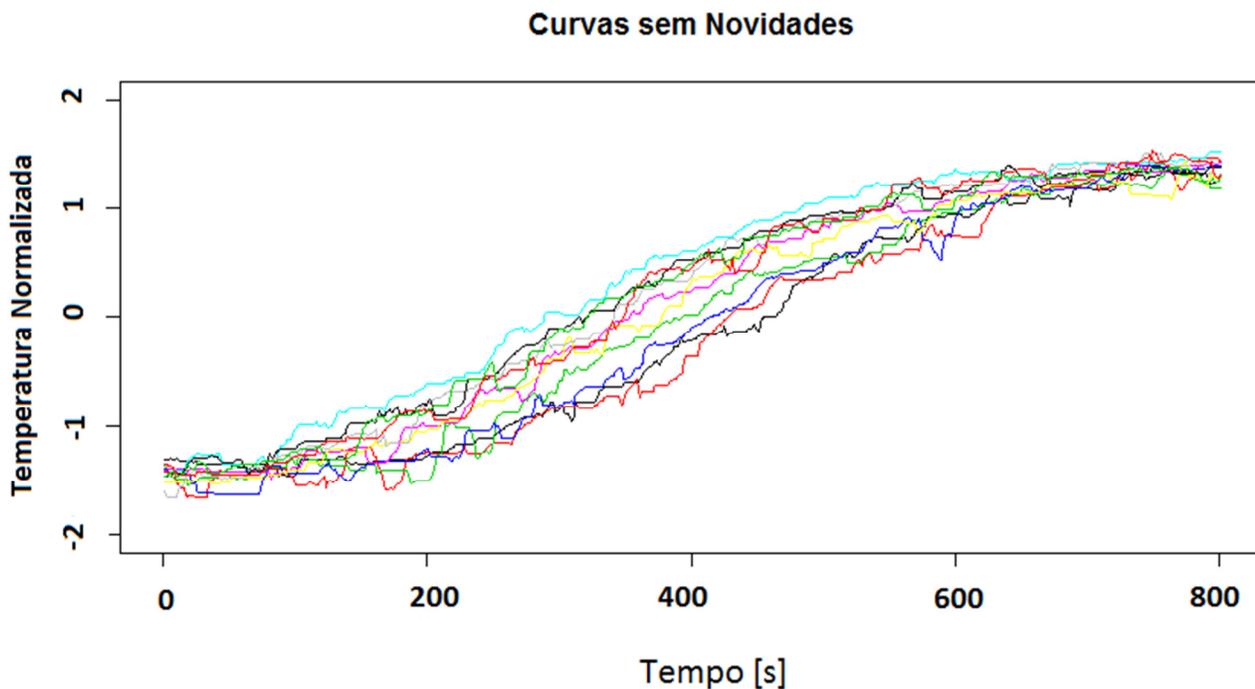


Figura 27 – Grupo de curvas mistas dos sinais sem filtro no microcontrolador e após a média móvel no software supervisor.

Na Figura 28 estão as curvas, em cores variadas, do grupo de sinais sem o filtro da média móvel. As curvas pertencentes a esse grupo são classificadas como curvas com novidades. Esse grupo será utilizado para verificação da capacidade do sistema em detectar novidades.

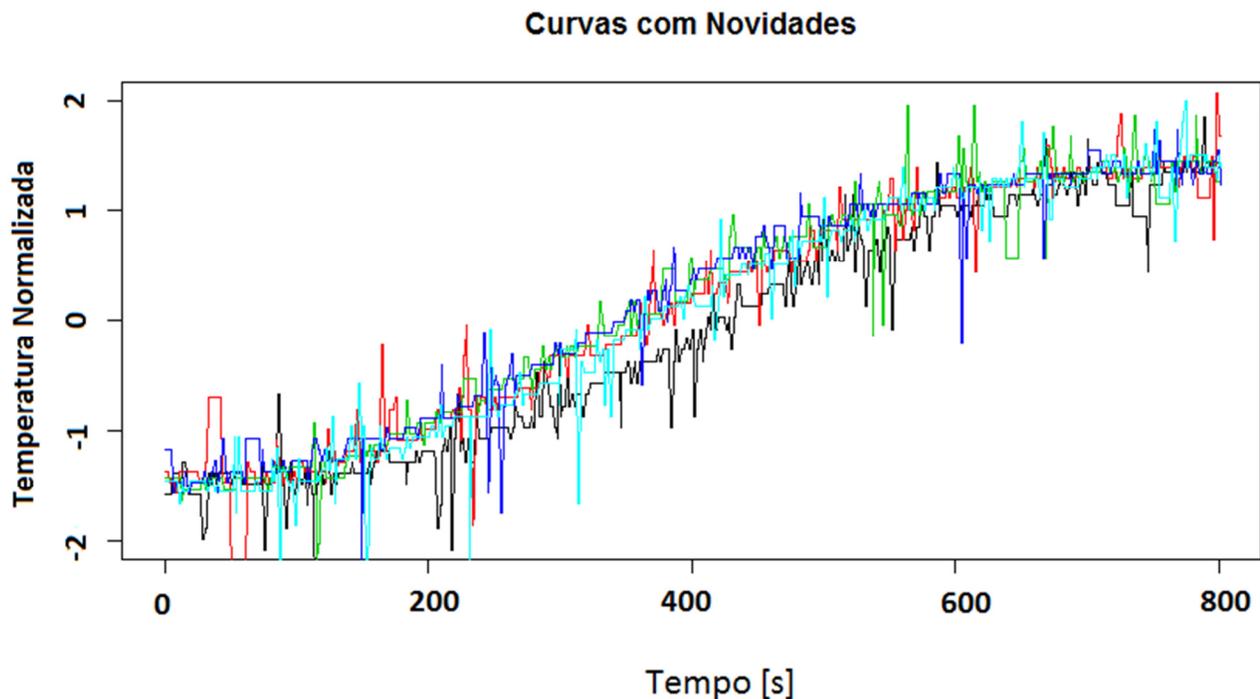


Figura 28- Curvas com grande variabilidade extraídas do grupo de curvas mistas, consideradas curvas com novidades.

5.2.2. Treinamento

Foram realizados dois treinamentos, um para o grupo de curvas de sinais sem ruídos (baixo ruído) e outro para o grupo de curvas de sinais com ruídos sem novidade. A verificação cruzada foi feita em todos os treinamentos. Esta consiste em realizar os testes de detecção de novidades nas curvas do grupo de curvas sem novidades, sendo que as curvas desse mesmo grupo são utilizadas para o treinamento. Com isso, pode-se validar se qualquer curva, sem novidade e de qualquer sensor, pode ser utilizada para detectar novidades de alguma curva dos três sinais redundantes.

5.2.3. Detecção de novidades

Fazendo a comparação entre as distâncias das curvas do grupo para verificação, em relação às curvas sem novidade de treinamento, foi possível detectar novidades. A Figura 29 apresenta a distribuição das distâncias das curvas. Os círculos representam as distâncias das curvas sem novidades, e os triângulos, as distâncias das curvas com novidades.

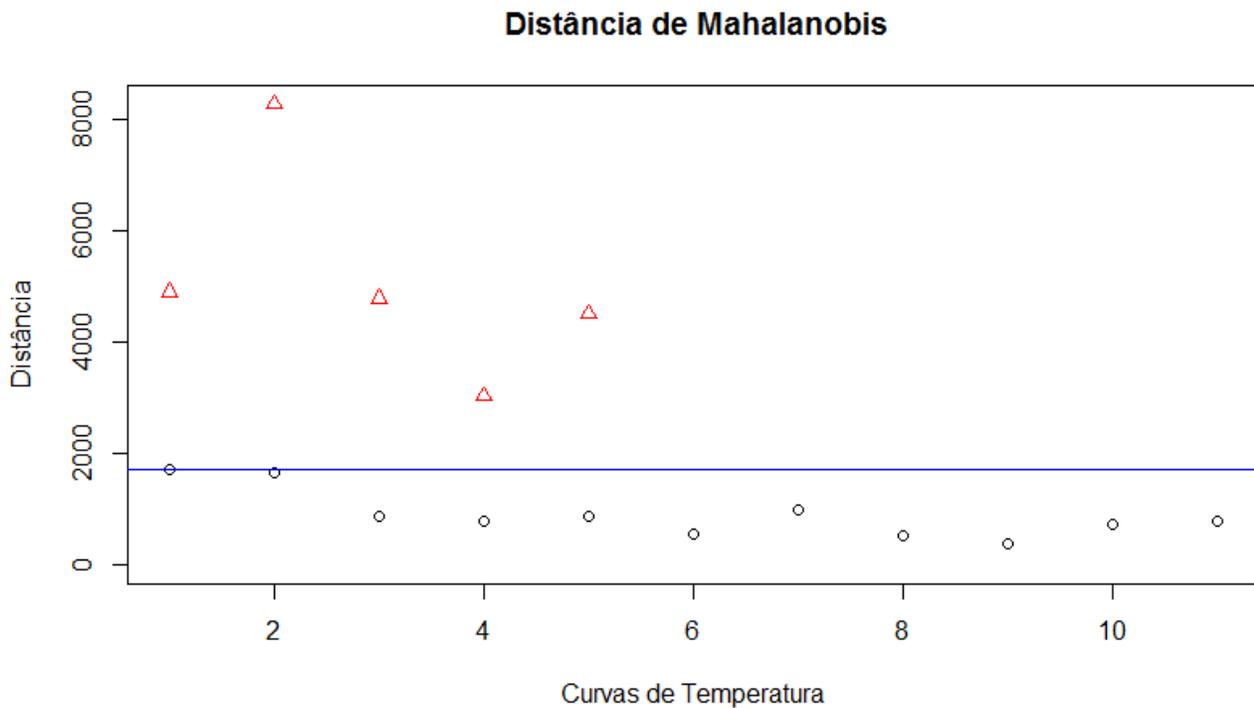


Figura 29- Demonstração gráfica da aplicação das distâncias de Mahalanobis como métrica para detecção de novidades.

6. RESULTADOS E DISCUSSÕES

Neste capítulo serão analisados os resultados dos experimentos e contempladas as discussões sobre os métodos e técnicas abordados.

6.1. Métodos de extração e tratamento de curvas

A análise do desempenho dos métodos de extração e tratamento de curvas é apresentada neste subcapítulo. As análises foram realizadas com as curvas crescentes não só para diminuir a complexidade, mas também pelo fato de o comportamento das curvas decrescentes ser muito similar ao das crescentes.

O método de extração de curvas, apresentado em 3.4.2, foi utilizado para extrair as curvas de estudo neste trabalho. Esse algoritmo foi robusto à presença de irregularidades, uma vez que realizou a extração de forma eficiente das curvas do banco de dados. Foram observadas irregularidades próximas aos tempos 0, 40000 e 70000 s, indicados pelas setas na Figura 30.

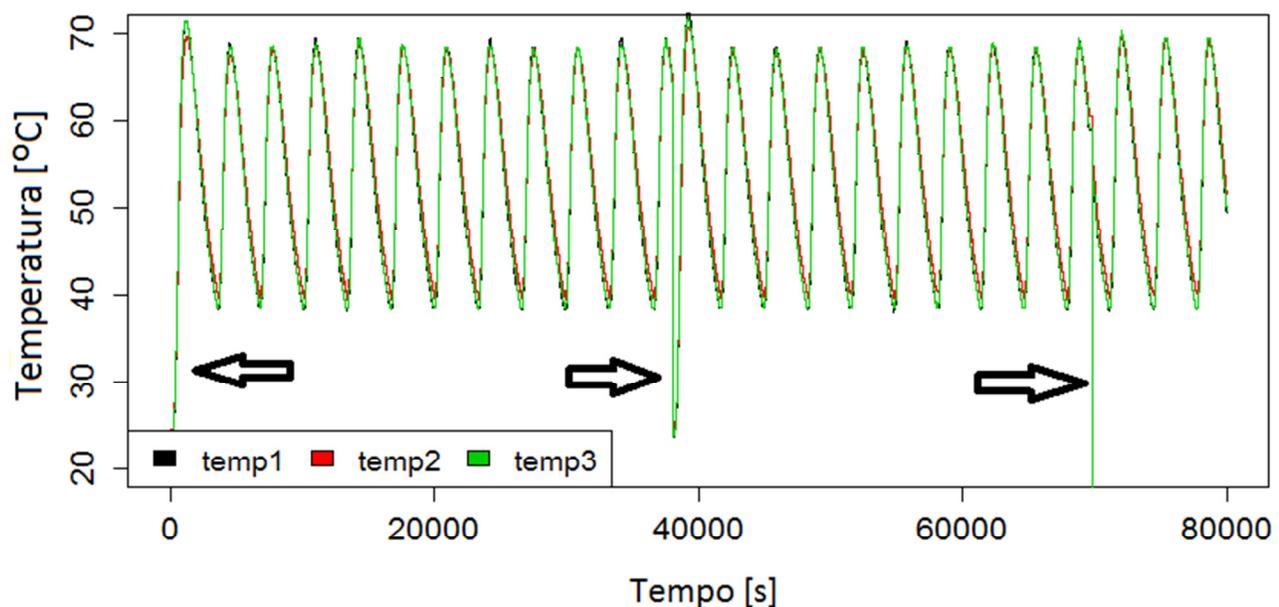


Figura 30- Curvas das temperaturas temp1, temp2 e temp3 do banco de dados.

A Figura 31 mostra o gráfico com resultado da extração das curvas da Figura 30. Foram extraídas 22, de um total 25. No gráfico, estão as curvas normalizadas, ou seja, as com média zero e desvio-padrão 1. As cores diferentes são para melhorar a visualização das diferentes curvas. As curvas indicadas pelas setas (A), (B) e (C), na Figura 31, apresentam afastamento, devido aos picos, em relação às demais. Os picos que geraram esse afastamento podem ser visualizados, indicados pelas setas, no gráfico da Figura 30.

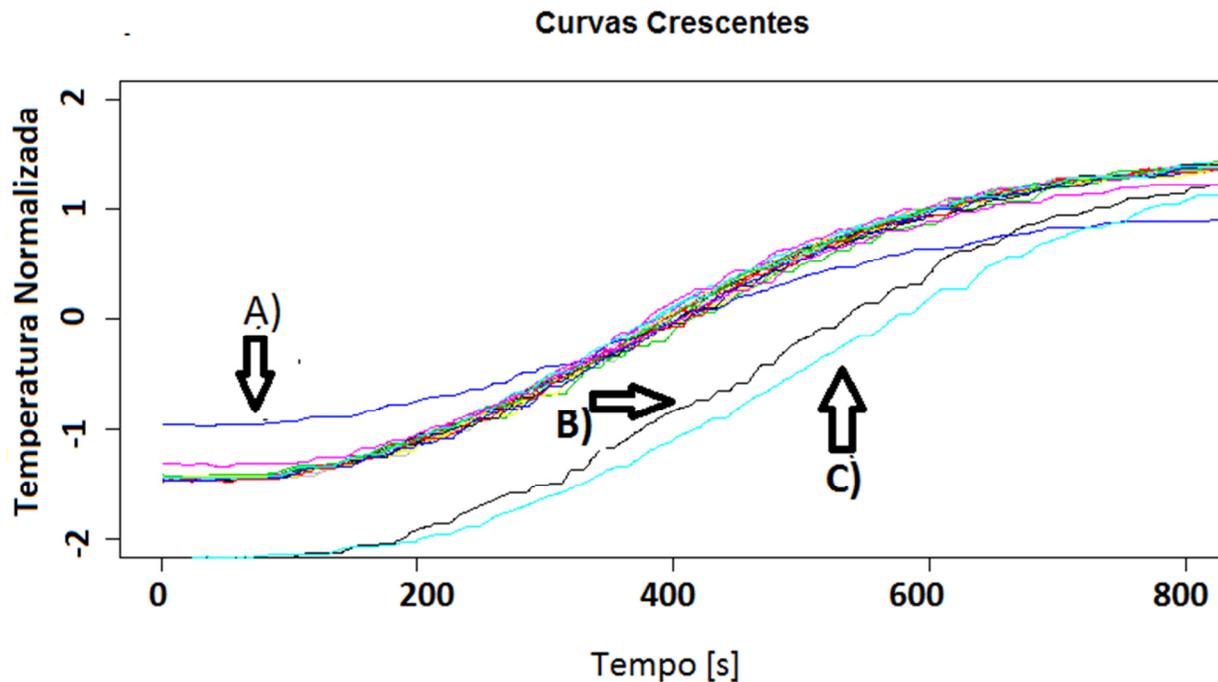


Figura 31- Curvas normalizadas.

A normalização permitiu agrupar curvas de mesmo padrão com escalas diferentes, (A) e (B) da Figura 32. As curvas do gráfico (A) têm valores mínimos de 40 °C e máximos de 60 °C, ou seja, uma variação de 60 °C. As curvas do gráfico (B) possuem valores mínimos de 40 °C e máximos próximos de 70 °C, apresentando uma variação de 30 °C. Apesar das amplitudes serem diferentes, as curvas mantêm o mesmo padrão, que, com a utilização da normalização, possibilitou o uso das curvas em conjunto nos experimentos.

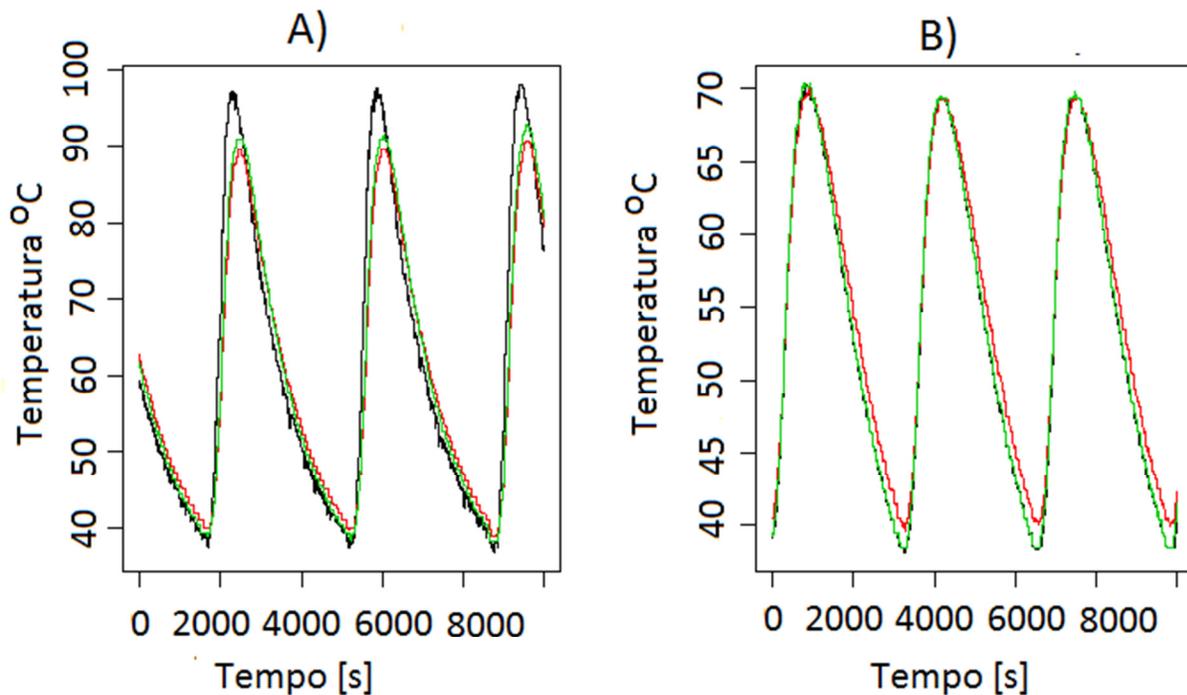


Figura 32- Curvas com amplitudes diferentes (A) curvas de 40 °C a 100 °C e em (B) curvas de 40 °C a 70 °C.

6.2. Média dos três sinais x média da menor diferença

Em todos os experimentos, foi medida a temperatura com o sensor LM35, com o intuito de ter um valor de referência, ou seja, um valor correto. Entretanto, foi observado que o tempo de resposta da variação da temperatura do sensor LM35 é maior que o dos sensores PT100. Uma das hipóteses seria o reduzido tamanho da superfície do sensor, se comparado ao tamanho da superfície do PT100. Como a curva da temperatura do LM35 apresentou um deslocamento em relação às curvas do PT100, desistiu-se da ideia de usar uma temperatura de referência do LM35.

Apesar da desvantagem de não possuir uma temperatura de referência, para as comparações de eficiência dos métodos aplicados ao Voter, houve a vantagem do desenvolvimento de uma análise diferencial entre os sinais. Com essa abordagem, não é possível mensurar a diferença com o valor correto; entretanto, é possível detectar as diferenças relativas entre os valores medidos pelos três sensores. Esse método tem se tornado viável dentro do contexto deste estudo, pois o sistema de detecção de novidades vai

sinalizar a ocorrência de falhas simultâneas em dois ou nos três sinais de entrada, não validando, portanto, o sinal de saída.

Para facilitar a descrição das análises, o método da média dos três sinais será denominado “**média**”, e o método da média da menor diferença, denominado “**voto**”.

Os melhores resultados são das curvas de saída do Voter, que estão mais distantes da curva de entrada mais ruidosa. Assim, pelas análises seguintes, quanto maior a distância da curva de saída, em relação à curva ruidosa, melhor o desempenho do método.

Objetivou-se analisar os sinais de saída pelos métodos da **média** e do **voto**. Com a análise, desejou-se verificar qual dos métodos é mais robusto à entrada de ruído. A análise utiliza as três curvas de entrada dos sinais do PT100 e as duas curvas de saída geradas pelos dois métodos. A técnica consiste em determinar a proximidade das curvas de saídas em relação às curvas de entrada. Foi utilizada a distância dos pontos entre as curvas, considerando-se a distância em uma dimensão, pois a distância foi medida em y na vertical, para cada posição de x na horizontal. O desvio-padrão e a média das distâncias entre os pontos das curvas foram aplicados como métrica para determinar a proximidade, quer dizer, quanto menores a média e o desvio-padrão, maior a proximidade com a curva de referência da entrada.

Levando-se em consideração o conhecimento anterior sobre as curvas, pôde-se verificar qual das curvas de saída era mais próxima da curva ruidosa. A Figura 33 mostra as curvas dos PT100, sendo *temp1* na cor preta, *temp2* na cor vermelha e *temp3* na cor verde. O sinal ruidoso pode ser identificado visualmente, no primeiro ciclo de aquecimento (*A*); o sinal *temp2* apresenta maior ruído. No segundo ciclo (*B*), não é possível perceber um sinal com maior ruído. No terceiro (*C*) e quarto ciclos (*D*), ocorreram ruídos respectivamente para os sinais de *temp1* e *temp2*. No quinto ciclo (*E*), também não foi possível, visualmente, perceber o sinal com maior ruído. A mesma abordagem pode ser aplicada aos demais ciclos, os quais correspondem às bateladas que estão indicadas entre as retas verticais tracejadas na Figura 33.

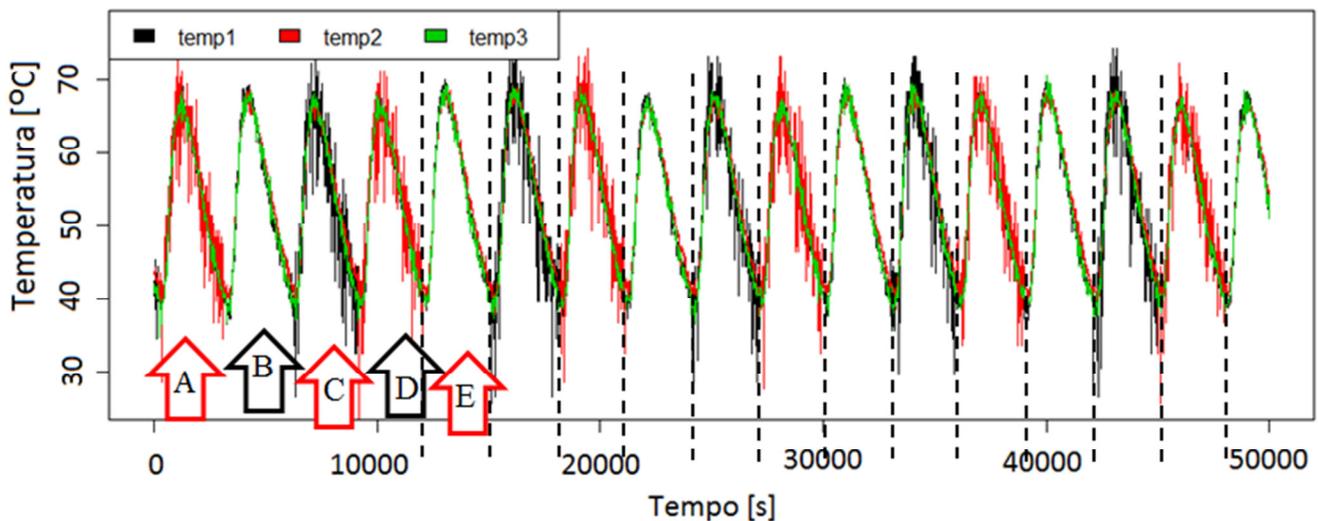


Figura 33- Curvas das temperaturas dos 3 sensores; as setas (A), (C) e D indicam ciclo no qual existem curvas com maior ruído; a seta (B) indica o segundo ciclo sem ruído. Entre as retas tracejadas, estão os demais ciclos ou bateladas.

A análise dos resíduos foi utilizada para detectar o sinal de maior ruído, conforme trabalho realizado por Martins [67]. Resíduo W (eq. 19) é a diferença da distância do valor da amostra x_i em relação ao valor mais provável, a média \bar{x} (eq. 20), em que n é o número de elementos na amostra [67]. Os resíduos foram calculados em relação à curva média dos três sinais, devido à inexistência de um valor de referência.

$$W = x_i - \bar{x} \quad (18)$$

$$\bar{x} = \frac{\sum_{i=1}^{i=n} x_i}{n} \quad (19)$$

A soma dos quadrados dos resíduos é utilizada para detecção de falhas no trabalho de Simon [65]. A sigla *SSR* é um acrônimo do inglês *sum-of-squared residuals* (eq. 21).

$$SSR = \sum_{i=0}^{i=n-1} [x_i - \bar{x}]^2 \quad (20)$$

A abordagem utilizada consiste na comparação das médias (avg) e dos desvios-padrão (sd) dos resíduos dos sinais de entrada, pois, quanto maiores a média e o desvio-

padrão, maior o ruído. Os valores das médias (avg) e desvios-padrão (sd) dos resíduos das curvas são mostrados na Tabela 4. A primeira coluna indica o ciclo, as demais indicam as médias e os desvios-padrão, sendo a curva 1 indicada por T1, a curva 2, por T2, e a curva 3, por T3.

Tabela 4- Determinação de sinal ruidoso através dos valores das médias (avg) e desvios-padrão (sd) dos resíduos da curva 1 (T1), curva 2 (T2) e da curva 3 (T3). Em negrito, os maiores valores de média e desvio- padrão. Ciclo 3 com comportamento diferente, em vermelho itálico

Ciclo	T1		T2		T3	
	avg	sd	avg	sd	avg	sd
1	0,77	1,34	1,96	4,64	0,62	1,50
2	0,62	0,93	0,99	1,12	0,46	0,76
3	<i>2,47</i>	<i>7,80</i>	<i>1,78</i>	<i>3,78</i>	<i>0,93</i>	<i>1,98</i>
4	0,83	1,77	2,06	5,11	0,60	1,23
5	0,44	0,48	0,95	1,01	0,46	0,78

O ciclo 3 possui os maiores valores de média e desvio-padrão para T1. No entanto, é possível visualizar valores elevados de *avg* e *sd* para T2, apesar de serem menores que o valor de T1. Esse fenômeno pode ser explicado devido ao fato dos resíduos serem calculados pela média dos três sinais, T1, T2 e T3, que, nesse ciclo, tiveram um comportamento atípico da curva T2. A curva T2, em (A) e (B) no gráfico da Figura 34, tem um leve distanciamento das curvas T1 e T3, o que faz a média ficar um pouco mais distante de T2. Isso justifica o comportamento dos valores de *avg* e *sd*.

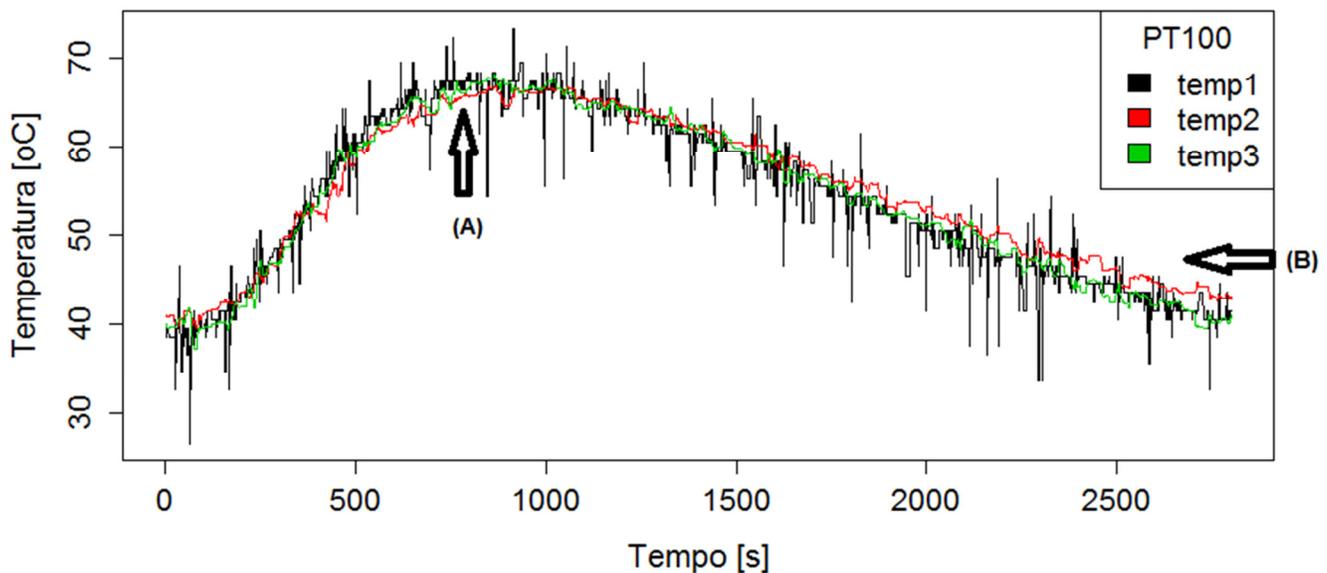


Figura 34- Curva do ciclo com afastamento da curva T2 (temp2) em (A) e (B) em relação às curvas T1(temp1) e T3(temp3).

A distância do sinal de saída do Voter, em relação aos sinais de entrada, foi empregada como parâmetro de verificação de robustez do método. Dessa forma, calcula-se a distância média (avg) e os desvios-padrão (sd) do sinal de saída do Voter, considerando cada método, em relação aos sinais de entrada. O método será mais robusto, quanto maior for a distância do sinal de saída do Voter em relação ao sinal que possui maior ruído. Dessa forma, quanto maior a distância média, mais afastado é o sinal de saída do sinal ruidoso. Foi possível identificar qual sinal foi mais ruidoso, pois foi programada a passagem dos sinais pelo filtro de média móvel, ou seja, o sinal mais ruidoso foi o que não passou pela média móvel. Além disso, este pode ser comprovado pelos cálculos utilizados anteriormente, na elaboração da Tabela 4. Conseqüentemente, as distâncias do sinal de saída em relação aos sinais não ruidosos devem ser menores. Assim, quanto menor a distância, maior a proximidade desses sinais.

As distâncias da curva de saída do método **voto**, em relação às curvas de entradas, são indicadas por *V-T1*, *V-T2* e *V-T3*, que são respectivamente comparações com as temperaturas dos sensores 1 a 3. As distâncias das curvas de saída do método **média**, em relação às curvas de entradas, são indicadas por *M-T1*, *M-T2* e *M-T3*, que são respectivamente comparações com as temperaturas dos sensores 1 a 3 e que podem ser

visualizadas nas Tabelas 5 e 6. Os maiores valores por ciclo de aquecimento são destacados em negrito.

A Tabela 5 mostra a comparação dos métodos para os sinais de entrada considerados sem ruídos, ou seja, sinais que passaram por um filtro de média móvel. Nos ciclos 2, 5, 8, 11, 13, 14 e 16, destacados em itálico vermelho, as diferenças entre as médias e desvios-padrão para os dois métodos foram menores quando comparadas aos demais ciclos, mostrados na Tabela 6. Essa menor diferença mostra que as curvas de saída dos dois métodos são próximas - situação justificada pela ausência de sinal com nível elevado de ruído nesses ciclos.

Tabela 5-Resultado dos desvios-padrão (sd) e das médias das distâncias (avg) das curvas dos métodos do voto em relação às n temperaturas de entrada (V-Tn) e do método da média(M-Tn) em relação às n curvas de entrada das temperaturas. Em itálico vermelho, os maiores valores sem ruído.

Ciclo	V-T1		V-T2		V-T3		M-T1		M-T2		M-T3	
	avg	sd	avg	sd	avg	sd	avg	sd	avg	sd	avg	sd
2	0,58	0,64	0,89	0,93	0,43	0,53	0,70	0,46	0,73	0,58	0,50	0,36
5	0,58	0,54	0,66	0,83	0,41	0,52	0,61	0,36	0,64	0,53	0,40	0,42
8	0,89	0,80	0,64	0,64	0,59	0,92	0,84	0,53	0,72	0,41	0,58	0,61
11	0,56	0,75	1,01	0,75	0,39	0,54	0,64	0,48	0,84	0,49	0,46	0,46
13	0,46	0,53	0,95	1,23	0,45	0,61	0,54	0,45	0,81	0,78	0,58	0,52
14	0,64	0,87	0,87	0,64	0,41	0,56	0,70	0,52	0,76	0,37	0,47	0,49
16	0,60	0,67	0,95	1,35	0,32	0,35	0,67	0,57	0,81	0,84	0,47	0,45

Na Tabela 6, está a comparação dos métodos para os sinais de entrada em que um sinal é considerado com ruídos, quer dizer, sinal que não passou por um filtro de média móvel. O ciclo 1 tem os maiores valores de média e desvio-padrão para V-T2, que indica uma maior distância da curva do método **voto** em relação à temperatura do sensor 2. O sinal de temperatura do sensor 2 é o do sinal mais ruidoso.

Tabela 6- Resultado dos desvios-padrão (sd) e das médias das distâncias (avg) das curvas dos métodos do voto em relação às n temperaturas de entrada (V-Tn) e do método da média(M-Tn) em relação às n curvas de entrada das temperaturas. Em negrito, os maiores valores quando há ruído. A coluna T ruído indica qual sensor de temperatura possui maior ruído.

Ciclo	T	V-T1		V-T2		V-T3		M-T1		M-T2		M-T3	
	ruído	avg	sd	avg	sd	avg	sd	avg	sd	avg	sd	avg	sd
1	2	0,42	0,42	1,32	1,52	0,39	0,61	0,57	0,47	1,00	0,97	0,64	0,64
3	1	1,27	1,68	0,80	0,96	0,52	0,60	1,07	1,07	0,96	0,74	0,66	0,58
4	2	0,50	0,62	1,33	1,81	0,40	0,49	0,69	0,73	1,03	1,15	0,63	0,58
6	1	1,39	2,12	0,69	0,86	0,48	0,49	1,17	1,35	0,85	0,76	0,67	0,73
7	2	0,49	0,64	1,29	1,53	0,41	0,58	0,70	0,59	1,01	0,97	0,57	0,60
9	1	1,35	1,66	0,87	0,82	0,50	0,53	1,09	1,04	0,95	0,58	0,73	0,61
10	2	0,38	0,43	1,23	1,69	0,37	0,56	0,62	0,64	0,93	1,09	0,57	0,58
12	1	1,33	1,56	0,62	0,70	0,48	0,61	1,09	0,95	0,80	0,57	0,66	0,61
15	1	1,20	1,72	0,84	0,84	0,64	0,78	1,08	1,07	0,92	0,66	0,76	0,71

Uma forma de melhorar a análise das distâncias é definir uma relação entre as médias de ambos os métodos, para os mesmos sensores de temperatura. Em cada ciclo, utilizou-se o sensor com ruído, que possui o valor em negrito, para cada método, que representa a maior distância média, conforme a Tabela 7.

A Tabela 7 apresenta, na primeira coluna, o ciclo; na segunda, o sensor; na terceira, a distância média para o método do **voto**; na quarta, a distância média para o método da **média**; e, na quinta coluna, a relação entre as distâncias médias. Na sexta e sétima colunas estão respectivamente os desvios-padrão dos métodos do **voto** e da **média**, e, na última coluna, a relação entre eles. As relações são entre o método do **voto** e o método da **média**.

Tabela 7- Relação entre as médias e desvios-padrão das distâncias dos métodos. Valores maiores indicam o quanto os sinais de saída do método do voto estão mais distantes que os sinais do método da média. Quanto maior a porcentagem, maior a robustez do método do voto em relação ao método da média.

ciclo	Sensor	avg Voto	avg Média	voto/média	sd Voto	sd Média	voto/média
1	T2	1,32	1	32%	1,52	0,97	57%
3	T1	1,27	1,07	19%	1,68	1,07	57%
4	T2	1,33	1,03	29%	1,81	1,15	57%
6	T1	1,39	1,17	19%	2,12	1,35	57%
7	T2	1,29	1,01	28%	1,53	0,97	58%
9	T1	0,95	0,81	17%	1,66	1,04	60%
10	T2	1,23	0,93	32%	1,69	1,09	55%
12	T1	1,33	1,09	22%	1,56	0,95	64%
15	T1	1,2	1,08	11%	1,72	1,07	61%
Média				23%	58%		

A última linha da Tabela 7 mostra que o método do **voto** possui uma distância 23% maior que o método da **média**, relativo ao sinal de maior ruído do sensor. Além disso, pode-se verificar que o desvio-padrão do método do **voto** é 58% maior que o método da **média**, que expressa uma oposição às variabilidades do sinal ruidoso.

O método proposto não exclui um sinal que em determinado momento esteja fora da faixa, desde que ele retorne à normalidade. As curvas das distâncias foram plotadas juntamente com a curva da temperatura de maior ruído e com as curvas de saídas dos métodos, conforme mostrado nas Figuras 35(A) e 36(A). Observe no ciclo 1, na Figura 35, que as curvas dos dois métodos estão mais afastadas - a curva da média dos três, em azul, e a curva da média da menor diferença denominada votado, em marrom, no gráfico (A). No gráfico (B), é possível verificar as curvas dos três sinais de entrada, em que a da temperatura 2 é a curva com sinal de maior ruído. Na parte inferior dos gráficos (A) e (B) estão as curvas com as distâncias dos dois métodos. A curva do método votado possui uma maior distância do sinal ruidoso, de acordo com a Figura 35.

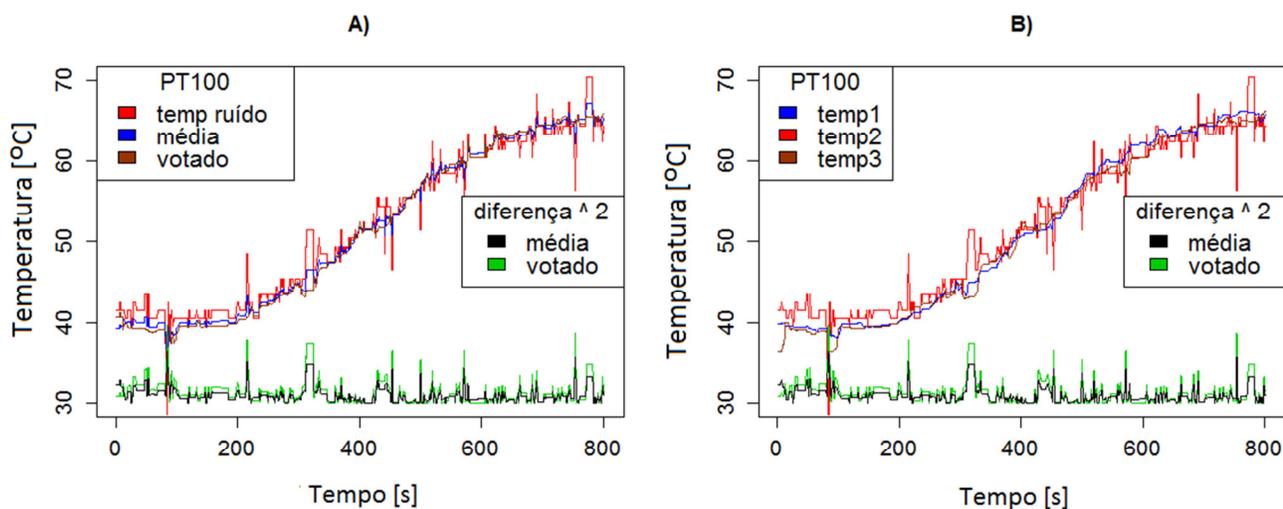


Figura 35- Gráfico (A) do ciclo 1 com entrada do sinal ruidoso e saídas dos dois métodos. Em (B) os três sinais de entrada; em ambos os gráficos, na parte inferior, a distância euclidiana do sinal de saída do Voter em relação ao sinal mais ruidoso.

É possível observar, no gráfico (A) da Figura 36, que no ciclo 2 as curvas dos sinais de saída dos dois métodos são muito próximas, com uma distância média de 0,16 - a curva da **média**, em azul, e a curva do **voto**, em marrom. No gráfico (B), observam-se as curvas dos três sinais de entrada, em que a curva da temperatura do sensor 2 é um pouco mais distante das demais. Em ambos os gráficos (A) e (B), na parte inferior são mostradas as curvas com as distâncias dos dois métodos. Nesse ciclo, as curvas são mais próximas, como apresentado na Figura 36.

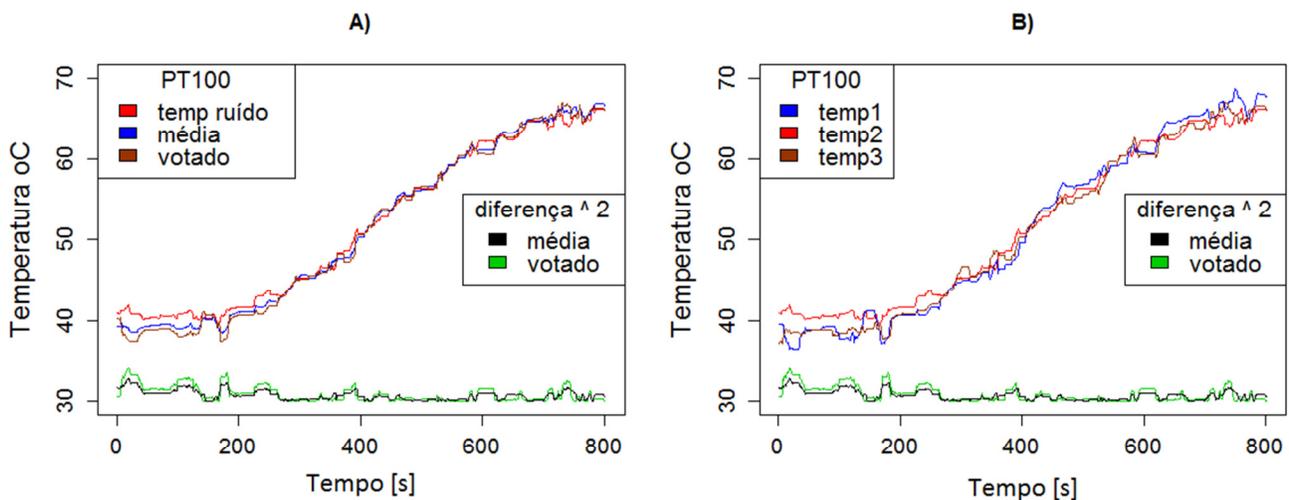


Figura 36- Gráfico (A) do ciclo 2 com entrada do sinal ruidoso e saídas dos dois métodos. Em (B), os três sinais de entrada; em ambos os gráficos, na parte inferior, a distância euclidiana do sinal de saída do Voter em relação ao sinal mais ruidoso.

A Figura 37 mostra o gráfico boxplot das distâncias da curva de saída dos métodos de seleção em relação às curvas de entradas dos sinais dos sensores de temperatura. As médias (avg) e desvios-padrões (sd) dessas distâncias podem ser visualizados na Tabela 8.

Tabela 8- Média (avg) e desvios-padrão (sd) das distâncias da curva de saída dos métodos de seleção em relação às curvas dos sinais de entradas dos sensores de temperatura.

ciclo	Sinal de entrada	Método média		Método voto	
		avg	sd	avg	sd
1	Temp1	0,57	0,47	0,42	0,42
1	Temp2	1,00	0,97	1,32	1,52
1	Temp3	0,64	0,64	0,39	0,61
2	Temp1	0,70	0,46	0,58	0,64
2	Temp2	0,73	0,58	0,89	0,93
2	Temp3	0,50	0,36	0,43	0,53

Os boxplot (A), (B) e (C) são do ciclo 1, e os boxplot (D), (E) e (F) são do ciclo 2. O boxplot (B) mostra maior média e maior variabilidade para o método **voto**, o que indica uma maior distância do sinal de temperatura 2. Esta possui o sinal com maior ruído do ciclo 1. No boxplot (B), o método **média**, ou seja, média dos três, apresenta maior proximidade com o sinal da temperatura 2, conforme a Figura 37.

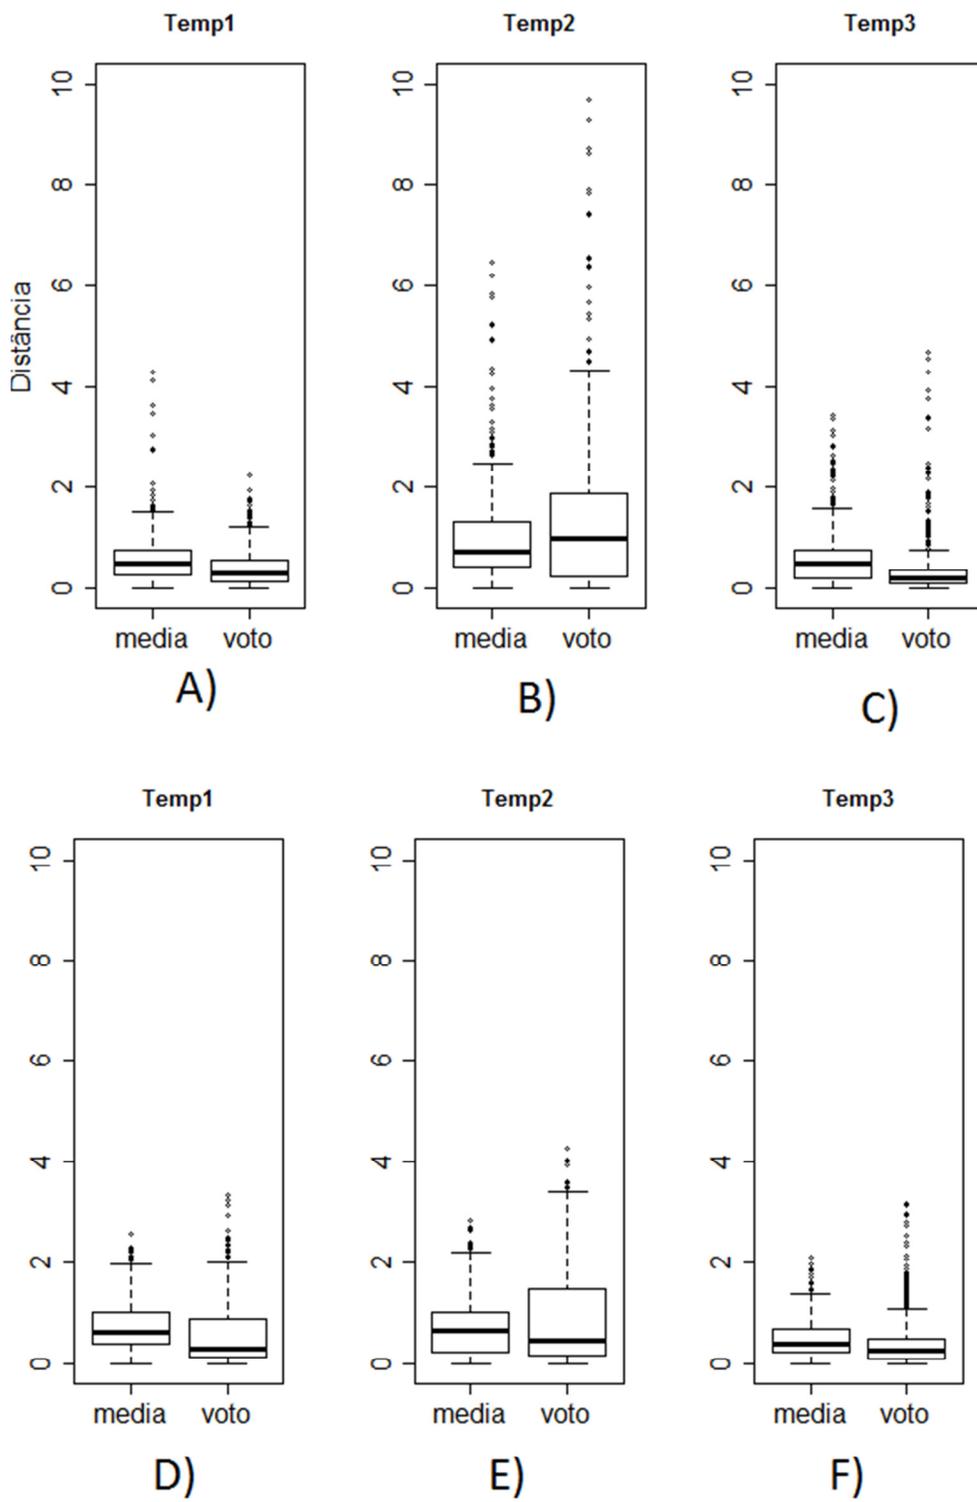


Figura 37- Boxplot com as distâncias das curvas dos ciclos 1 e ciclos 2

6.1. Experimentos com reconhecimento de padrões

Neste subcapítulo são descritos os experimentos realizados com o uso da inteligência artificial para verificação da alteração do comportamento dos sinais, por meio do reconhecimento de padrões e detecção de novidades. O subcapítulo é dividido em: determinação da quantidade de curvas para treinamento e testes da metodologia proposta.

6.1.1. Quantidade de curvas para treinamento

Foram geradas, no período do experimento, 183 curvas que foram consideradas sem anomalias e que podiam ser utilizadas para o treinamento do sistema de detecção de novidades.

Como ferramenta para determinar a quantidade mínima de curvas para treinamento, fez-se uso da matriz de confusão [65], que é muito aplicada para avaliação de modelos com classes desbalanceadas, o que se aplica ao modelo deste estudo. O desbalanceamento é devido à disponibilidade de 24 curvas com novidades e 183 curvas sem novidades, geradas durante os experimentos.

A matriz de confusão é empregada para mostrar a avaliação estatística de modelos de classificadores por tabulação cruzada, utilizando a classificação do modelo e a classificação real dos exemplos. Quando um exemplo positivo é classificado como positivo, é denominado verdadeiro positivo T_P (*true positive*); quando um exemplo negativo é classificado como positivo, é denominado falso positivo F_P (*false positive*). No sentido inverso, temos falso negativo F_N (*false negative*) e verdadeiro negativo T_N (*true negative*) [68], como na Tabela 9.

Tabela 9- Estrutura da matriz de confusão

	Classe	Classificação do modelo	
		Com Novidades	Sem Novidades
Classificação real	Com Novidades	T_P	F_N
	Sem Novidades	F_P	T_N

O parâmetro a ser considerado com o uso da matriz de confusão é a taxa de erro total T_{et} , no qual n é o somatório de T_P , F_P , T_n e F_n (eq. 21).

$$T_{et} = \frac{FP + FN}{n} \quad (21)$$

Foram realizados 6 experimentos, cada um com 31 replicações. Um experimento para 3, 10, 20, 30, 40 e 60 curvas de treinamento, sendo que, para cada replicação, foram selecionadas curvas de forma aleatória, do universo de 183 curvas disponíveis para treinamento. Em cada replicação, foram testadas 6 curvas escolhidas de forma aleatória, sendo 3 do grupo de curvas com novidades e 3 do grupo de curvas sem novidades. Selecionaram-se exemplos com três curvas de cada grupo, com o objetivo de aproximação da situação real, em que existem três sinais redundantes.

Os exemplos com novidades foram escolhidos, de forma aleatória, de um grupo de 24 curvas classificadas com novidades. Os exemplos sem novidades foram escolhidos, aleatoriamente, do grupo de 183 curvas sem novidades. Dessa forma, foram 31 replicações, cada uma avaliando 6 curvas, perfazendo um total de 186, ou seja, n igual a 186. Para cada experimento, gerou-se uma matriz de confusão e foi calculado o erro total T_{et} .

As matrizes de confusão dos experimentos 1 a 6 são mostradas respectivamente nas Tabelas 10 a 15.

Tabela 10- Matriz de confusão para o treinamento com 3 curvas, experimento 1.

Classe	Com Novidades	Sem Novidades
Com Novidades	58	35
Sem Novidades	2	91

Tabela 11- Matriz de confusão para o treinamento com 10 curvas, experimento 2.

Classe	Com	Sem
--------	-----	-----

	Novidades	Novidades
Com Novidades	69	24
Sem Novidades	6	87

Tabela 12- Matriz de confusão para o treinamento com 20 curvas, experimento 3.

Classe	Com Novidades	Sem Novidades
Com Novidades	79	14
Sem Novidades	7	86

Tabela 13- Matriz de confusão para o treinamento com 30 curvas, experimento 4.

Classe	Com Novidades	Sem Novidades
Com Novidades	93	0
Sem Novidades	8	85

Tabela 14- Matriz de confusão para o treinamento com 40 curvas, experimento 5.

Classe	Com Novidades	Sem Novidades
Com Novidades	93	0
Sem Novidades	6	87

Tabela 15- Matriz de confusão para o treinamento com 60 curvas, experimento 6.

Classe	Com Novidades	Sem Novidades
Com Novidades	93	0

A taxa de erro total T_{et} , para cada grupo de curvas para treinamento, está presente na Tabela 16, que demonstra que, com o aumento da quantidade de curvas para treinamento, o erro total diminui. Uma observação importante: acima de 30 curvas de treinamento, a variação do erro não é grande; além disso, os erros estão abaixo de 5%.

Tabela 16- Mostra a taxa de erro total T_{et} para as quantidades de curvas de treinamento.

Curvas de Treinamento	T_{et}
3	0,2258
10	0,1613
20	0,1129
30	0,0430
40	0.0322
60	0.0268

Os experimentos com as matrizes de confusão mostraram que, quanto maior o número de curvas para treinamento, mais robusto se torna o sistema de detecção de novidades. Além disso, 30 seriam uma quantidade mínima de curvas para treinamento, para um erro total abaixo de 5%.

6.1.2. Verificação do método

Foram feitos vários experimentos para verificação do sistema de detecção de novidades, por meio da validação cruzada. Esta é uma técnica estatística utilizada para determinar a capacidade de generalização de um método e é muito aplicada em redes neurais. Tipicamente, na validação cruzada, a amostra é dividida aleatoriamente em dois

subconjuntos: um de treinamento e outro de teste (validação). Para a validação cruzada, foram usadas 60 curvas para treinamento e 60 para teste (validação), o que atende ao levantamento mínimo de curvas realizado com as matrizes de confusão.

As operações de aquecimento que geraram essas curvas são classificadas em operações sem falhas ou perturbações. As curvas de treinamento são agrupamentos formados pelas curvas dos três sinais de entrada. Isso fortalece o conceito de redundância, uma vez que cada sinal deve ser uma cópia do outro. Essa foi uma das justificativas de não se realizar a detecção de novidades para cada sinal, ou seja, que o sinal de temperatura 1 tivesse seu grupo de detecção diferente dos sinais de temperaturas 2 e 3.

O primeiro experimento procurou verificar se a capacidade em detectar novidades foi comprometida após a união das curvas de todos os sinais. Seleccionadas as 183 curvas (A), a estratégia adotada consistiu em utilizar 60 curvas para o treinamento (B) e realizar uma validação cruzada com outras 60 (C). Essas curvas foram escolhidas de forma aleatória. Após o treinamento e a validação, foi apresentado um grupo com cinco curvas para detecção de novidades (D), como na Figura 38. Fez-se uso de somente cinco curvas, para facilitar a compreensão da detecção de novidades.

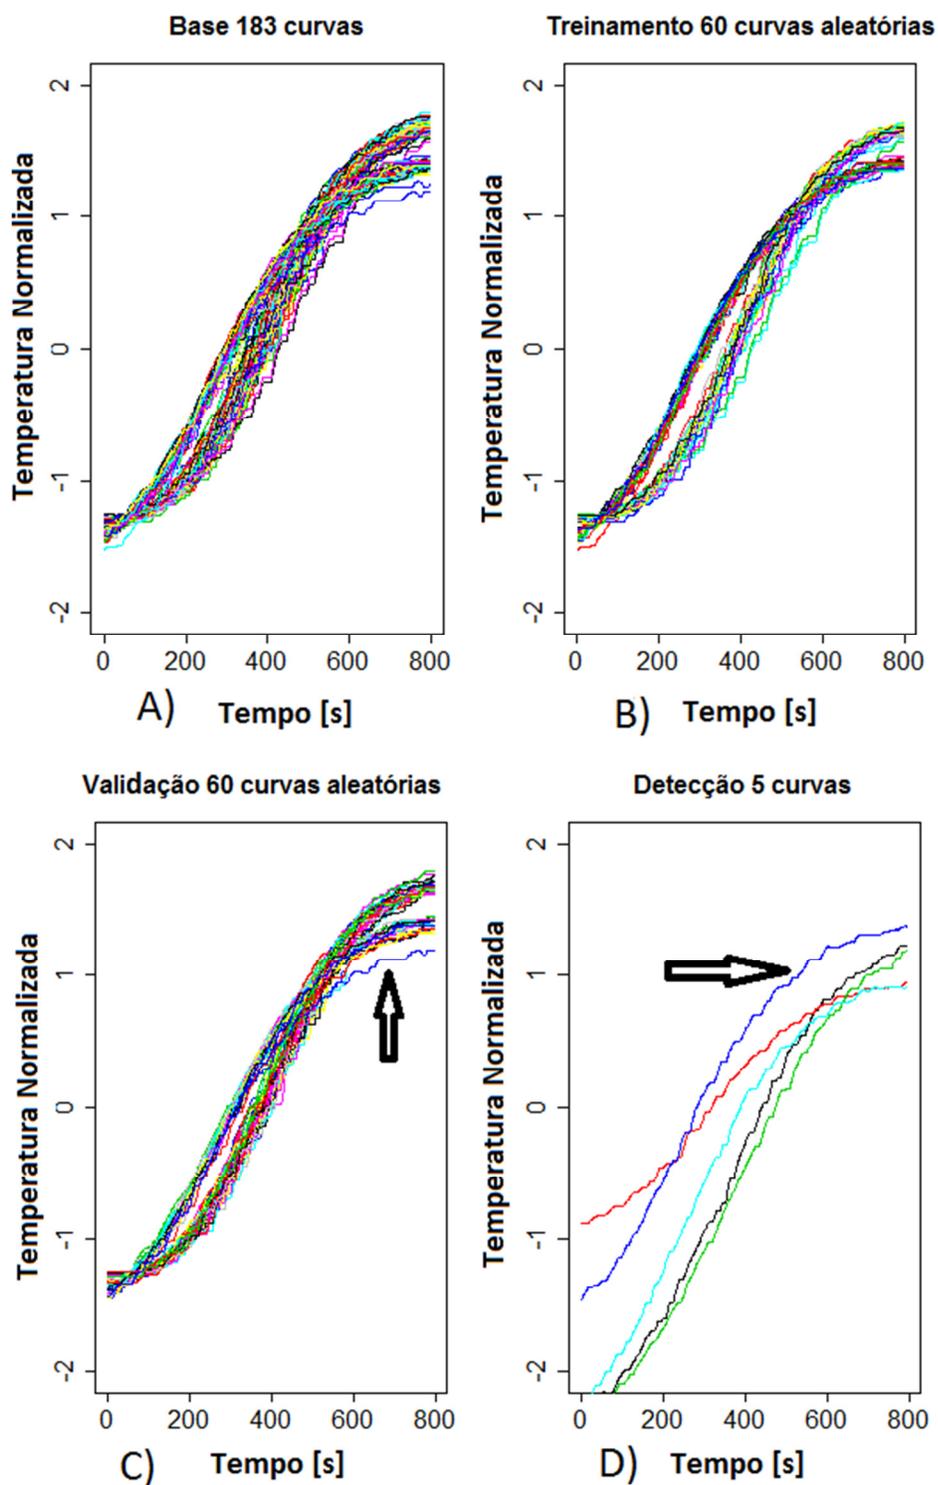


Figura 38- Experimento 1 de detecção de novidades com base de curvas para treinamento (A), curvas para treinamento (B), curvas para validação cruzada (C) e curvas para avaliação (D).

O limiar foi calculado para 95% de aproveitamento das curvas de treinamento, com base nas distâncias dessas curvas representadas pelos círculos verdes. Nas curvas de teste da validação cruzada, indicadas pelos pontos triangulares, detectou-se uma curva com distância maior que a do limiar (A). Para curvas com novidades, representadas pelos pontos circulares na cor azul, quatro pontos ficaram acima do limiar (A). No entanto, um ponto ficou abaixo do limiar (A), como mostrado na Figura 39. O triângulo vermelho indica uma curva de teste da validação com novidades, conforme a Figura 39 (B), que possui uma curva correspondente em (C) indicada pela seta na Figura 38. O círculo azul, que aponta uma curva sem novidade no grupo de curvas com novidades, também possui uma curva correspondente na Figura 38, em (D), indicada pela seta. Isso indica que o sistema foi robusto na detecção de novidades.

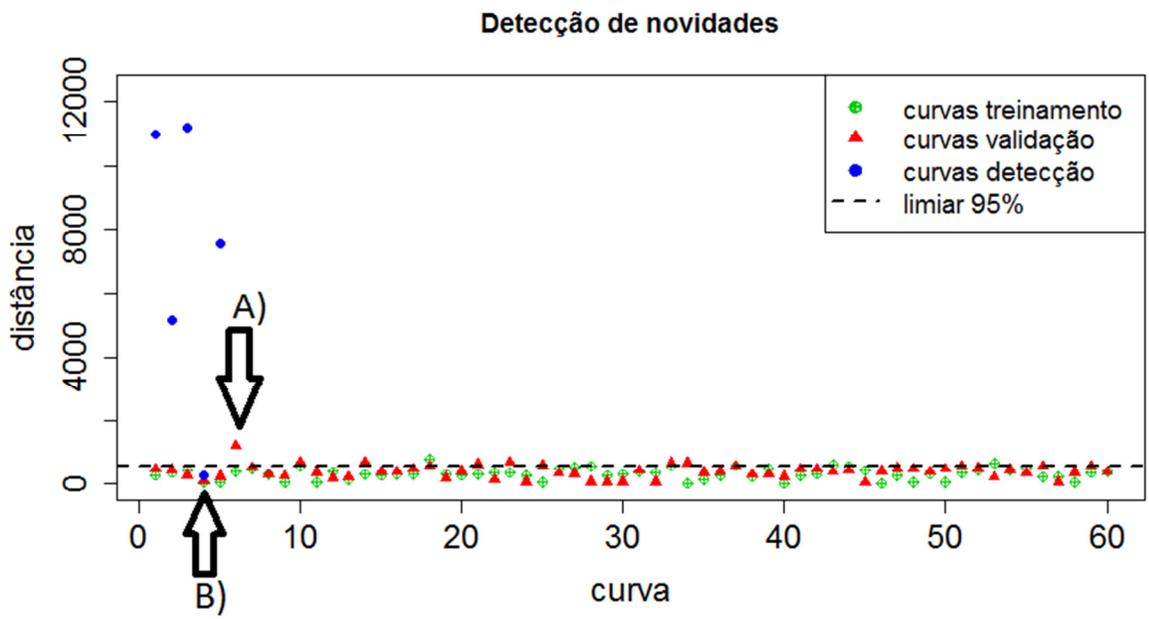


Figura 39- Gráfico com as distâncias do treinamento, validação e detecção do sistema de detecção de novidades.

No segundo experimento, foram repetidos os procedimentos do primeiro. A diferença é que o grupo de curvas com novidades são curvas dos sinais sem tratamento no microcontrolador. Essas curvas são consideradas de operações normais, ou seja, consideradas sem falhas (D), conforme a Figura 40. As curvas (B) e (C) da Figura 40 diferem

das curvas (B) e (C) da Figura 38, pois são escolhidas de forma aleatória a cada treinamento.

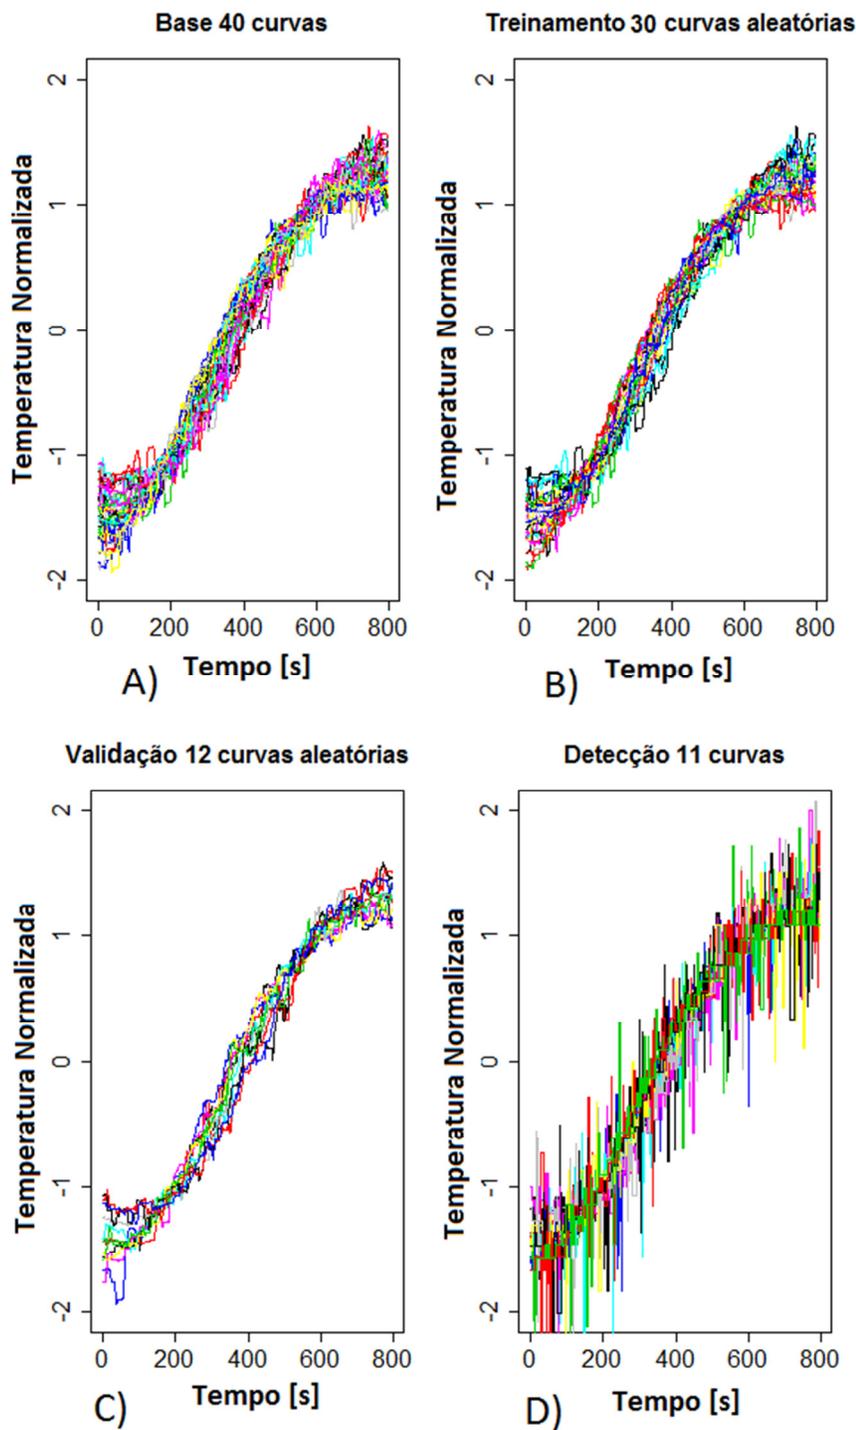


Figura 40- Experimento 2, detecção de novidades com base de curvas para treinamento (A), curvas para treinamento (B), curvas para validação cruzada (C) e curvas para detecção oriundas de sinais sem tratamento (D).

Mesmo sendo consideradas sem falhas, todas as curvas apresentaram uma distância muito grande em relação ao limiar, indicadas pelos pontos circulares azuis, Figura 41. Portanto, erroneamente são classificadas como curvas com novidades. Isso demonstra a importância do conhecimento anterior *na avaliação da detecção de novidades*.

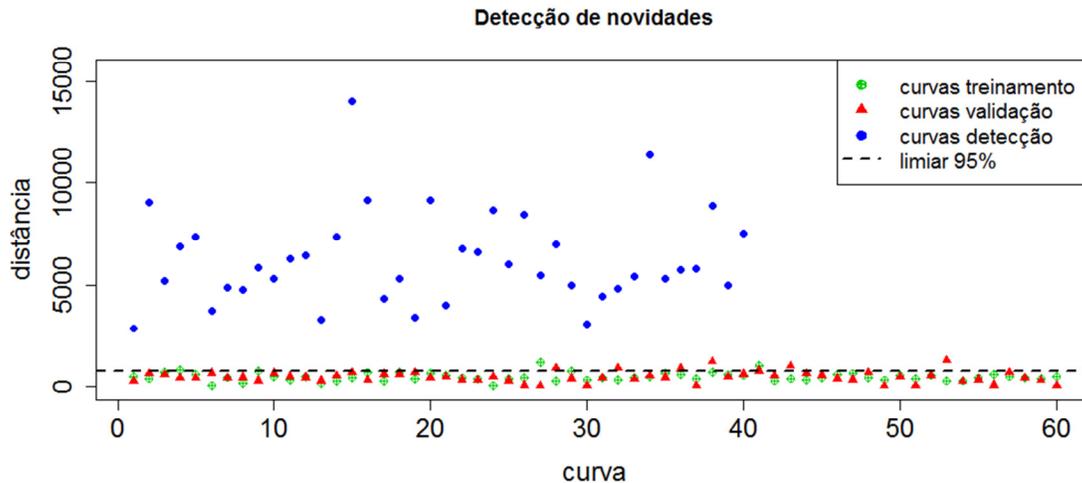


Figura 41-Gráfico com os resultados da detecção de novidades das curvas sem falhas oriundas dos sinais sem tratamento.

A Figura 42 apresenta o resultado da detecção de novidades de 11 curvas com novidades (A) oriundas dos sinais sem tratamento do microcontrolador. As distâncias entre elas são muito grandes, consequência da grande variabilidade dessas curvas, visualizadas em (B).

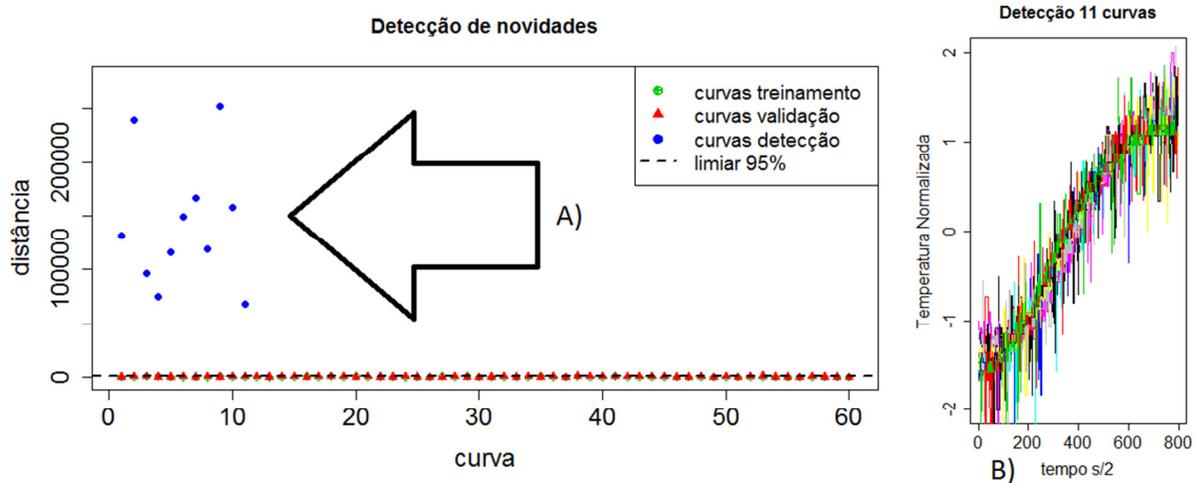


Figura 42- Gráfico com os pontos azuis (A) que indicam uma distância muito grande em relação ao limiar para o grupo de curvas ruidosas sem tratamento de sinais pelo microcontrolador (B).

O quarto experimento considerou curvas sem falhas de um processo de aquecimento em que foram geradas curvas sem o tratamento dos sinais pelo microcontrolador. Nesse experimento, foram empregadas 40 curvas como base de treinamento (A), 30 para treinamento (B) e 12 para validação (C). As curvas para detecção são de ruído elevado (D), Figura 43.

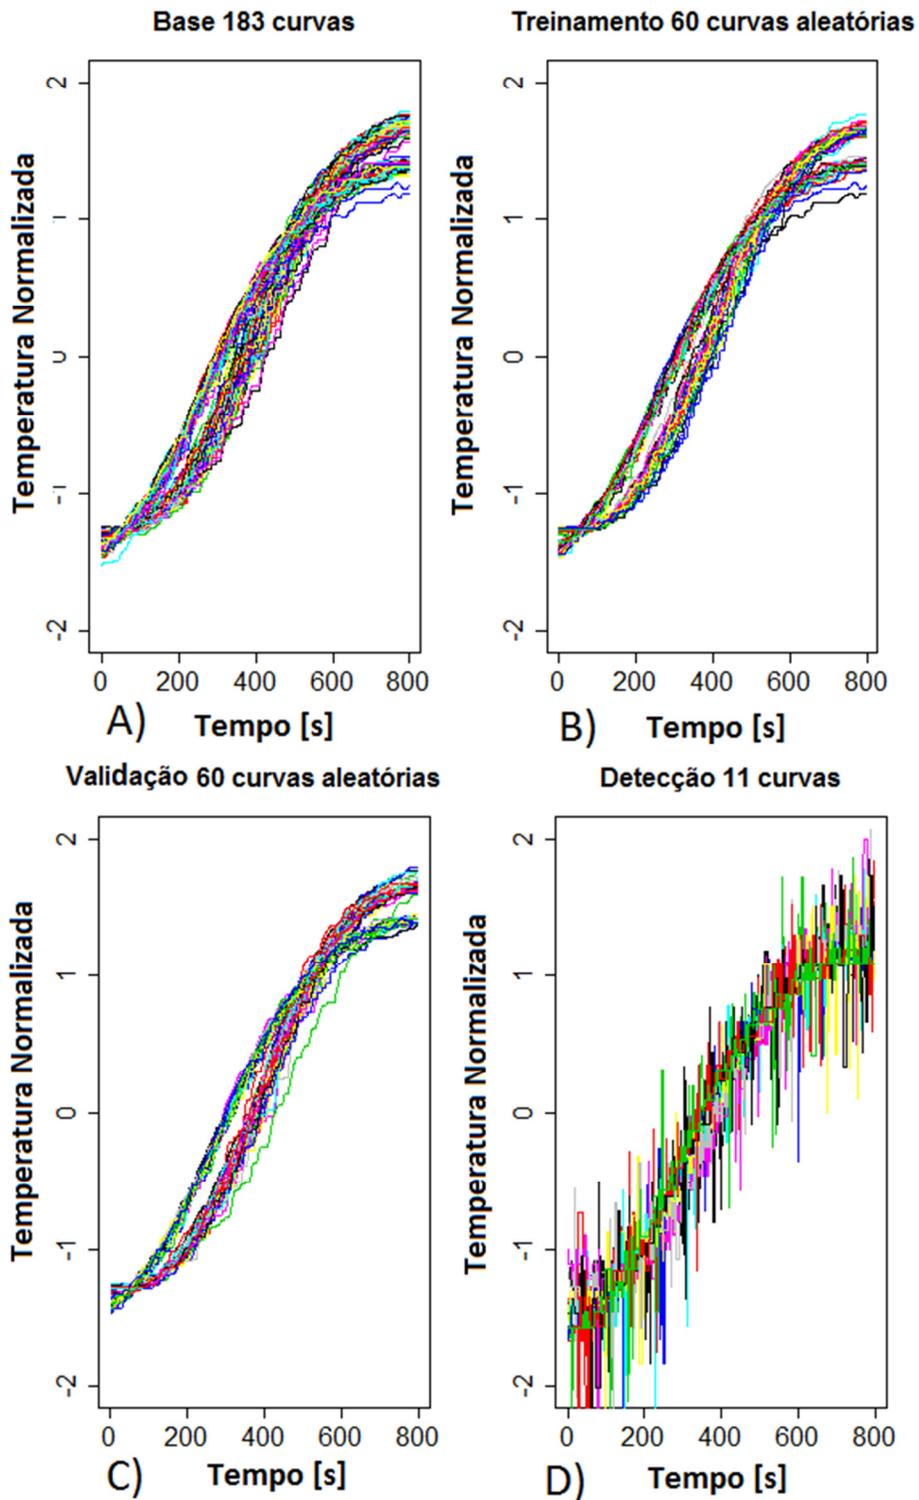


Figura 43- Gráfico com o grupo de curvas-base(A), curvas de treinamento (B), curvas de validação(C) formadas pelo grupo de curvas sem novidades e o grupo de curvas de sinais ruidosos (D).

Nesse experimento, as curvas de sinais ruidosos foram classificadas como curvas com novidades. Porém, as distâncias são aproximadamente 10 vezes menores (Figura 44) que as detectadas com o experimento 3, mostradas na Figura 42 pela seta (A). Isso reforça a necessidade do conhecimento do processo, para a correta aplicação da técnica de detecção de novidades.

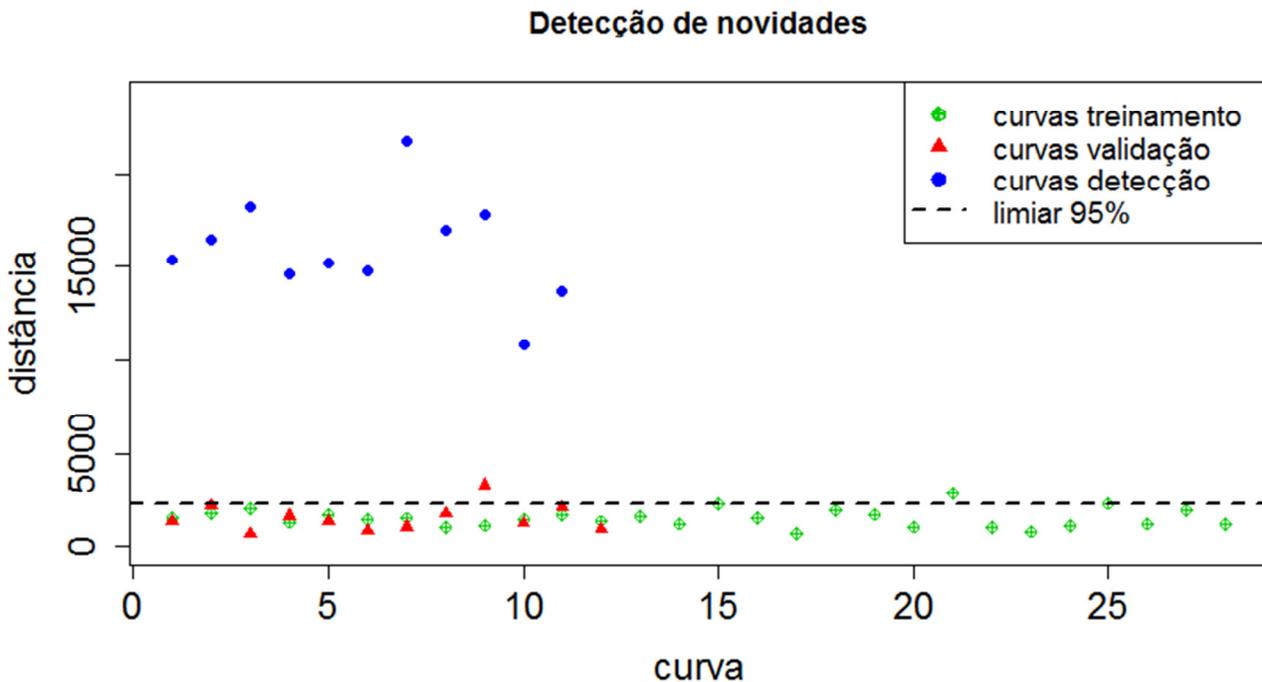


Figura 44-Gráfico com as distâncias do grupo de curvas ruidosas em relação ao grupo de treinamento, ambas oriundas de sinais sem tratamento pelo microcontrolador.

6.2. Considerações finais sobre os experimentos

Neste capítulo são apresentados os experimentos com os métodos de seleção de sinais pelo TMR e também a técnica de detecção de novidades com reconhecimento de padrões.

Em todos os experimentos foram aplicados os métodos e algoritmos citados no início. Os resultados dos experimentos foram colocados em gráficos para a melhor

compreensão. Os métodos propostos foram capazes de detectar todas as novidades apresentadas. Não só as curvas sem falhas, mas também as com falhas foram geradas pelo processo; portanto, não foram utilizadas curvas simuladas.

A planta-piloto utilizada não permitiu um controle mais detalhado de erros, como, por exemplo, erros intermitentes com menor variabilidade. Contudo, os erros gerados foram reais e suficientes para a aplicação de todas as técnicas discutidas e propostas.

Em todos os experimentos, fez-se uso do sensor LM35 como uma maneira de ter um referencial para a temperatura. Porém, o sensor apresentou uma resposta térmica rápida em relação aos sensores PT100. Isso inviabilizou o uso do LM35 como um referencial para o valor correto da temperatura.

7. CONCLUSÕES

Neste capítulo estão as conclusões dos estudos realizados neste trabalho para aumento da confiabilidade dos sistemas embutidos, usando redundância e algoritmos de decisões baseados em reconhecimento de padrões. Além disso, sugerem-se alguns temas que foram percebidos, para serem explorados e estudados em estudos futuros.

Verifica-se que sistemas embutidos, que aplicam aquisição de dados, são largamente usados em várias áreas do conhecimento, principalmente nos ambientes industriais. Como eles são empregados para tomada de decisões de sistemas críticos, como abordado pelos níveis de segurança SIL, conclui-se que é de vital importância que os sistemas embutidos operem de forma confiável, uma vez que estão sujeitos a falhas pelo ruído, mau funcionamento e outras, denominadas novidades. A nova metodologia proposta para o aumento da confiabilidade de sistemas embutidos de aquisição de dados, fundamentada no uso das duas técnicas distintas e diretamente conectadas, proporciona um aumento da confiabilidade. Avaliando os resultados dos experimentos, foi possível perceber que a técnica de resposta imediata, baseada na redundância dos sinais analógicos dos sensores do sistema de aquisição de dados on-line, foi eficiente na seleção do sinal de saída. A eficiência é creditada ao método de seleção do Voter - uma novidade proposta por esta pesquisa - que proporcionou menor interferência de sinal de entrada ruidoso ao sinal de saída. Pôde-se concluir que a conexão da técnica de redundância com a técnica de reconhecimento de padrões preenche a lacuna encontrada no TMR, quando dois ou três sinais possuem anomalias semelhantes, já que a alteração do comportamento pode ser percebida pela detecção de novidades, e isso valida o sinal de saída do Voter. Apesar da existência do atraso entre as duas técnicas de redundância e reconhecimento de padrões, a conexão entre elas possibilita a sinalização de problemas intermitentes no sinal e também pode prevenir uma sequência de bateladas futuras com anomalias, até que a falha leve o sistema ao colapso, gerando prejuízos.

A metodologia proposta mostrou-se adequada, uma vez que todos os experimentos foram realizados de acordo com ela. A organização em quatro grandes blocos foi um guia

para a execução e avaliação dos experimentos realizados. Criou-se uma planta-piloto de um sistema de aquecimento, que consistiu de um forno elétrico residencial, sensores de temperatura, módulos eletrônicos de conversão de temperatura, sistema embutido de aquisição de dados e computador com software de supervisão.

A estrutura da planta-piloto atendeu às necessidades para avaliação das metodologias estudadas aqui. As especificações de redundância do TMR foram atendidas com a montagem dos módulos em nível de sensores e instrumentação. Além disso, o sistema se mostrou estável para geração de curvas com repetibilidade dos padrões das curvas de aquecimento, mesmo com a alteração de escalas de temperatura. A planta-piloto proporcionou não só a geração dos dados, mas também a aplicação dos métodos de ações on-line do TMR. A sua pequena dimensão facilitou a mobilidade e a alteração e ajuste de sua estrutura. O sistema proporcionou a replicação de todos os experimentos realizados, e a planta-piloto atingiu todos os objetivos esperados. Portanto, foi uma ferramenta útil no desenvolvimento deste trabalho.

As técnicas de extração de curvas foram utilizadas para extrair todas as curvas empregadas no estudo. Os parâmetros dos algoritmos de detecção de estados e extração de curvas foram calibrados manualmente para os dois padrões de curvas.

O método proposto no TMR, média da menor diferença ou **voto**, mostrou-se mais robusto à entrada de sinais ruidosos que o método da média dos três sinais ou **média**. A robustez está em relação ao nível de influência do sinal de entrada no sinal de saída. Essas conclusões são fundamentadas nos experimentos observacionais e também nos experimentos estatísticos das distâncias entre as curvas. Esses métodos foram implementados na linguagem de programação C++ e utilizados pelo software supervisor da planta-piloto. A mesma implementação pode ser inserida no *firmware* do microcontrolador.

O sistema de detecção de novidades apresentou elevado número de acerto, pois foram identificadas todas as curvas com novidades, conforme demonstraram os experimentos.

O processo de normalização e centralização possibilitou agrupar as curvas dos três diferentes sinais de entrada para o treinamento do sistema de detecção de novidades. Essa técnica possibilitou a utilização de curvas em escalas e intervalos diferentes. Os experimentos indicaram que não houve perda de eficiência na detecção de novidades,

quando se utilizou todas as curvas em somente um conjunto de treinamento. Na verdade, esse agrupamento valida as estruturas e os métodos de redundância aplicados, já que considera que as curvas são praticamente cópias umas das outras. Conclui-se que as três entradas da mesma grandeza, medidas por três sensores redundantes, possuem o mesmo comportamento e podem ser utilizadas para a detecção de novidades de qualquer sinal.

O primeiro experimento mostrou que a detecção de novidades por validação cruzada pode ser utilizada para remover as curvas que apresentam um maior desvio. Assim, é possível melhorar a qualidade dos grupos de curvas de treinamento.

Os experimentos apontaram que é necessário dividir grupos de treinamento pela mudança de características dos sinais, ou seja, pela mudança dos padrões destes. Isso reforça a necessidade do conhecimento anterior sobre o que é novidade, que depende da avaliação de cada sistema. Em outro experimento, as curvas sem falhas de um sistema de aquecimento com menor tratamento de sinais foram classificadas erroneamente como curvas com novidades, quando se utilizou treinamento com curvas com maior nível de tratamento de sinais.

A detecção de novidades, com a utilização do modelo Gaussiano multivariado e da distância de Mahalanobis, foi adequada aos estudos desta pesquisa. A afirmação é justificada pela sensibilidade dos métodos à variabilidade dos sinais de entrada, ou seja, quanto maior a variabilidade ou diferença do padrão, maior a distância. Esse comportamento pode ser observado nos experimentos de detecção de novidades. Esta foi implementada no software supervisor, devido à complexidade envolvida no sistema de detecção de novidades.

A sugestão para futuros trabalhos é a proposta de detecção de novidades on-line, ou seja, enquanto o sistema está em operação. Assim, seria possível indicar um sinal com novidades para o sistema de votação do TMR. Outra sugestão é encontrar uma forma de determinação automática dos parâmetros para extração de curva, pois nesta pesquisa os parâmetros foram determinados por tentativa.

De acordo com os estudos realizados aqui, conclui-se que a confiabilidade em sistema de aquisição de dados analógicos para sistemas embutidos pode ser aumentada com a utilização do método proposto, que utiliza duas técnicas distintas diretamente

conectadas: redundância com TMR e detecção de novidades. Além disso, o uso do novo método proposto para o sistema de votação do TMR mostrou-se robusto à entrada de sinais ruidosos. O uso da inteligência artificial, por meio do reconhecimento dos padrões das curvas dos sinais redundantes, também se apresentou promissor para o aumento da confiabilidade dos sistemas embutidos.

8. REFERÊNCIAS

1. MARWEDEL, P. **Embedded Systems Foundations of Cyber-Physical Systems**. 2nd Edition. ed. Springer Science: Business Media, 2011.
2. FORD MOTOR COMPANY. **As ferramentas da NI mantêm a FORD na vanguarda da inovação**. National Instruments. . 2009. Acessado em abril 2015 em: <http://sine.ni.com/cs/app/doc/p/id/cs-12976>.
3. BATISTA, D. M.; REZENDE, F. C. **Sistema de aquisição de dados embarcado em veículo para análise de fadiga térmica em componentes plásticos**. , National Instruments. 2010. Acessado em abril 2015 em: <http://sine.ni.com/cs/app/doc/p/id/cs-14524>.
4. JUNIOR, M. F. D. S.; VIDAL, J. L. A. **Sistema de Instrumentação e Controle para Separadores Multifásicos Aplicados à Perfuração**. . 2010. Acessado em abril 2015 em: <http://sine.ni.com/cs/app/doc/p/id/cs-12393>.
5. ALVES, E. M. D. A.; TORRES, F. S.; MAIA, R. D. **Computador industrial e placas de aquisição de dados como controlador final de processo**. Mecatrônica Atual, p. 54-59. 2013.
6. ALVES, E. M. D. A.; AL., E. **Vantagens do Desenvolvimento Interno de Sistemas de Automação e Controle: O caso da Liasa**. Campina Grande - PB. Congresso Brasileiro de Automática 2012.
7. FALLER, R. **Project experience with IEC 61508 and its consequences**. Safety science [0925-7535] vol:42 iss:5., p. 405 -422. 2004.
8. BARR, M.; MASSA, A. **Programming embedded systems: with C and GNU development tools**. "O'Reilly , p. 1–2. ISBN 978-0-596-00983-0. 2006.
9. MALINOWSKI, A. **Comparison of embedded system design for industrial applications**. IEEE Transactions on Industrial Informatics [1551-3203] vol:7 iss:2, p. 244 - 254. 2011.
- 10 EMILIO, M. **EMBEDDED SYSTEM SYSTEM DESIGN**. Electronics world [1365-4675] . vol:120, p. 30 -32. 2014.
- 11 LIM, H. **Using virtual platform in embedded system education**. Computer applications . in engineering education [1061-3773] vol:20 , p. 346 -355. 2012.
- 12 RAJPAL, R. **Embedded data acquisition system for neutron monitors**. Fusion

- . engineering and design [0920-3796], p. 2166 -2169. 2012.
- 13 MEDINA, V. **Embedded data acquisition system with MDSPlus**. IEEE Transactions on Instrumentation and Measurement [0018-9456]. 2011.
- 14 GAITAN, N. C. **Real-time Acquisition of the Distributed Data by using an Intelligent System**. Elektronika ir elektrotechnika [1392-1215], p. 13-18. 2010.
- 15 SMITH, S. W. **The Scientist and Engineer's Guide to Digital Signal Processing**. Hard Cover, , ISBN 0-9660176-3-3 - chapter 3 and 4. 1997. Acessado em abril 2015: <http://www.DSPguide.com>.
- 16 NISHIJIMA, K.; KANASUGI, A.; ANDO, K. **Accuracy improvement of genetic algorithm for obtaining floating-point solution**. Artificial life and robotics [1433-5298]. 2014.
- 17 KWAK, S. W.; KIM, B. K. **Task-Scheduling Strategies for Reliable TMR Controllers Using Task Grouping and Assignment**. . IEEE TRANSACTIONS ON RELIABILITY, VOL. 49, NO. 4, DECEMBER 2000.
- 18 RANOUS, C. A. **Reliability**. Education, IEEE Transactions. ISSN 0018-9359, p. 52 - 54. 2007.
- 19 GUNAWARDANE, G. **Measuring reliability of service systems using failure rates: variations and extensions**. The International Journal of Quality & Reliability Management [0265-671X]. vol:21 iss: 5, p. 578 -590. 2004.
- 20 MICROSEMI CORPORATION. **Design of a Safe and Secure Process Control System. Application Example**. , Microsemi Corporation. 2013. acessado em abril 2015 em: http://www.microsemi.com/document-portal/doc_download/132858-design-of-a-safe-and-secure-process-control-system.
- 21 TIAN, P. **The Research of Embedded Software Reliability Evaluation System**. IEEE. . 2008.
- 22 GOSHEBLAGH, R. O.; MOHAMMADI, K. **Hybrid time and hardware redundancy to mitigate SEU effects on SRAM-FPGAs: Case study over the MicroLAN protocol**. Microelectronics Journal 45, p. 870–879. 2014.
- 23 KANNO, Y.; BEN-HAIM2, Y. **Redundancy and Robustness, or When Is Redundancy Redundant?** JOURNAL OF STRUCTURAL ENGINEERING, p. 935-945. 2011.
- 24 NANDA, A. K.; HAZRA, N. K. **Some results on active redundancy at component level versus system level**. Operations Research Letters 41 , p. 241–245. 2013.

- 25 MIKEL IDIRIN, X. A. A. V. J. L. A. J. M. **Implementation Details and Safety Analysis of a Microcontroller-based SIL-4 Software Voter**. IEEE Transactions on Industrial Electronics [0278-0046] yr:2011 vol:58 iss:3, p. 822 -829. 2011.
- 26 NEUMANN, J. V. **Probabilistic Logics Automata Studies**. Princeton University Press. . 1956.
- 27 FAVALLI, M. **TMR Voting in the Presence of Crosstalk Faults**. IEEE TRANSACTIONS ON RELIABILITY, VOL. 53, NO. 3. SEPTEMBER 2004.
- 28 LYONS, R. E.; VANDERKULK, W. **The Use of The Tripl-Modular Redundance To Improve Computer Reliability**. IBM Jornal. 1962.
- 29 ELMAGARMID, A. K.; DATTA, A. K. **The Design of Totally Self-checking TMR Fault-Tolerant Systems**. . IEEE TRANSACTIONS ON COMPUTERS. 1988.
- 30 SHIN, K. G.; KIM, H. **A Time Redundancy Approach to TMR Failures Using Fault-State Likelihoods**. , IEEE TRANSACTIONS ON COMPUTERS, VOL. 43, NO. 10, OCTOBER 1994.
- 31 DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. Hardcover, Second Edition. November 9, 2000.
- 32 BANFELDER, J. **Fourier and PCA Analysis**. Weill Cornell Medical College. 2008.
 . Acessado em abril/2015 em:
http://physiology.med.cornell.edu/people/banfelder/qbio/resources_2009/2009_4.3_Fourier%20Analysis.pdf.
- 33 GUYON, I. et al. **Feature Extraction. Foundations and Applications**. New York ISBN-13 . 978-3-540-35487-1 Springer Berlin Heidelberg. 2006.
- 34 L, T.; PIMENTEL, A. F.; CLIFTON, A. D. A. **Review of novelty detection**. Elsevier. Signal Processing., p. 215–249. 2014.
- 35 MA, J.; PERKINS, S. **Online Novelty Detection on Temporal Sequences**. Association of the Computer Machinery.ISBN:1-58113-737-0, p. 613-618. 2003.
- 36 COHEN, F. **Novelty Detection**. Network Security. , p. 18-19. 2003.
- 37 FILIPPONE, M.; SANGUINETTI, G. **Information Theoretic Novelty Detection**. Elsevier., . p. 805 - 814. July. 2009.

- 38 MODENESI, P. A.; BRAGA, P. A. **Analysis of Time Series Novelty Detection . Strategies for Synthetic and Real Data**. Neural Process Lett Springer Science+Business Media, LLC. 2009.
- 39 TODESCHINI, R. et al. **Locally centred Mahalanobis distance: A new distance . measure with salient features towards outlier detection**. Elsevier. Analytica Chimica Acta 787, p. 1–9. 2013.
- 40 MARSLAND, S. Novelty Detection in Learning Systems. **Neural Computing Surveys**, . mar. 2003. 1-39. On-Line at: <http://www.icsi.berkeley.edu/~jagota/NCS>.
- 41 HAN, H. et al. **A New Analog Circuit Fault Diagnosis Method Based on Improved . Mahalanobis Distance**. Springer Science. J Electron Test., p. 95–102. 2013.
- 42 GUL, M.; CATBAS, F. N. **Statistical pattern recognition for Structural Health . Monitoring using time series modeling: Theory and experimental verifications**. Mechanical systems and signal processing [0888-3270]. vol:23 iss:7, p. 2192 -2204. 2009.
- 43 MARKLEY, S. C.; MILLER, D. J. **Joint Parsimonious Modeling and Model . OrderSelection for Multivariate Gaussian Mixtures**. , IEEE JOURNAL OF SELECTED TOPICS IN SIGNAL PROCESSING, VOL. 4, NO. 3, JUNE 2010.
- 44 MILIORIS, D.; TZAGKARAKIS, G.; PAPAKONSTANTINOY, A. **Low-dimensional signal- . strength fingerprint-based positioning in wireless LANs**. Elsevier. Ad Hoc Networks 12, p. 100–114. 2014.
- 45 MACHADO, W. R. S.; GONZAGA, A. **Uma abordagem para maximização da eficiência . da aplicação da DGM para recuperação de imagens coloridas baseada na restrição desimilaridade entre matizes**. II Workshop de Visão Computacional. São Carlos, SP, p. 49-54. 2006.
- 46 VERGES, J.; SANFELIU, A. **Evaluation of Distances Between Color Image . Segmentations**. IbPRIA 2005, LNCS 3523, p. 263–270. 2005.
- 47 SHIN, K. G.; RAMANATHAN, P. **Real-Time Computing: A New Discipline of Computer . Science and Engineering**. , PROCEEDINGS OF THE IEEE, VOL. 82, NO. 1, JANUARY 1994.
- 48 BECKMAN, L. **Determining the required safety integrity level for your process**. , p. 105±111. Elsevier. ISA Transactions 37. 1998.
- 49 ASKARI, S.; NOURAN, M.; NAMAZI, I. A. **Fault-tolerant A/D converter using analogue . voting**. , p. 462 -462. IET Circuits, Devices & Systems [1751-858X] vol:5 iss:6 2011.

- 50 KRSTIC, M. D. et al. **A Mid-Value Select Voter**. , p. 733 -738. Microelectronics Reliability . [0026-2714] vol:45 iss:3. 2005.
- 51 BORGES, G. D. M. **Tolerância a Falhas Baseada em Projeto Diversitário**. Porto Alegre, . Departamento de Engenharia Elétrica. Escola de Engenharia - UFRS. 2010. Projeto de Diplmação.
- 52 PARHAM, B. **Voting networks**. , IEEE Transactions on Reliability [0018-9529] Parhami, . B yr:1991 vol:40 iss:3 pg:380 -394.
- 53 BJORNSON, N. **How Much Redundancy and What It Will Cost**. , p. 192 -195. IEEE . Transactions on Industry and General Applications [0018-943X]. 1970.
- 54 OPPENHEIM, A. V.; WILLISKY, A. S.; NAWAB, S. H. **Signals & Systems**. , 2. ed. New . Jersey: Prentice Hall, 1997.
- 55 SHEVLYAKOV., K. K. A. G. **Why Gaussianity?** IEEE Signal Processing Magazine, p. 102 . -113. 2008.
- 56 BLANK, D. M. P.; MARQUES, J. R. Q.; BARBOSA, F. **ANÁLISE DOS QUANTIS DA . TEMPERATURA MÍNIMA NO RIO GRANDE DO SUL E LIGAÇÕES COM OS SETORES DA CONCENTRAÇÃO DE GELO MARINHO ANTÁRTICO**. Revista Brasileira de Meteorologia, v.26. , p. 41 - 52. 2011.
- 57 OMEGA. **Practical Temperature Measurements**. : Made in the USA Handbook, v. 1, Z- . 33 to Z-36. 1989.
- 58 HYDE,. **Evaluating Thin Film RTD Stability**. , p. 79. 1997.
- 59 TEXAS INSTRUMENTS. **LM35 Precision Centigrade Temperature Sensors**. . AUGUST . 1999. REVISED OCTOBER 2013. Acessado em abril 2015 em: <http://www.ti.com/lit/ds/symlink/lm35.pdf>.
- 60 ADD-THREM. **Sensores PT100 – Linha A70, A71 Manual de Referência e . Especificações**. . 2013. Acessado em abril 2015 em: http://www.addtherm.com.br/wp-content/uploads/2014/10/A70_SensorPT100_ADD.pdf.
- 61 MICROCHIP. AN687 - Precision Temperature-Sensing With RTD, 2008. Acessado em . abril 2015 em: <http://ww1.microchip.com/downloads/en/appnotes/00687c.pdf>.
- 62 TEXAS INSTRUMENT. **AN1559 - Practical RTD Interface Solutions**. SNOA481B. June . 2007. Revised May 2013. Acessado em abril 2015 em:

<http://www.ti.com/lit/an/snoa481b/snoa481b.pdf>.

- 63 ACROMAG. **INTRODUCTION TO MODBUS TCP/IP**. , BusWorks® 900EN Series . 10/100M Industrial Ethernet I/O Modules w/ Modbus. 2005. acessado em maio 2015 em: http://www.acromag.com/sites/default/files/Acromag_Intro_ModbusTCP_765A.pdf.
- 64 NXP SEMICONDUCTORS. **LPC2364/65/66/67/68 - Single-chip 16-bit/32-bit microcontrollers**. NXP Semiconductors. , Product data sheet. Rev. 7.1. 2013. Acessado me abril 2015 em: http://www.nxp.com/documents/data_sheet/LPC2364_65_66_67_68.pdf.
- 65 SIMON, D.; SIMON, D. L. **Analytic Confusion Matrix Bounds for Fault Detection and Isolation Using a Sum-of-Squared-Residuals Approach**. IEEE TRANSACTIONS ON RELIABILITY. , p. 287 -296. 2010.
- 66 CRAN. **R free software environment for statistical**. CRAN. . 2014. Acessado em abtil . 2015 em : <http://www.r-project.org/>.
- 67 MARTINS, M. A. F.; PESSOA, R. W. S.; KALID, R. A. **ANÁLISE ESTATÍSTICA DO USO DE UM FILTRO DE KALMAN A UM SISTEMA DE MEDIÇÃO COM RUÍDOS**. V CONGRESSO BRASILEIRO DE METROLOGIA. Salvador, Bahia – Brasil. 2009.
- 68 PRATY, R. C.; BATISTA, G. A. P. A.; MONARD, M. C. **Curvas ROC para Avaliação de Classificadores**. IEEE Latin Amrican Transaction. , p. 215 - 222. 2008.