

DISSERTAÇÃO DE MESTRADO Nº 655

**UMA ESTRATÉGIA EVOLUTIVA PARA
DETECÇÃO E DIAGNÓSTICO DE FALHAS
EM SISTEMAS DINÂMICOS**

Reginaldo Rodrigues Braga

DATA DA DEFESA: 02/02/2011

Universidade Federal de Minas Gerais

Escola de Engenharia

Programa de Pós-Graduação em Engenharia Elétrica

**UMA ESTRATÉGIA EVOLUTIVA PARA DETECÇÃO E
DIAGNÓSTICO DE FALHAS EM SISTEMAS DINÂMICOS**

Reginaldo Rodrigues Braga

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. Walmir Matos Caminhas

Belo Horizonte - MG

Fevereiro de 2011

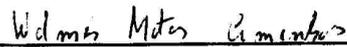
"Uma Estratégia Evolutiva para Detecção e Diagnóstico de Falhas em Sistemas Dinâmicos"

Reginaldo Rodrigues Braga

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 02 de fevereiro de 2011.

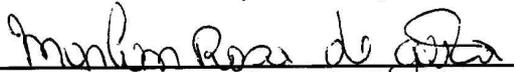
Por:



Prof. Dr. Walmir Matos Caminhas
DELT (UFMG) - Orientador



Prof. Dr. Fernando Antônio Campos Gomide
DCA (UNICAMP)



Dr. Marlon Rosa de Góvêa
Laminação (GERDAU-AÇOMINAS)

Dedicatória

Aos meus pais, *Maria e José Braga*, que representam a base e o norte da minha caminhada nesta vida: “*de onde eu vim*”.

Aos meus filhos, *Natália e Fernando*, que representam o motivo maior da minha luta: “*para onde eu vou*”.

À minha esposa, *Claudete*, que esteve ao meu lado durante toda esta peregrinação, incentivando e dando o suporte necessário para atingir os objetivos traçados.

Agradecimentos

Primeiramente a *Deus* por toda a Sua generosidade.

Aos meus gestores *Mário Hermes Rezende, Selma Marchette da Silva Marinho, Jorge Luiz de Oliveira e Sérgio Nascimento Leal*, pela oportunidade de realizar este mestrado.

Ao meu orientador, *Prof. Walmir Matos Caminhas*, pelo apoio, incentivo e direcionamento deste trabalho.

Ao colega *André Paim Lemos*, pelas valiosas sugestões e dicas durante o desenvolvimento do algoritmo.

Ao amigo *Luciano Morais Teixeira*, pela inestimável ajuda na pesquisa, coleta e compilação dos dados de formação de laço no laminador de fio máquina.

À Universidade Federal de Minas Gerais, representando todos os contribuintes do Brasil.

Sumário

Dedicatória.....	1
Agradecimentos	2
Sumário.....	3
Índice de Figuras	5
Índice de Tabelas	7
Resumo	8
Abstract.....	9
1. Introdução.....	10
1.1 Detecção e Diagnóstico de Falhas	10
1.2 Motivação e Objetivos do Trabalho	13
1.3 Descrição da Metodologia Empregada.....	14
1.4 Estrutura do Trabalho	16
2. Revisão Bibliográfica	18
2.1 Aprendizado Participativo	18
2.2 Agrupamento Participativo.....	21
3. Desenvolvimento do Novo Algoritmo	24
3.1 Modificações no AAP Original	24
3.2 Influência do R_{min} no Agrupamento de Dados	33
3.3 Variação da Taxa de Aprendizagem no AAPM	37
3.4 Interface com o Operador Para Rotulagem dos Grupos.....	39
3.5 Pseudo Código do AAPM	40
4. Aplicação do AAPM com Dados Simulados	42
4.1 Condições de Simulação.....	42
4.2 Resultados.....	44

4.2.1	Classificação Utilizando Tensão e Corrente das Três Fases	44
4.2.2	Classificação Utilizando Tensão e Corrente da Fase A.....	46
5.	Aplicação do AAPM com Dados Reais	48
5.1	Visão Geral de um Laminador de Fio Máquina	48
5.2	Controle de Velocidade e Formação de Laços	49
5.3	Laço Horizontal em Linha.....	51
5.4	Rotas de Laminação.....	53
5.5	Condições de Aplicação do AAPM.....	54
5.6	Resultados.....	60
5.6.1	Amostras da Operação Normal.....	60
5.6.2	Amostras da Operação com Falha 1	62
5.6.3	Amostras da Operação com Falha 2	64
5.6.4	Amostras da Operação com Falha 3	66
5.6.5	Conjunto Completo de Amostras	68
5.6.6	Síntese dos Resultados.....	71
6.	Conclusão	75
6.1	Problemas Encontrados	75
6.2	Principais Contribuições.....	75
6.3	Conclusão Final.....	75
6.4	Trabalhos Futuros.....	76
	Bibliografia.....	77

Índice de Figuras

Figura 1.1 – Metodologia de detecção e diagnóstico adaptativo de falhas..	16
Figura 2.1 – Mecanismo de aprendizado participativo.	20
Figura 3.1 – Raios de ação dos grupos.....	27
Figura 3.2 – Comportamento de a^k para diferentes valores de NAG	32
Figura 3.3 – Agrupamento de dados com duas variáveis e quatro grupos... 33	
Figura 3.4 – Agrupamento de dados com R_{min} maior que zero.....	34
Figura 3.5 – Agrupamento de dados com R_{min} nulo (quadro 1).....	34
Figura 3.6 – Agrupamento de dados com R_{min} nulo (quadro 2).....	35
Figura 3.7 – Evolução do controle de grupos com R_{min} maior que zero.....	36
Figura 3.8 – Evolução do controle de grupos com R_{min} nulo.....	36
Figura 3.9 – Variação da taxa de aprendizagem.	38
Figura 3.10 – Janela para intervenção do operador.....	39
Figura 4.1 – Janela para rotulagem das condições de operação.....	43
Figura 4.2 – Classificação usando seis variáveis de entrada.....	45
Figura 4.3 – Classificação usando duas variáveis de entrada.	47
Figura 5.1 –Mesa de formação de laço horizontal em linha.	51
Figura 5.2 – Lay-out do laminador na área dos blocos laminadores	54
Figura 5.3 – Controle do laço horizontal sem falha.	55
Figura 5.4 – Formação normal do laço.	56
Figura 5.5 – Formação com falha 1 do laço.....	57
Figura 5.6 – Formação com falha 2 do laço.....	57
Figura 5.7 – Formação com falha 3 do laço.....	58
Figura 5.8 – Janela de intervenção do operador para formação de laço.	59
Figura 5.9 – Grupos identificados nas amostras de operação normal.....	60

Figura 5.10 – Amostras da operação normal.	61
Figura 5.11 – Grupos identificados nas amostras de operação com falha 1.	62
Figura 5.12 – Amostras da operação com falha 1.	63
Figura 5.13 – Grupos identificados nas amostras de operação com falha 2.	64
Figura 5.14 – Amostras da operação com falha 2.	65
Figura 5.15 – Grupos identificados nas amostras de operação com falha 3.	66
Figura 5.16 – Amostras da operação com falha 3.	67
Figura 5.17 – Grupos identificados no conjunto completo de amostras.	70
Figura 5.18 – Amostras da operação completa.	70
Figura 5.19 – Mapa geral de identificação dos grupos consolidados.	72

Índice de Tabelas

Tabela 3.1 – Dados de quatro grupos distintos.	25
Tabela 3.2 – Centros dos grupos.	25
Tabela 4.1 – Condições de Operação do motor de indução.	42
Tabela 4.2 – Grupos consolidados usando seis variáveis de entrada.	44
Tabela 4.3 – Intervenções do operador para seis variáveis de entrada.	45
Tabela 4.4 – Grupos consolidados usando duas variáveis de entrada.	46
Tabela 4.5 – Intervenções do operador para duas variáveis de entrada.	47
Tabela 5.1 – Grupos consolidados para operação normal.	60
Tabela 5.2 – Intervenções do operador para operação normal.	61
Tabela 5.3 – Grupos consolidados para operação com falha 1.	62
Tabela 5.4 – Intervenções do operador para operação com falha 1.	63
Tabela 5.5 – Grupos consolidados para operação com falha 2.	64
Tabela 5.6 – Intervenções do operador para operação com falha 2.	65
Tabela 5.7 – Grupos consolidados para operação com falha 3.	66
Tabela 5.8 – Intervenções do operador para operação com falha 3.	67
Tabela 5.9 – Grupos consolidados para operação completa.	68
Tabela 5.10 – Intervenções do operador para operação completa.	69
Tabela 5.11 – Comparação dos grupos consolidados nos cinco testes.	71
Tabela 5.12 – Comparação das intervenções do operador nos cinco testes.	73
Tabela 5.13 – Comparação dos indicadores nos cinco testes.	74

Resumo

Detecção e Diagnóstico de Falhas (DDF) em sistemas dinâmicos é um problema importante em engenharia de processos que tem atraído muita atenção nos últimos anos. A detecção precoce e o diagnóstico de falhas de processo em sua fase inicial podem ajudar a evitar a progressão de eventos anormais e reduzir a perda de produtividade. Este trabalho propõe uma abordagem para DDF baseada no *Algoritmo de Agrupamento Participativo*; um classificador evolutivo que permite ao sistema aprender a classificar as falhas à medida que elas ocorrem. Ele é capaz de detectar novos modos de operação, e a cada iteração um novo grupo pode ser criado, um grupo existente pode ter seus parâmetros modificados, ou dois grupos redundantes unificados. Além disso, mais de um grupo pode ser utilizado para descrever um modo de operação. O resultado final é a proposição do *Algoritmo de Agrupamento Participativo Modificado (AAPM)*, que inova no uso dos índices de compatibilidade e de alerta, bem como nos seus procedimentos de cálculo. O AAPM introduz os conceitos de grupos *candidatos* e grupos *consolidados*, sugerindo uma nova abordagem para os problemas de *outlier* (ruídos). Visando analisar o desempenho do algoritmo, o AAPM é testado para DDF de dois sistemas dinâmicos diferentes: um motor de indução (utilizando dados simulados), e um processo na laminação de fio-máquina (utilizando dados reais de operação). Finalmente, são discutidos os resultados e avaliado o uso do AAPM em outros casos de DDF.

Palavras-chave: *Detecção e Diagnóstico de Falhas, Aprendizagem Participativa Evolutiva, Inteligência Computacional, Sistemas Nebulosos Evolutivos, Sistemas Evolutivos Inteligentes.*

Abstract

Fault Detection and Diagnosis (FDD) in dynamic systems is an important problem in process engineering that has attracted much attention in recent years. Early detection and diagnosis of process failures in its initial stage can help avoid abnormal event progression and reduce productivity loss. This work proposes an approach for FDD based on the *Participatory Clustering Algorithm*; an evolutionary classifier that allows the system to learn how to classify the faults as they occur. It is able to detect new operation modes, and in each iteration a new group may be created, an existing group may have its parameters changed, or two redundant groups unified. Moreover, more than one group can be used to describe an operation mode. The end result is the proposition of *Modified Participatory Clustering Algorithm (MPCA)*, which innovates in the use of compatibility and alert indices, as well as in their calculation procedures. The MPCA introduces the concepts of candidate groups and consolidated groups, suggesting a new approach to the outlier problems. In order to analyze the algorithm performance, the MPCA is tested for FDD of two different dynamical systems: an induction motor (using simulated data), and a process on wire rod mill (using actual operation data). Finally, the results are discussed and the use of the MPCA in other FDD cases is evaluated.

Keywords: *Fault Detection and Diagnosis, Evolutionary Participatory Learning, Computational Intelligence, Fuzzy Evolutionary Systems, Intelligent Evolutionary Systems.*

1. Introdução

1.1 Detecção e Diagnóstico de Falhas

Com o desenvolvimento da microeletrônica, e em especial dos microprocessadores, a disciplina controle de processo teve enormes avanços nas últimas quatro décadas. O advento dos microcomputadores e dos controladores lógicos programáveis possibilitou o controle de processos complexos com relativa facilidade, rapidez e baixo custo. Ações de controle regulatório ao nível de chão de fábrica, tais como abertura e fechamento de válvulas, que anteriormente eram realizadas por seres humanos, agora são realizadas de forma automatizada e com um sucesso considerável por controladores microprocessados. Com o progresso no controle distribuído e modelagem de sistemas de controle preditivo, os benefícios para diversos segmentos industriais, tais como químico, petroquímico, cimento, mineração, siderurgia, energia elétrica e de dessalinização têm sido muito grandes [VEN 02a].

Apesar disto, uma tarefa fundamental de controle na gestão das plantas industriais ainda continua a ser uma atividade manual, desempenhada por operadores. Trata-se da tarefa de responder a eventos anormais de um processo. Esta tarefa evolui a detecção no tempo certo de um evento anormal, o diagnóstico de suas causas fundamentais e, em seguida, a tomada de decisões adequadas de supervisão com ações para trazer o processo de volta ao normal, em segurança e em estado operacional. Toda essa atividade passou a ser chamada de *Gestão de Eventos Anormais*, do inglês *Abnormal Event Management (AEM)*, uma componente chave do controle e supervisão de processos [VEN 02a].

No entanto, essa total confiança nos operadores para lidar com tais eventos anormais e emergenciais tem se tornado cada vez mais difícil. Ela é difícil por causa do amplo escopo da atividade de diagnóstico, que abrange uma variedade de anomalias tais como falhas em sensores, degradação na unidade de processo, desvio dos parâmetros e assim por diante. Esta tarefa torna-se mais complicada ainda devido ao tamanho e complexidade das plantas de processo modernas. Por exemplo, em uma planta de grande porte como um laminador de chapas grossas pode haver mais de 20.000 variáveis de processo sendo monitoradas em poucos décimos de segundo, levando à sobrecarga de informação. Além do mais, a tarefa de diagnóstico de falhas é dificultada

pelo fato de que as medições de processo podem muitas vezes ser insuficientes, incompletas ou não confiáveis. Para piorar a situação, frequentemente é dada ênfase ao diagnóstico rápido, o que coloca sobre a atividade de diagnóstico algumas restrições e exigências.

Dadas tais condições difíceis, não é nenhuma surpresa constatar que os operadores tendem a tomar decisões erradas e adotar medidas que tornam as coisas ainda piores. Estatísticas da produção industrial mostram que cerca de 70% dos acidentes são causados por erros humanos. Esses eventos anormais têm impactos significativos nas áreas econômica, ambiental e de segurança.

Detecção e Diagnóstico de Falhas (DDF) em sistemas dinâmicos é um problema importante em engenharia de processos que tem atraído muita atenção nos últimos anos. A detecção precoce e o diagnóstico de falhas de processo em sua fase inicial, enquanto a planta ainda está operando em uma região controlável, pode ajudar a evitar a progressão de eventos anormais e reduzir a perda de produtividade. Uma vez que as indústrias perdem bilhões de dólares todos os anos em decorrência de falhas em seus sistemas, este setor considera a Gestão de Eventos Anormais como o problema número um que precisa ser resolvido. Portanto, há atualmente um considerável interesse neste campo, não só por parte dos profissionais da indústria como também por parte dos pesquisadores acadêmicos, o que não era comum há algumas décadas atrás

Na literatura há uma abundância de trabalhos sobre DDF que vão desde métodos analíticos para a inteligência artificial até abordagens estatísticas. Do ponto de vista de modelagem, há métodos que requerem modelos exatos de processos, modelos semi-quantitativos ou modelos qualitativos. No outro extremo do espectro existem métodos que não pressupõem qualquer forma de informação do modelo e dependem somente de dados históricos do processo. Além disso, dado o conhecimento do processo, existem diferentes técnicas de pesquisa que podem ser aplicadas para realizar diagnóstico [VEN 02a] [VEN 02b] [VEN 02c].

Ao analisarmos a evolução das técnicas empregadas para detecção e diagnóstico de falhas em sistemas dinâmicos, verifica-se que ela pode ser dividida basicamente em três fases.

Na primeira fase, a partir de meados da década de 70, as técnicas eram baseadas em modelos que representam a física do processo. Neste caso têm-se a

redundância analítica, cujas abordagens incluem espaço de paridade, estimação de estados, estimação de parâmetros e sistemas especialistas, dentre outros [FRA 90].

Numa segunda fase, a partir da década de 90, foram aplicadas técnicas sob duas óticas distintas:

- Classificação de padrões, donde se podem destacar algoritmos heurísticos, técnicas de probabilidade, redes neurais e lógica neuro-fuzzy. Este tipo de técnica requer uma massa de dados coletada e selecionada previamente, que então é apresentada ao sistema classificador em forma de aprendizagem supervisionada [CAM 96].
- Conhecimento adquirido diretamente de especialistas, que emprega lógica clássica ou lógica nebulosa. O termo conhecimento se refere à experiência que um ser humano tem em um determinado processo. Este método é normalmente utilizado quando o comportamento do sistema obedece a uma regra empírica.

Na terceira e atual fase, iniciada há uns cinco anos atrás, algumas propostas de trabalho na área de DDF têm sido baseadas em *Algoritmos Evolutivos Inteligentes* [KAS 06] [LIM 08] [INA 09] [LEM 10]. Eles são capazes de realizar um aprendizado gradativo com um conjunto de dados sequencial e de tomar uma decisão a cada etapa.

Sistemas Inteligentes podem ser definidos como sistemas que incorporam alguma forma de raciocínio que é típica dos seres humanos. Por outro lado, a *Evolução* é descrita na teoria de Darwin como um fenômeno que se dá com a seleção natural das espécies em populações de seres vivos ao longo de gerações. Neste contexto, o termo *Sistemas Evolutivos Inteligentes* é usado para descrever o fenômeno do desenvolvimento gradual da estrutura do sistema e seus parâmetros [KAS 06].

O termo *evolutivo* foi empregado para diferenciar tais sistemas dos adaptativos e dos evolucionários. Os *Sistemas Adaptativos* são capazes de ajustar apenas seus parâmetros e possuem uma estrutura fixa, enquanto os *Sistemas Evolucionários* (algoritmos genéticos, programação genética), baseiam-se no processo de evolução que ocorre em populações de seres vivos e seus mecanismos de adaptação são inspirados no conceito de seleção, cruzamento e mutação de cromossomos.

Já os *Sistemas Evolutivos* são capazes de ajustar sua estrutura e seus parâmetros em tempo real. Tais sistemas se baseiam no processo de aprendizado

humano, mais especificamente, na geração e adaptação do conhecimento a partir de experiências, ou seja, tem como base o processo de evolução dos indivíduos ao longo de sua vida. Esse processo pode iniciar-se a partir de um conjunto vazio de regras (conhecimento) e novas regras são aprendidas à medida que o indivíduo se depara com novas experiências não explicadas pelas regras existentes. As regras não são fixas ou pré-determinadas e sua geração é incremental, permitindo que regras possam ser adicionadas, excluídas ou modificadas, para melhor se adaptarem às experiências vivenciadas.

1.2 Motivação e Objetivos do Trabalho

A pesquisa em sistemas de DDF no sentido de se usar sistemas evolutivos inteligentes foi impulsionada pelo fato da grande maioria dos sistemas físicos não ser linear e seus parâmetros variarem no tempo. De fato, se observarmos as aplicações práticas de controle nos processos físicos da indústria, constata-se que em sua quase totalidade tem-se pelo menos uma das seguintes situações presente: os modos de operação são complexos (eventualmente desconhecidos), ou eles mudam com o tempo (desgastes dos equipamentos, substituição de componentes, etc.)

As técnicas adaptativas convencionais são apropriadas para representar objetos com lenta alteração de parâmetros. Estas técnicas têm baixo desempenho ao manipular sistemas complexos com múltiplos modos de operação ou mudanças bruscas de características, já que levam muito tempo para reaprender os parâmetros do modelo após uma mudança drástica no sistema [KAS 06].

O presente trabalho propõe um sistema de DDF baseado no algoritmo de agrupamento não supervisionado, chamado de *Algoritmo de Agrupamento Participativo*, utilizado e discutido na dissertação de Elton Mário de Lima [LIM 08]. O agrupamento participativo surgiu como resultado da aplicação do conceito de *Aprendizagem Participativa* em problemas de agrupamento de dados. O Aprendizado Participativo é um mecanismo de aprendizagem no qual a percepção acerca de um sistema depende de quanto o mecanismo é capaz de representar o conhecimento já estabelecido sobre o sistema. Ele define um processo de aprendizagem passo a passo que pode ser implementado recursivamente [LIM 08] [YAG 04].

1.3 Descrição da Metodologia Empregada

Para contextualizar o emprego do *Algoritmo Evolutivo Inteligente* neste trabalho, suponha que o objetivo seja desenvolver um sistema para detecção e diagnóstico de falhas num processo que apresente as seguintes características:

- Processo muito complexo, cuja obtenção de um modelo matemático baseado na física é inviável;
- Não se dispõe de dados de falhas, por se tratar de uma planta nova;
- Certos modos de operação podem ser desconhecidos, devido a complexidade do sistema monitorado. Os modos operacionais também podem mudar ao longo do tempo, devido a desgastes, manutenções e troca de componentes, por exemplo.

Para este caso hipotético, que é o que ocorre em muitos processos industriais, torna-se impraticável a utilização dos métodos tradicionais de detecção e diagnóstico de falhas. Porém, técnicas de monitoramento da condição de operação podem ser utilizadas para detectar condições anormais que podem estar relacionadas à falhas.

Métodos de monitoramento da condição de operação, em geral, são baseados em lógica de limiares, que proporcionam elevado índice de alarme, em controle estatístico de processos [MON 01] ou em aprendizado de máquina [WON 06] [TIM 08] [RAJ 06], que aplicam técnicas de detecção de novidades [MAR 03a] [MAR 03b] para detectar condições normais de operação. Esses métodos de monitoramento podem ser utilizados para detecção de falhas. No entanto, geralmente eles não têm a capacidade de diagnosticar, pois apesar de detectarem operações anormais, são incapazes de classificá-las.

Diante desse contexto, a melhor opção é empregar técnicas que utilizam classificadores evolutivos e informações fornecidas pelo operador. A metodologia de detecção e diagnóstico de falhas desenvolvida neste trabalho é baseada em um classificador evolutivo que permite ao sistema aprender a classificar as falhas à medida que elas ocorrem. Ela é capaz de detectar novos modos de operação (mudanças no ponto de operação ou falhas). A cada iteração um novo grupo pode ser criado, um grupo

existente pode ter seus parâmetros modificados, ou dois grupos redundantes unidos. Mais de um grupo pode ser utilizado para descrever um modo de operação.

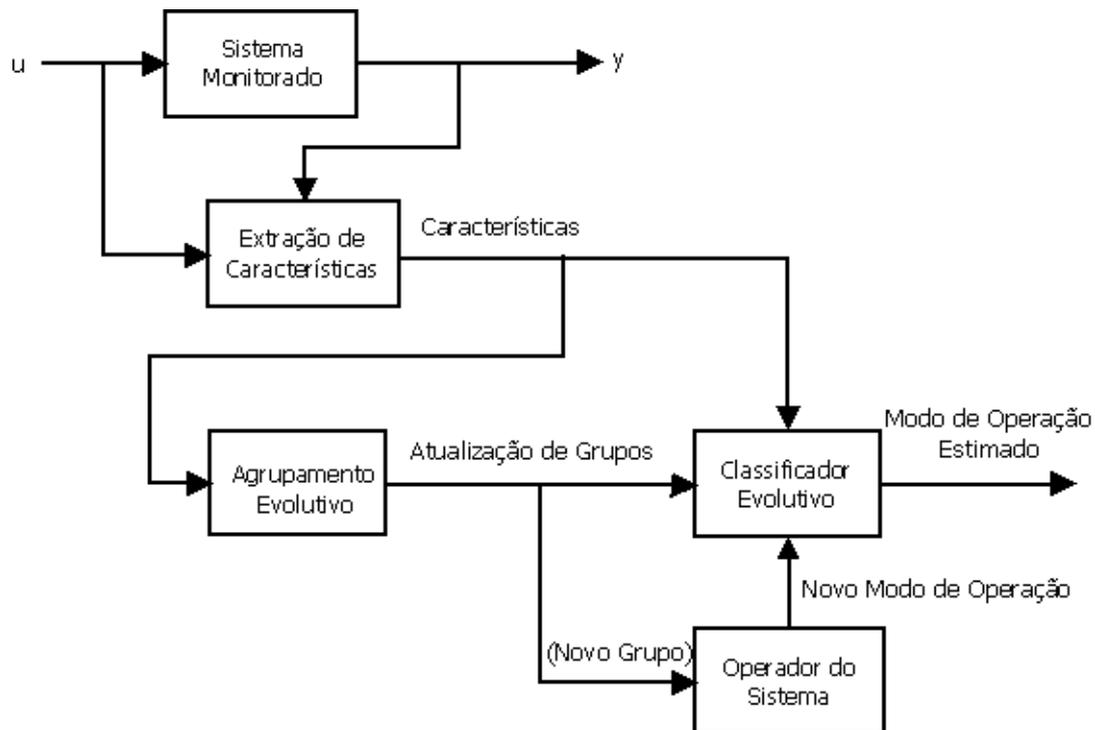
Para realizar a detecção e diagnóstico de falhas, inicialmente características devem ser extraídas das medidas de sensores do sistema. O método de extração de características depende do problema, mas deve ser capaz de ser executado em tempo real, uma vez que a metodologia de detecção e diagnóstico de falhas proposta também visa execução em tempo real. Esse processo de extração é realizado para transformar medidas de sensores do sistema monitorado em informações (características), capazes de distinguir os diferentes modos de operação do sistema.

Essas características são utilizadas como entradas do algoritmo de agrupamento evolutivo e do classificador evolutivo para estimar o modo de operação atual. O algoritmo de agrupamento processa cada vetor de características e atualiza a estrutura de grupo. O classificador evolutivo também processa essas características e estima o modo de operação do sistema e o grau de similaridade correspondente.

Caso o grau de pertinência do modo de operação estimado pelo classificador seja menor que um limiar pré-definido, o operador do processo deve ser notificado sobre um possível novo modo de operação. Esse operador age com autoridade para rotular as características apresentadas, ou seja, identificar o modo de operação atual, baseado nas características extraídas do sistema monitorado. Nesse caso, o modo de operação definido pelo operador é utilizado como rótulo da nova classe.

Caso o grau de similaridade do modo de operação estimado pelo classificador seja maior ou igual ao limiar, o operador não é notificado e o rótulo da classe é definido como o modo de operação estimado pelo classificador.

Conforme descrito anteriormente, dois grupos são combinados se eles estiverem associados ao mesmo modo de operação, isto é, se a compatibilidade entre eles for maior que o limiar. A Figura 1.1 mostra o esquema da metodologia do sistema de detecção e diagnóstico adaptativo de falhas proposto neste trabalho.



Fonte: [LEM 10].

Figura 1.1 – Metodologia de detecção e diagnóstico adaptativo de falhas.

Embora já existam métodos de detecção de falhas que empregam modelos nebulosos evolutivos [FIL 06] [LUG 08] [WAN 08], nenhum desses é capaz de realizar um diagnóstico adaptativo do sistema monitorado. Deste modo, a metodologia proposta difere das encontradas na literatura. Ela se traduz em um sistema de detecção e diagnóstico adaptativo de falhas capaz de detectar novos modos de operação usando um algoritmo robusto a ruído, realizar o diagnóstico sem a necessidade de modelos dinâmicos e incorporar informações sobre os novos modos de operação detectados.

1.4 Estrutura do Trabalho

Este trabalho é dividido em seis capítulos.

O capítulo 1 é a introdução do trabalho, apresentando os principais conceitos sobre DDF, a linha de pesquisa do trabalho e a metodologia empregada.

O capítulo 2 faz uma revisão bibliográfica sobre aprendizado participativo e agrupamento participativo, assuntos indispensáveis ao entendimento do trabalho.

O capítulo 3 discute todo o desenvolvimento do trabalho para a obtenção do novo algoritmo.

Os capítulos 4 e 5 apresentam as aplicações do AAPM em DDF considerando dois sistemas dinâmicos diferentes:

- As condições de operação normal e de falhas em um motor de indução (simulação em MatLab).
- Um sistema de controle de formação de laço horizontal entre cadeiras de uma laminação de fio-máquina (dados reais).

O capítulo 6 apresenta a conclusão do trabalho: as principais contribuições, os problemas encontrados, as considerações finais e propostas de trabalhos futuros.

2. Revisão Bibliográfica

2.1 Aprendizado Participativo

A ideia central do Aprendizado Participativo é que, quanto maior a compatibilidade entre uma nova observação e o estado atual do sistema, maior será o impacto dessa informação na aprendizagem do mesmo. Se a expressão $\bar{v} \in [0,1]^p$ é a representação do conhecimento, diz-se que o objetivo é aprender o valor de \bar{v} a partir de um conjunto de observações $x^k \in [0,1]^p$. Essa aprendizagem é feita via atualização de estimativas v^k feitas de acordo com a compatibilidade em relação a cada x^k observado [LIM 08].

O que se busca é uma função convergente do tipo $v^k = v(G^k, x^{k-1}, v^{k-1})$, onde se deve considerar as informações, a experiência acumulada e uma função de compatibilidade entre o dado observado e o modelo atual. Esta função de compatibilidade é uma função do tipo $\rho : [0,1]^p \times [0,1]^p \rightarrow [0,1]$ tal que ela seja:

- Reflexiva: $\rho(x, x) = 1$;
- Simétrica: $\rho(x, v) = \rho(v, x)$.

Define-se compatibilidade plena entre x e v quando $\rho(x, v) = 1$ e incompatibilidade, também plena, quando $\rho(x, v) = 0$. Considera-se que o sistema está propenso a aprender se $\rho \approx 1$, e o contrário se $\rho \approx 0$. Considerando x^k uma variável real em $[0,1]^p$ e $\alpha \in [0,1]$ o parâmetro *taxa de aprendizado*, então o processo de aprendizagem participativa é definido por uma sequência $\{v^k\}$ na forma: [YAG 90]

$$v^{k+1} = v^k + \alpha G^k(x^k - v^k) \quad (2.1)$$

Onde: $v^1 \in [0,1]^p$ e $G^k = G(\rho(x^k, v^k))$ uma função que depende da compatibilidade entre os vetores x^k e v^k em $k = 1, 2, 3, \dots$

No aprendizado participativo procura-se estimar a contribuição da última observação na atualização do conhecimento, representado pela variável v^k , e espera-se que a compatibilidade seja tão maior quanto mais próxima x^k estiver de v^k . Escolhendo-se $G^k = \rho^k$, obtém-se a seguinte expressão:

$$v^{k+1} = v^k + \alpha \rho^k (x^k - v^k) \quad (2.2)$$

Onde: $\alpha \in [0,1]$ é a taxa básica de aprendizagem e $\rho \in [0,1]$ uma função de compatibilidade.

Uma maneira simples de medir a compatibilidade entre as variáveis x^k e v^k é utilizar a distância entre elas como uma medida da proximidade. Neste caso definimos ρ^k como:

$$\rho^k = 1 - d(x^k, v^k) \quad (2.3)$$

Onde: $d(x^k, v^k)$, ou simplesmente d^k , é a distância Euclidiana entre x^k e v^k , calculada pela fórmula $d^k = \sqrt{(x_1^k - v_1^k)^2 + (x_2^k - v_2^k)^2 + \dots + (x_n^k - v_n^k)^2}$, sendo n a dimensão de x .

Em situações onde x^k apresente consecutivamente baixos índices de compatibilidade com v^k , ou seja, x^k é uma informação conflitante com v^k , é importante que um mecanismo de proteção seja criado para evitar inconsistências no aprendizado. Nestes casos deve-se minimizar a influência do índice de compatibilidade na atualização de v^k (sistema). Tal mecanismo no aprendizado participativo é chamado de *índice de alerta* (representado por “ a ”), e pode ser definido como: [LIM 08]

$$a^{k+1} = a^k + \beta(1 - \rho^k - a^k) \quad (2.4)$$

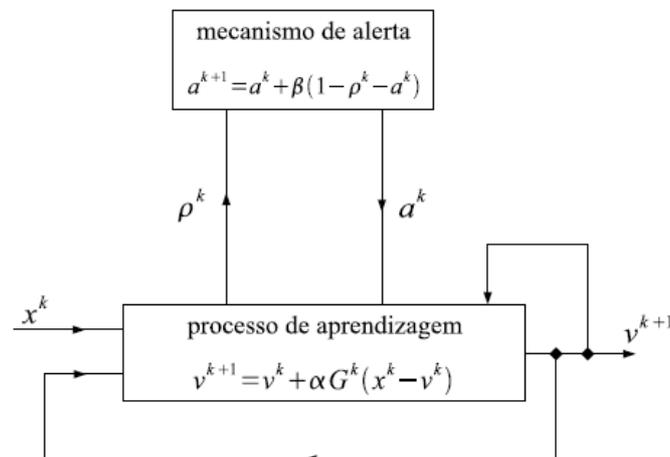
Onde: $\beta \in [0,1]$ é um parâmetro que controla a taxa de variação do índice de alerta e $a \in [0,1]$ o índice de alerta, com $k = 1, 2, 3, \dots$

Fazendo-se a substituição da equação (2.3) em (2.4), obtém-se:

$$a^{k+1} - a^k = \beta(a^k - \rho^k) \quad (2.5)$$

Na equação (2.5) percebe-se que a sensibilidade do índice de alerta ($a^{k+1} - a^k$), com relação às variações da entrada, é máxima quando $\beta = 1$. Yager [YAG 04] sugere o parâmetro β como o grau de conservadorismo do sistema e o índice de alerta a^k a confiança do sistema em relação ao aprendizado v^k .

O fluxograma da Figura 2.1 ilustra como é tratada cada nova observação x^k para a obtenção de v^{k+1} e mostra a interação das equações (2.1) e (2.4) discutidas anteriormente, formando o mecanismo do aprendizado participativo.



Fonte: [LIM 08]

Figura 2.1 – Mecanismo de aprendizado participativo.

Yager [YAG 04] propôs $G^k = (\rho^k)^{1-a^k}$ de forma a considerar também o índice de alerta na atualização v^{k+1} do aprendizado. A ideia é que a^k possa influenciar a aprendizagem alterando o peso de ρ^k na expressão da equação (2.1). Com isto tem-se esta equação reescrita da seguinte forma:

$$v^{k+1} = v^k + \alpha(\rho^k)^{1-a^k} (x^k - v^k) \quad (2.6)$$

2.2 Agrupamento Participativo

De forma geral conceitua-se agrupamento como sendo a classificação de padrões em grupos (clusters). Os padrões são descritos como vetores multidimensionais de atributos. É senso comum que padrões semelhantes devam estar no mesmo grupo e que padrões distintos devam estar em grupos distintos.

Agrupamento é uma técnica orientada por dados, o que significa que não se conhece previamente a que grupos os dados pertencem. Quando o número de grupos é um parâmetro fixo de entrada (informado previamente), o algoritmo de agrupamento é dito supervisionado. Quando um algoritmo é capaz de definir o número de grupos de acordo com os dados de entrada ele é chamado de não supervisionado.

Em geral as técnicas de agrupamento se dividem em *hierárquicas* e *particionais*. No agrupamento hierárquico gera-se uma representação em forma de árvore chamada *dendograma*, que representa grupos de padrões aninhados e níveis de similaridade nos quais os agrupamentos mudam. No nível mais alto todos os padrões estão em um mesmo grupo, enquanto no nível mais específico cada padrão está em um grupo unitário. Já no agrupamento particional gera-se uma única partição para cada grupo de dados. Dado um conjunto finito de dados X , o problema de agrupamento particional consiste em encontrar vários centros de agrupamentos (clusters), que possam caracterizar adequadamente classes relevantes de X .

No agrupamento particional a geração de grupos é feita pela otimização de uma função objetivo. A sua vantagem é ser mais eficiente para um conjunto de dados grandes. A desvantagem é o fato de ser necessário definir previamente o número de grupos desejável. Dentre os algoritmos de agrupamento particional, os mais conhecidos são o *Algoritmo de Erro Quadrático* e o *Algoritmo k-means*.

Agrupamento Participativo se encaixa no tipo de agrupamento particional, porém apresentando as seguintes diferenças: o número de grupos não é definido a priori; o número de grupos varia dinamicamente durante a execução do algoritmo; e os centros dos grupos são ajustados gradativamente utilizando o conceito de aprendizagem participativa.

No algoritmo de agrupamento participativo descrito em [LIM 08] e [SIL 03], base para desenvolvimento deste trabalho, c^k é o número de grupos no instante k (onde $k = 1, 2, 3, \dots$ são os instantes nos quais os dados são apresentados), e $v_i^k \in [0,1]^p$ é o centro de cada grupo $i = 1, 2, 3, \dots, c^k$. A partir da equação (2.6) do aprendizado participativo a atualização de cada centro de grupo é dada por:

$$v_i^{k+1} = v_i^k + \alpha (\rho_i^k)^{1-a_i^k} (x^k - v_i^k) \quad (2.7)$$

Onde: ρ_i^k é o índice de compatibilidade da entrada x^k com o centro v_i^k ; a_i^k o índice de alerta do grupo i nos instantes $k= 1, 2, 3, \dots$ e α a taxa de aprendizagem.

A cada nova observação x^k o algoritmo de agrupamento participativo atualiza a estrutura de grupos utilizando os índices ρ_i^k e a_i^k . No algoritmo é definido o limiar $\tau \in [0,1]$ para o índice de alerta a_i^k . Um novo grupo é criado se qualquer $a_i^k > \tau$, isto é, se qualquer um dos índices de alerta é violado. Por outro lado, se não houver esta violação o índice de compatibilidade ρ_i^k é utilizado como critério para atualização dos parâmetros do grupo v_i^k mais compatível com a entrada x^k .

Outro mecanismo previsto no algoritmo de agrupamento participativo é a verificação de redundância de grupos. O objetivo é fundir dois grupos quaisquer que apresentem regiões comuns de alcance. A verificação é feita utilizando conceitos de compatibilidade análogos aos do índice de compatibilidade ρ_i^k demonstrados anteriormente para x^k em relação a v_i^k . Dados dois centros de grupos v_i^k e v_j^k , o índice de compatibilidade $\rho_{ij}^k \in [0,1]$ entre estes centros será:

$$\rho_{ij}^k = \rho_{ij}^k (v_i^k - v_j^k) = 1 - d(v_i^k - v_j^k) \quad (2.8)$$

Quanto mais próximo de 1 for ρ_{ij}^k , maior será a redundância dos centros. No algoritmo de agrupamento participativo é definido o limiar $\lambda \in [0,1]$ para o índice de

compatibilidade ρ_{ij}^k entre dois centros i e j . Estes centros são considerados redundantes se $\rho_{ij}^k \geq \lambda$, o que significa $d(v_i^k - v_j^k) > (1 - \lambda)$. Na fusão dos grupos é redefinido um novo centro v_r^k a partir da combinação dos centros v_i^k e v_j^k .

Vale salientar que o algoritmo de agrupamento participativo é não supervisionado e o seu comportamento é definido pela taxa de aprendizagem α , pela sensibilidade do índice de alerta β , pelo limiar do índice de alerta τ e pelo limiar do índice de compatibilidade entre centros λ . Enquanto α e β definem como os centros serão modificados, τ e λ estão associados ao tamanho e ao número de grupos [LIM 08].

3. Desenvolvimento do Novo Algoritmo

3.1 Modificações no AAP Original

Para facilitar a análise do *Algoritmo de Agrupamento Participativo Modificado (AAPM)*, usaremos neste capítulo somente exemplos de modelo bidimensional, de tal maneira que se possa visualizar no plano cartesiano a aplicação das definições aqui tratadas. Assim, todo dado de entrada é x_n (sendo $n = 2$), composto então pelo par ordenado (x_1, x_2) , correspondendo às variáveis x e y do plano cartesiano. O algoritmo, no entanto, é preparado para trabalhar com problemas multidimensionais, com 4, 6, 8 ou mais variáveis.

A primeira tarefa do AAPM é calcular os índices de compatibilidade ρ^k do dado de entrada x^k em relação aos centros dos grupos já identificados. A distância Euclidiana d^k é utilizada como métrica para o cálculo dos índices de compatibilidade, conforme apresentado na equação (2.3). Antes de calcular d^k o algoritmo faz dois importantes tratamentos nos dados.

O primeiro é normalizar os dados de entrada usando a equação: $ValorNormal = [(ValorUnEng - ValorMin) / (ValorMax - ValorMin)]$. Esta normalização é importante para que não haja erro de agrupamento nos casos onde a diferença entre as ordens de grandeza das variáveis seja grande (exemplo: um par tensão/corrente, sendo $v = 220$ V e $i = 5$ A). O valor máximo e o valor mínimo usados para a realização desta transformação são calculados pelo programa a partir da população de amostras.

O segundo é encontrar o maior raio de ação dos grupos já identificados (R_{max}), cujo valor será usado para dividir d^k e outros parâmetros de controle do algoritmo. Isto faz com que os cálculos de agrupamento sejam relativizados a cada iteração em função de R_{max} . O raio de ação de um dado grupo é definido como a metade da distância entre seu centro e o centro do grupo mais próximo, conforme pode ser visto no exemplo da Figura 3.1.

Uma modificação realizada no algoritmo de agrupamento participativo original foi o modo de se calcular os centros dos grupos, representados pela equação (2.7). No AAPM as amostras de um mesmo grupo são armazenadas em uma fila de dados do tipo FIFO (first in – first out), formando uma janela de tamanho ω . O tamanho desta janela deve ser fixado pelo usuário em função do peso que se quer dar à

participação do dado de entrada x^k no ajuste dos centros, em outras palavras, na participação do aprendizado (um valor usual de ω é 100). O centro de um grupo é representado pela média aritmética simples das amostras deste grupo, calculadas para cada variável. Para um grupo i qualquer, o seu centro c será calculado conforme mostrado na equação abaixo.

$$c^i = \left(\frac{1}{t} \sum_{m=1}^t x_1^m, \frac{1}{t} \sum_{m=1}^t x_2^m, \dots, \frac{1}{t} \sum_{m=1}^t x_n^m \right) \quad (3.1)$$

Onde: i é o número do grupo, t é o número de amostras do grupo e n o número de variáveis que compõem as amostras (dimensão do dado de entrada).

Os dados que compõem aos quatro grupos do gráfico da Figura 3.1 são mostrados na Tabela 3.1 e serão usados para facilitar o entendimento dos conceitos apresentados anteriormente. Observe que neste exemplo didático todos os grupos possuem seis amostras de dados compondo suas populações.

Tabela 3.1 – Dados de quatro grupos distintos.

Nº da Amostra	Grupo 1		Grupo 2		Grupo 3		Grupo 4	
	X ₁	X ₂						
1	2,2	5,5	5,2	3,2	2,1	0,8	4,3	0,8
2	1,7	6,5	5,1	3,3	1,9	1,2	4,1	1,2
3	2,3	5,7	4,8	2,8	1,8	0,9	3,7	0,6
4	1,5	6,4	4,5	3,5	2,2	1,1	3,9	1,4
5	1,9	5,3	5,5	2,7	1,7	0,6	3,6	1,3
6	2,4	6,6	4,9	2,5	2,3	1,4	4,4	0,7
Média simples	2,0	6,0	5,0	3,0	2,0	1,0	4,0	1,0

Na Tabela 3.2 têm-se então os quatro centros dos grupos que foram calculados conforme equação 3.1.

Tabela 3.2 – Centros dos grupos.

Centro	Variável X	Variável Y
C1	2,0	6,0
C2	5,0	3,0
C3	2,0	1,0
C4	4,0	1,0

Calculando-se os raios entre os grupos, teremos:

- Grupo 1

$$R_{12} = \frac{\sqrt{(2-5)^2 + (6-3)^2}}{2} = 2,12 \quad (\text{grupo 1 em relação ao grupo 2})$$

$$R_{13} = \frac{\sqrt{(2-2)^2 + (6-1)^2}}{2} = 2,50 \quad (\text{grupo 1 em relação ao grupo 3})$$

$$R_{14} = \frac{\sqrt{(2-4)^2 + (6-1)^2}}{2} = 2,69 \quad (\text{grupo 1 em relação ao grupo 4})$$

Pelo conceito adotado neste trabalho o raio de ação do grupo 1 é $R_{12}=2,12$, porque é relativo ao grupo que está mais próximo dele (o menor dos raios calculados).

- Grupo 2

$$R_{21} = R_{12} = 2,12 \quad (\text{grupo 2 em relação ao grupo 1})$$

$$R_{23} = \frac{\sqrt{(5-2)^2 + (3-1)^2}}{2} = 1,80 \quad (\text{grupo 2 em relação ao grupo 3})$$

$$R_{24} = \frac{\sqrt{(5-4)^2 + (3-1)^2}}{2} = 1,19 \quad (\text{grupo 2 em relação ao grupo 4})$$

Assim o raio de ação do grupo 2 é $R_{24}=1,19$.

- Grupo 3

$$R_{31} = R_{13} = 2,50 \quad (\text{grupo 3 em relação ao grupo 1})$$

$$R_{32} = R_{23} = 1,80 \quad (\text{grupo 3 em relação ao grupo 2})$$

$$R_{34} = \frac{\sqrt{(2-4)^2 + (1-1)^2}}{2} = 1,00 \quad (\text{grupo 3 em relação ao grupo 4})$$

Assim o raio de ação do grupo 3 é $R_{34}=1,00$.

- Grupo 4

$$R_{41} = R_{14} = 2,69 \quad (\text{grupo 4 em relação ao grupo 1})$$

$$R_{42} = R_{24} = 1,19 \quad (\text{grupo 4 em relação ao grupo 2})$$

$$R_{43} = R_{34} = 1,00 \quad (\text{grupo 4 em relação ao grupo 3})$$

Assim o raio de ação do grupo 4 é $R_{43} = 1,00$.

- R_{max} , que é o maior de todos os raios calculados

$$R_{max} = R_{14} = R_{41} = 2,69 \quad (\text{grupo 1 em relação ao grupo 4})$$

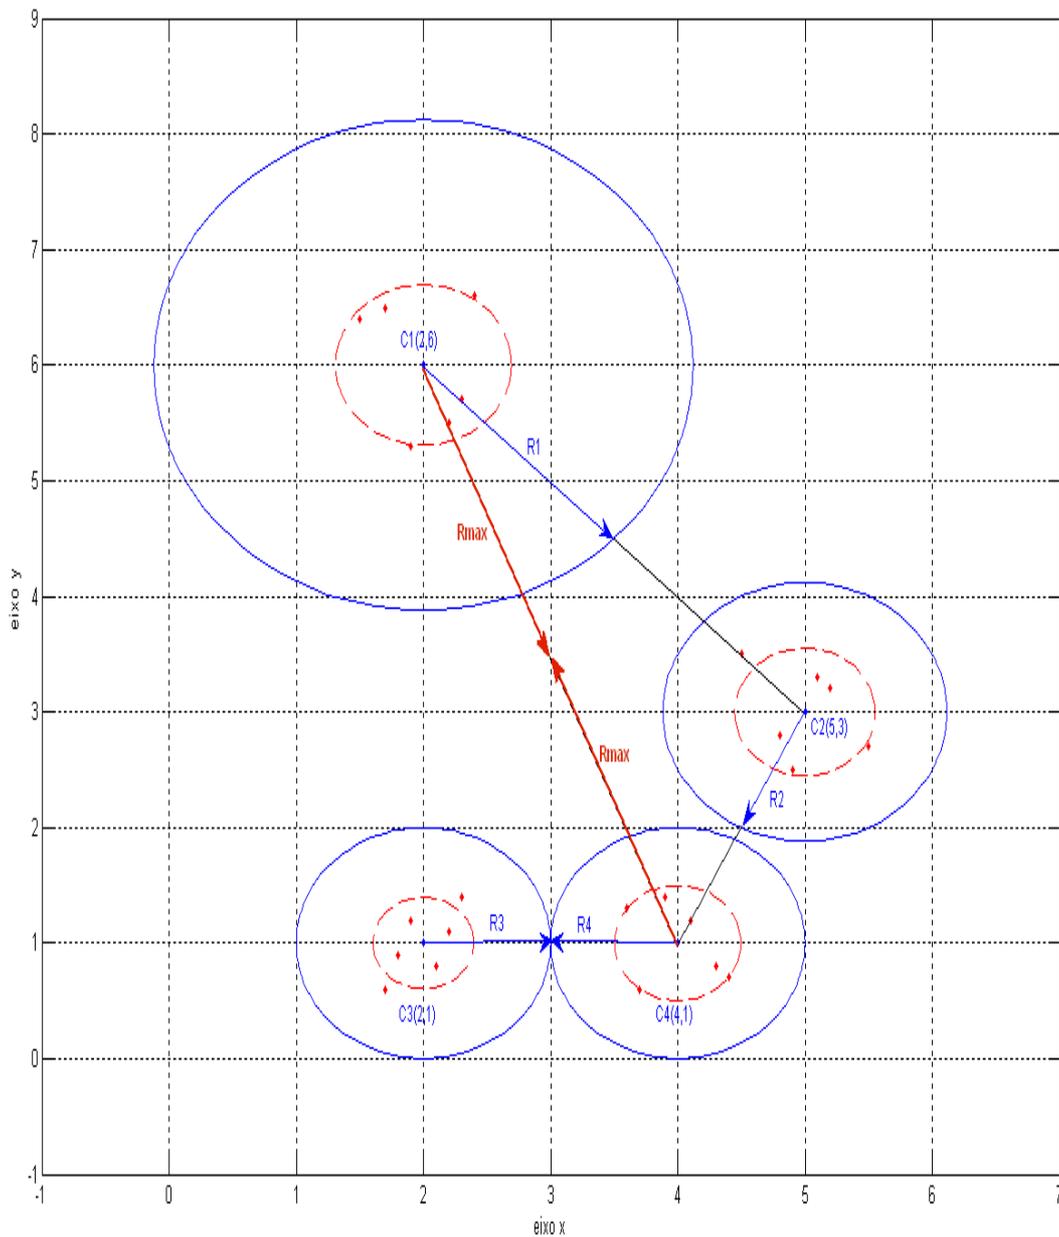


Figura 3.1 – Raios de ação dos grupos.

A partir das amostras armazenadas nas filas de dados FIFO, calcula-se em cada grupo o vetor de desvio padrão s das variáveis. Para um grupo i qualquer o vetor s será calculado conforme mostrado na equação abaixo.

$$s^i = \left(\sqrt{\frac{1}{t-1} \sum_{m=1}^t (x_1^m - c_1^i)^2}, \sqrt{\frac{1}{t-1} \sum_{m=1}^t (x_2^m - c_2^i)^2}, \dots, \sqrt{\frac{1}{t-1} \sum_{m=1}^t (x_n^m - c_n^i)^2} \right) \quad (3.2)$$

Onde: i é o número do grupo, c é o centro do grupo, t é o número de amostras do grupo e n o número de variáveis que compõem as amostras (dimensão do dado de entrada).

Em seguida calcula-se a média aritmética simples \bar{s} do vetor de desvio padrão s calculado a partir da equação 3.2. Este valor será utilizado nos testes de agrupamento. Para um grupo i qualquer o valor de \bar{s} será calculado conforme mostrado na equação abaixo.

$$\bar{s}^i = \frac{1}{n} \sum_{m=1}^n s_m^i \quad (3.3)$$

Onde: i é o número do grupo e n o número de variáveis que compõem as amostras (dimensão do vetor s).

Tomando os dados do grupo 1 da Tabela 3.1 para exemplificar o uso das equações 3.2 e 3.3, teremos:

$$s_1^1 = \sqrt{\frac{1}{6-1} [(2,2-2)^2 + (1,7-2)^2 + (2,3-2)^2 + (1,5-2)^2 + (1,9-2)^2 + (2,4-2)^2]}$$

$$s_1^1 = 0,36$$

$$s_2^1 = \sqrt{\frac{1}{6-1} [(5,5-6)^2 + (6,5-6)^2 + (5,7-6)^2 + (6,4-6)^2 + (5,3-6)^2 + (6,6-6)^2]}$$

$$s_2^1 = 0,57$$

$$\bar{s}^1 = \frac{0,36 + 0,57}{2} = 0,46$$

Outra inovação do AAPM é a introdução do conceito de raio mínimo (R_{min}). O $R_{min} \in [0,1]$ define a região de compatibilidade de cada grupo em torno de seus respectivos centros. Ele é a distância euclidiana mínima observada pelo algoritmo na decisão de se criar um novo grupo. Isto significa que, dada uma nova amostra x^k e calculadas todas as distâncias euclidianas d_i^k em relação aos centros dos grupos v_i^k , se pelo menos uma dessas distâncias for menor que R_{min} , então esta nova amostra não irá gerar um novo grupo. Em síntese, qualquer dado de entrada que esteja dentro da região de compatibilidade de um ou mais grupos (definida por R_{min}), será considerada como pertencente a um destes grupos.

O R_{min} tem efeito direto sobre o processo de agrupamento e evita a criação desnecessária de grupos. Isto fica evidente na inicialização do agrupamento para uma sequência de amostras. Obviamente a primeira amostra ($k=1$), será o centro do primeiro grupo identificado. Com o algoritmo original, sem o conceito de R_{min} , a segunda amostra ($k=2$) representará o centro de um novo grupo porque não há como prever a dispersão dos dados. No AAPM estas duas amostras irão formar um único grupo se a distância euclidiana entre elas for menor que R_{min} .

Observa-se aqui que o valor de R_{min} é definido por um conhecimento a priori do processo a ser monitorado, ou seja, exige-se um conhecimento prévio do operador sobre o comportamento do sistema para se determinar o grau de variabilidade a ser permitido (que é o valor de R_{min}), sem que um novo grupo seja criado. O AAPM foi desenvolvido para trabalhar também quando não se tem ideia da ordem de grandeza de R_{min} . Basta fazer R_{min} igual a zero para que o AAPM funcione conforme o algoritmo original, similar ao limiar do índice de alerta τ .

Uma vez calculados os índices de compatibilidade, a tarefa seguinte do AAPM é verificar se o dado de entrada x^k pertence a algum grupo já criado (identificado pelo algoritmo), ou deverá formar um novo grupo. Conforme descrito no item 2.2, o algoritmo de agrupamento participativo original testa os índices de alerta para tomar a decisão de criar ou não um novo grupo (cria se $a_i^k > \tau$). Já o AAPM verifica somente os índices de compatibilidade calculados para x^k . Um novo grupo será criado se quaisquer das duas condições descritas a seguir forem satisfeitas.

- Se $R_{min} > 0$, então o grupo será criado se, para todo grupo $i = 1, 2, 3, \dots$, ocorrer $\rho_i^k < 1 - R_{min}$, o que significa $d_i^k > R_{min}$.
- Se $R_{min} = 0$, então o grupo será criado se, para todo grupo $i = 1, 2, 3, \dots$, ocorrer $\rho_i^k < 1 - (1,5\bar{s}_i^k / R_{max}^k)$ ou $\rho_i^k < 0,8$, o que significa $d_i^k > (1,5\bar{s}_i^k / R_{max}^k)$ ou $d_i^k > 0,2$.

Caso nenhuma das condições anteriores seja satisfeita, a entrada x^k será armazenada no início da fila de dados FIFO referente ao grupo de maior compatibilidade, sendo excluída desta fila a entrada mais antiga.

Após a atualização ou criação de um grupo, o passo seguinte do AAPM é minimizar a quantidade de grupos, verificando a compatibilidade entre eles e fazendo a fusão dos grupos redundantes. Para isto são calculados os índices de compatibilidade entre os grupos utilizando a mesma metodologia apresentada anteriormente para o dado de entrada x^k , porém aplicada de grupo para grupo. Ocorrerá a fusão de dois grupos i e j se quaisquer das duas condições descritas a seguir forem satisfeitas.

- Se $R_{min} > 0$, então os grupos i e j serão fundidos se ocorrer $\rho_{ij}^k > 1 - 0,75R_{min}$, o que significa, $d_{ij}^k < 0,75R_{min}$.
- Se $R_{min} = 0$, então os grupos i e j serão fundidos se ocorrer $\rho_{ij}^k > 1 - (1,5\bar{s}_i^k \bar{s}_j^k / 2R_{max}^k)$ ou $\rho_{ij}^k > 0,9$, o que significa $d_{ij}^k < (1,5\bar{s}_i^k \bar{s}_j^k / 2R_{max}^k)$ ou $d_{ij}^k < 0,1$.

Uma vez identificados os grupos que serão fundidos, o algoritmo compõe uma nova fila de dados FIFO copiando alternadamente os dados das filas de cada grupo, até que o limite máximo da janela ω seja atingido ou, antes disso, as duas filas FIFO dos grupos tenham acabado. Em seguida o grupo j é excluído e os valores v_i^k e \bar{s}_i^k são atualizados.

Outro novo conceito introduzido no AAPM é a existência de dois tipos de grupos: os grupos *candidatos* e os grupos *consolidados*. Os grupos candidatos são aqueles grupos que ainda não alcançaram um número mínimo de amostras μ suficiente para serem considerados consistentes. Este mecanismo funciona como um filtro e tem o objetivo de aumentar a robustez do algoritmo, minimizando o efeito dos *outliers* (ruídos). Ao ser criado, o grupo é imediatamente rotulado como grupo candidato e passa

à condição de grupo consolidado quando atinge o valor de μ . Sugere-se que o parâmetro μ do AAPM seja configurado pelo usuário com valor pelo menos igual a 3, pois em um grupo com três amostras os valores calculados de média aritmética e desvio padrão já têm boa representatividade.

Após a atualização da estrutura dos grupos, com a fusão dos grupos redundantes, a tarefa seguinte do AAPM é o controle dos grupos candidatos. Este controle é realizado monitorando-se os índices de alerta a_i^k , calculados com base nas relações entre o número de amostras do grupo, o número de entradas x^k decorridas desde a última amostra classificada para o grupo e o tamanho da janela ω . A equação abaixo mostra como é esta relação.

$$a_i^k = \left\{ \left(\frac{\mu}{NAG_i^k} \right)^{\left(\frac{NED_i^k}{\omega} \right)} - 0.5 \right\} \quad (3.4)$$

Onde: $a_i^k \in [0,1]$ é o índice de alerta do grupo i no instante k , $\mu > 0$ é o n° mínimo de amostras, $NAG_i^k > 0$ é o n° de amostras do grupo i , $NED_i^k \geq 0$ é o n° de entradas decorridas desde a última classificação de amostra para o grupo i e $\omega > 0$ é o tamanho da janela de amostras.

Uma vez calculados os índices de alerta, o algoritmo testa estes valores e exclui todos os grupos cujo respectivo a_i^k seja maior que 0,75.

Para melhor entendermos a equação (3.3), vamos analisar o comportamento de a_i^k fixando-se $\mu = 3$ e $\omega = 100$. A Figura 3.2 mostra quatro simulações de a_i^k em função de NED , correspondendo a quatro valores distintos de NAG . Independentemente do valor de NAG^k , verifica-se que no instante da criação de um grupo o valor de $a_i^k = 0,5$, pois $NED^k = 0$. É importante salientar que o algoritmo foi desenvolvido de tal forma que no instante em que mais uma amostra é acrescentada a um grupo candidato o seu contador de NED é reinicializado.

Para $NAG = 1$ (curva em vermelho), o grupo será excluído após 21 entradas consecutivas sem que nenhuma amostra seja associada a ele, pois neste instante $NED^k = 21$ e $a^k = 0,7595$. Pode-se verificar facilmente que um grupo candidato com $NAG = 2$ será excluído para NED aproximadamente igual a 55.

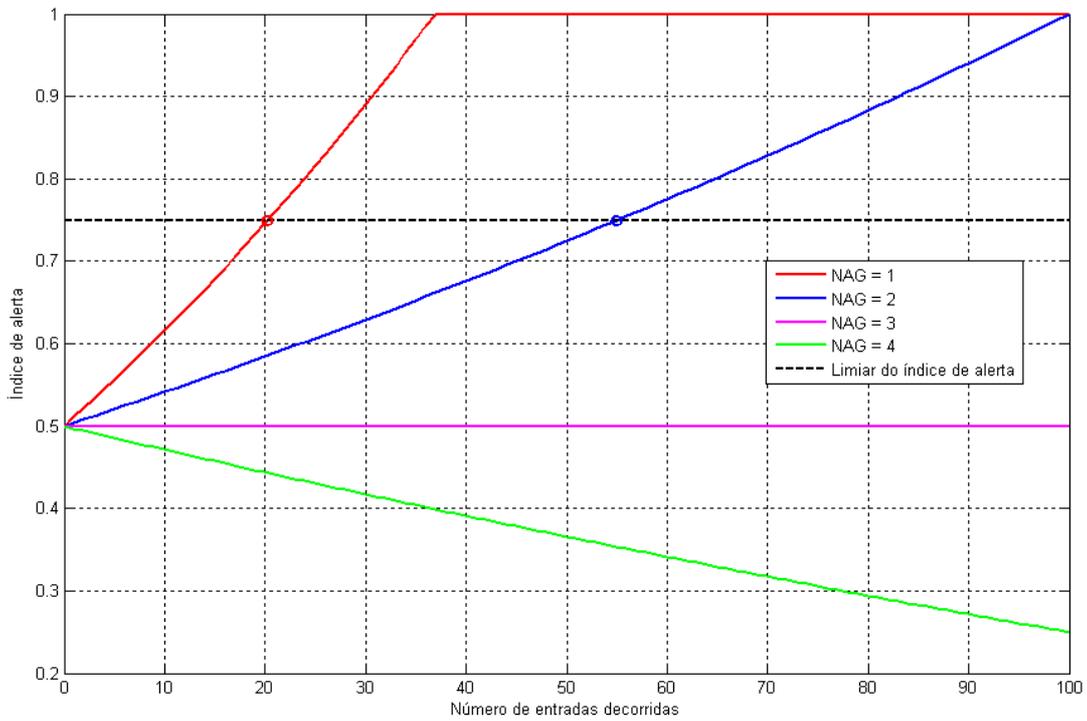


Figura 3.2 – Comportamento de a^k para diferentes valores de NAG

3.2 Influência do R_{min} no Agrupamento de Dados

A seguir será mostrado de forma didática como o uso de R_{min} torna ágil o processo de gerenciamento dos grupos (criação e fusão). Na simulação mostrada a seguir foi criada em MatLab uma população de 200 indivíduos dividida em 4 grupos com centros bem distintos. Os indivíduos são compostos por 2 variáveis (x e y), e foram gerados com um fator de espalhamento randômico em torno do centro a que pertencem. Foi criado também um vetor de mesmo tamanho da população no qual é registrado o número do grupo ao qual pertence cada indivíduo.

A população foi criada de tal forma que inicialmente é apresentada ao AAPM um conjunto de indivíduos do grupo 1, depois um conjunto de indivíduos do grupo 2, em seguida do grupo 3 e por último do grupo 4. A partir daí os indivíduos restantes da população são preenchidos aleatoriamente quanto à origem do grupo. A Figura 3.3 mostra a classificação final da população.

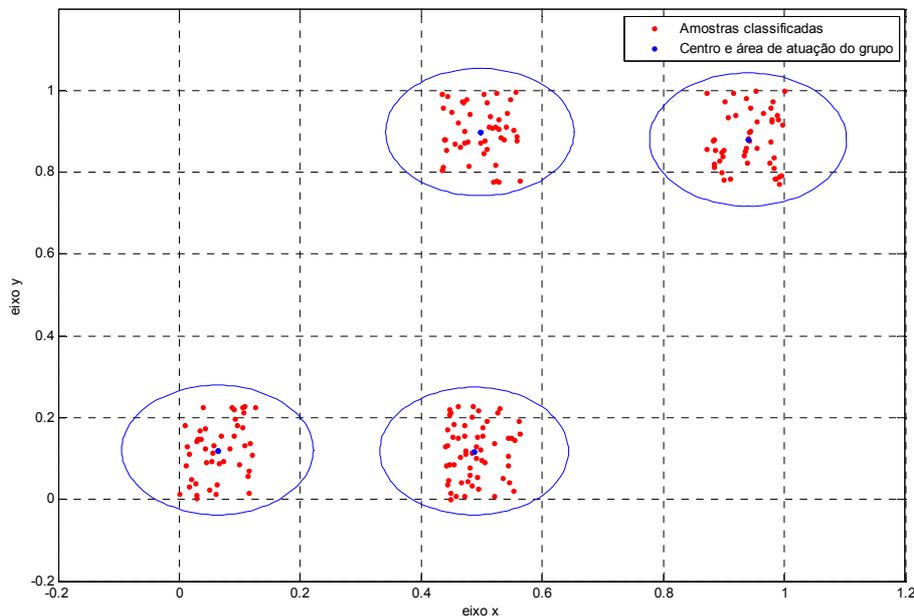


Figura 3.3 – Agrupamento de dados com duas variáveis e quatro grupos.

A Figura 3.4 mostra o gráfico de agrupamento da população gerado pelo AAPM após a apresentação de 10 indivíduos, sendo $R_{min} = 0,25$. Observe que foi criado um único grupo consolidado (grupo 1).

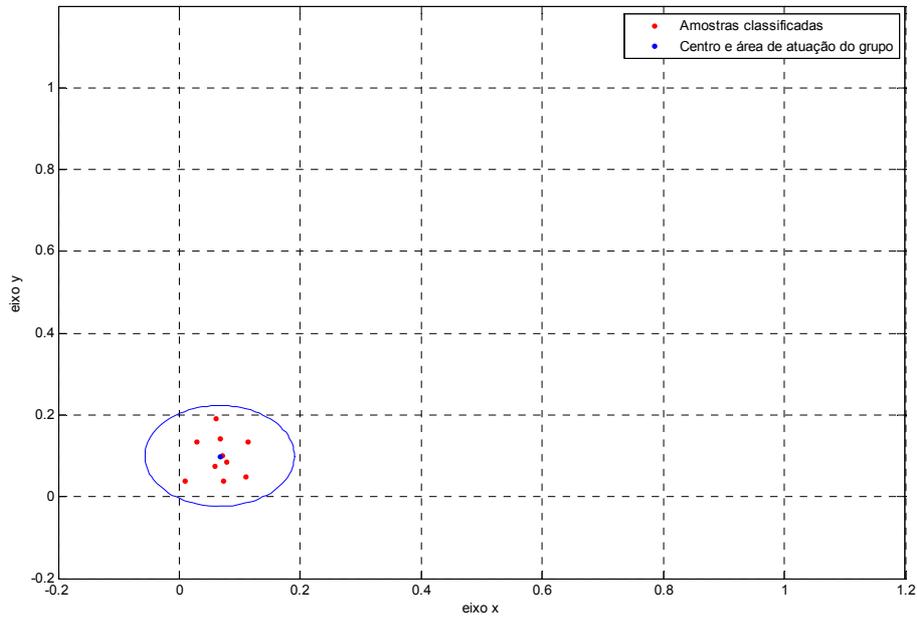


Figura 3.4 – Agrupamento de dados com R_{min} maior que zero.

A Figura 3.5 mostra o gráfico de agrupamento da população gerado pelo AAPM após a apresentação de 9 indivíduos, sendo $R_{min} = 0$. Neste caso foram criados 8 grupos candidatos, sendo um deles formado pela fusão de dois grupos..

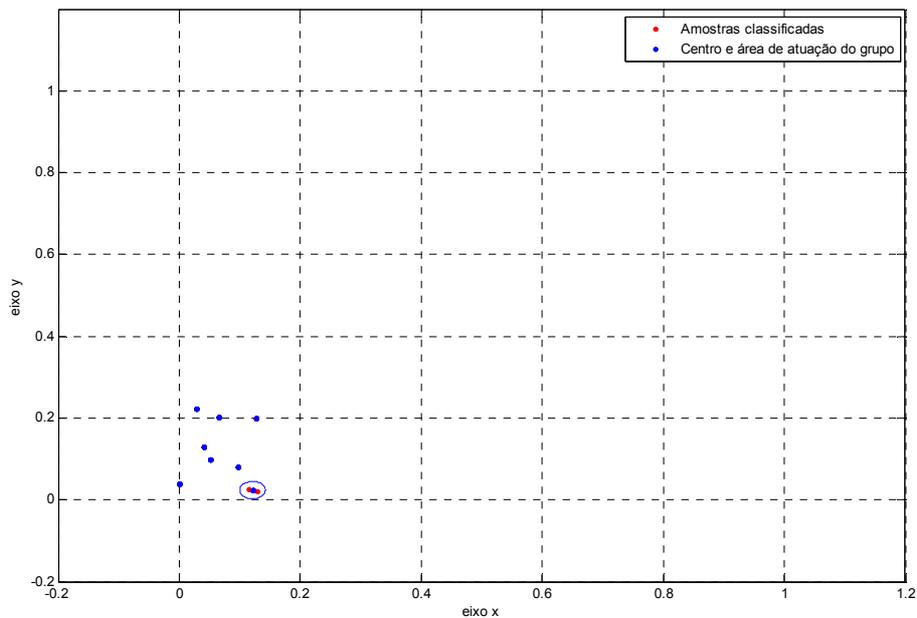


Figura 3.5 – Agrupamento de dados com R_{min} nulo (quadro 1).

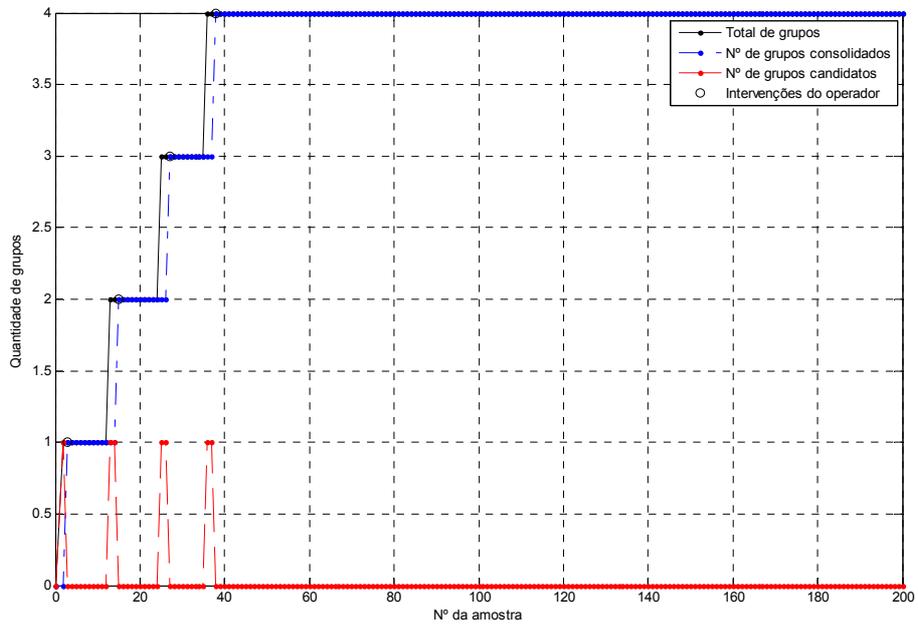


Figura 3.7 – Evolução do controle de grupos com R_{\min} maior que zero.

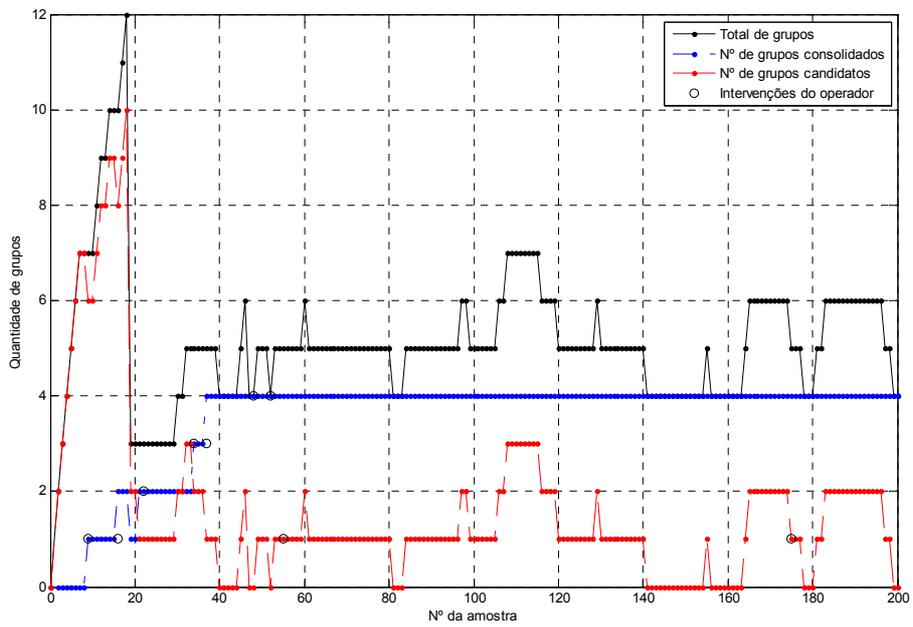


Figura 3.8 – Evolução do controle de grupos com R_{\min} nulo.

3.3 Variação da Taxa de Aprendizagem no AAPM

Como foi dito anteriormente neste capítulo (seção 3.2), no AAPM as amostras de um mesmo grupo são armazenadas em uma fila de dados formando uma janela de tamanho ω . O tamanho desta janela deve ser fixado pelo usuário em função do peso que se quer dar à participação do dado de entrada x^k no ajuste dos centros (aprendizado). Pode-se comprovar matematicamente que o parâmetro ω tem o mesmo efeito da taxa básica de aprendizagem α .

Tomemos a definição de média amostral indicada na equação abaixo.

$$\begin{aligned}\mu^k &= \frac{1}{k} \sum_{i=1}^k x^i \\ \mu^k &= \frac{1}{k} \left(\sum_{i=1}^{k-1} x^i + x^k \right)\end{aligned}\quad (3.5)$$

A partir da definição anterior podemos escrever a equação abaixo.

$$\begin{aligned}\mu^{k-1} &= \frac{1}{k-1} \sum_{i=1}^{k-1} x^i \\ \sum_{i=1}^{k-1} x^i &= (k-1)\mu^{k-1}\end{aligned}\quad (3.6)$$

Substituindo a equação (3.6) em (3.5), temos:

$$\begin{aligned}\mu^k &= \frac{1}{k} \left((k-1)\mu^{k-1} + x^k \right) \\ \mu^k &= \left(1 - \frac{1}{k} \right) \mu^{k-1} + \frac{1}{k} x^k\end{aligned}\quad (3.7)$$

Definindo-se $\alpha = \frac{1}{k}$ e substituindo-o na equação (3.7), tem-se:

$$\mu^k = (1 - \alpha)\mu^{k-1} + \alpha x^k \quad (3.8)$$

A partir dos conceitos sobre o AAPM apresentados até aqui, podemos verificar que o máximo valor de α é 1 (um), e ele ocorre quando se cria um grupo candidato, pois neste momento o número de amostras do grupo é 1 (o próprio dado de entrada x^k). Por outro lado, o mínimo valor de α nunca poderá ser igual a zero, uma vez que o número máximo de amostras de um grupo está limitado pelo tamanho da janela ω .

Neste caso quando a fila de dados está cheia temos $\alpha = 1/\omega$. Portanto se ω tender para o infinito, α tenderá para zero, mas nunca chegará a zero.

Um grupo consolidado terá o valor de α variando do momento em que ele é criado (quando o grupo candidato alcança o número mínimo de amostras μ), até o momento em que o número de amostras fica igual ao tamanho da janela ω . A partir deste instante um novo dado de entrada classificado para este grupo acarretará a exclusão do dado mais antigo da fila FIFO, mantendo o número de amostras do grupo igual ao tamanho ω e por consequência a taxa de aprendizagem constante.

Uma vez que $\mu < \omega$, verificamos que:

- $\frac{1}{\mu-1} \leq \alpha \leq 1$ para um grupo candidato.
- $\frac{1}{\omega} \leq \alpha \leq \frac{1}{\mu}$ para um grupo consolidado.

A Figura 3.9 mostra a variação da taxa de aprendizagem α de um grupo em quatro condições de simulação: $\omega_1 = 5$, $\omega_2 = 10$, $\omega_3 = 20$ e $\omega_4 = 50$. Em todas elas foi usado $\mu = 3$ e número de amostras totais de entrada igual a 60.

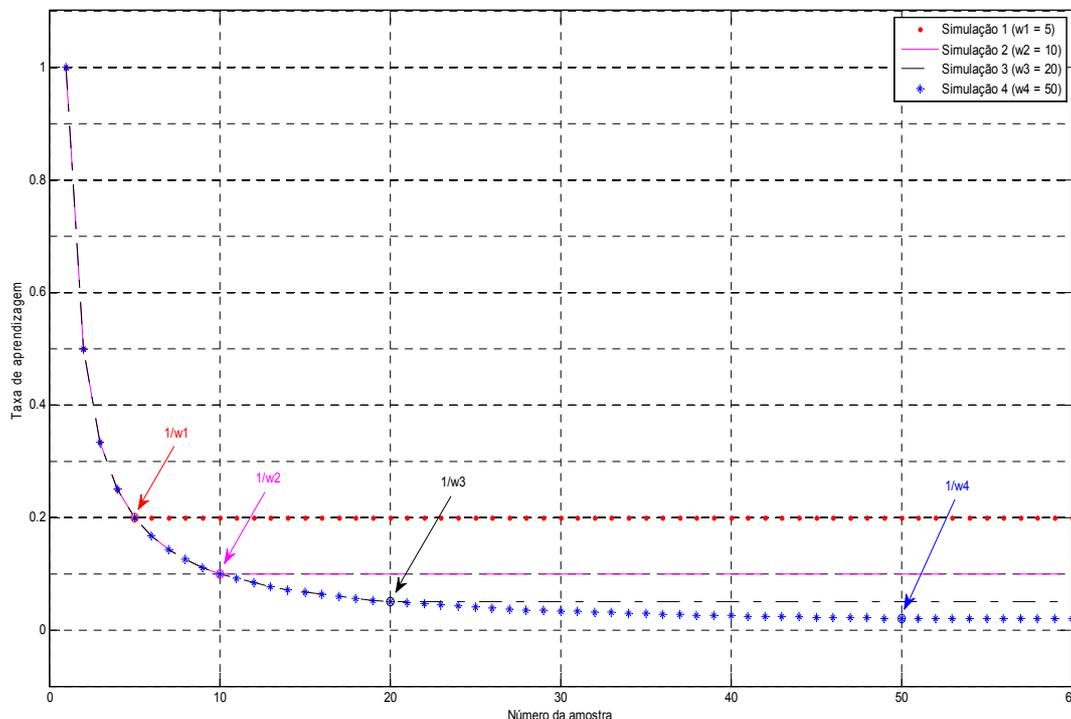


Figura 3.9 – Variação da taxa de aprendizagem.

Para uma janela $\omega = 50$ teremos uma taxa de aprendizagem final $\alpha = 0,02$, ou seja, conforme equação (3.8) o dado de entrada x^k terá participação de 2% no ajuste do centro. É interessante observarmos que se dobrarmos o esforço computacional do programa, dobrando o tamanho desta janela ($\omega = 100$), a participação do dado de entrada x^k no ajuste do centro passará para 1%, o que não é uma mudança significativa. Portanto, deve-se ter cautela na definição do tamanho desta janela de dados observando-se sempre a relação custo versus benefício.

3.4 Interface com o Operador Para Rotulagem dos Grupos

Uma tarefa adicional foi desenvolvida no AAPM com o objetivo de gerenciar a interface com o operador. No momento da detecção de uma nova condição de operação, o que acontece quando há a transformação de um grupo candidato em consolidado, uma janela é apresentada ao operador solicitando a sua intervenção. Através de uma múltipla escolha o operador deve indicar qual a opção que melhor descreve o grupo. É importante ressaltar que, por critério puramente de projeto, o AAPM classifica automaticamente como grupo 0 (zero) toda amostra que no momento da sua avaliação pertença a um grupo candidato qualquer.

Decidiu-se também apresentar nesta janela do operador, a título de informação, as coordenadas da amostra a ser classificada e o número do grupo gerado durante sua criação, ou conhecido a priori por meio de análise dos dados quando for o caso. A Figura 3.10 mostra a janela de interface do AAPM com o operador para o exemplo mostrado neste capítulo (seção 3.2).

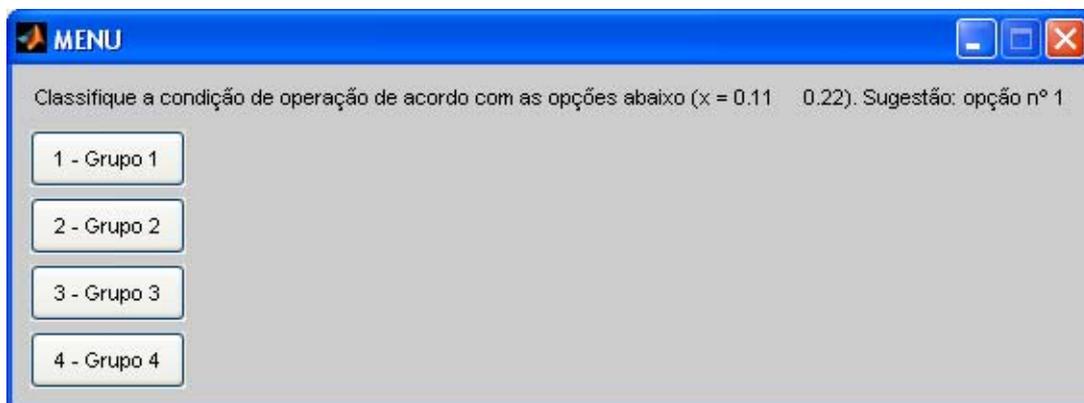


Figura 3.10 – Janela para intervenção do operador.

3.5 Pseudo Código do AAPM

```
01 Carrega População de dados de entrada
02 Normaliza População de dados de entrada
03 Entra com o valor de  $R_{min} \in [0,1]$ 
04 Inicializa variáveis de controle do AAPM:
05    $NumIndivPop$  = tamanho da População de dados de entrada
06    $NumVar$  = dimensão do dado de entrada  $x^k$ 
07    $\mu$  = número mínimo de amostras válidas ( $\geq 3$ )
08    $\omega$  = tamanho da janela de amostras = 100
09    $c$  = número total de grupos identificados (candidatos + consolidados) = 1
10    $v$  = matriz com os centros dos grupos = 1º dado de entrada da População
11    $s$  = vetor de desvio padrão dos centros = zeros( $c,1$ )
12    $p$  = vetor de índices de compatibilidade dos centros = zeros( $c,1$ )
13    $NAG$  = vetor de contadores do número de amostras dos grupos = ones( $c,1$ )
14    $NED$  = vetor de contadores do número de entradas decorridas dos grupos = zeros( $c,1$ )
15    $FilasGrupos$  = array da fila de dados classificados = zeros( $\omega, NumVar, c$ )
16    $TiposOperação$  = matriz de classificação dos grupos consolidados = zeros( $1, NumVar+1$ )
17 Para  $k = 1$  Até  $k = NumIndivPop$  Faz
18   Calcula  $R_{max}$ 
19   Calcula vetor de índices de compatibilidade  $p$  do dado de entrada  $x^k$ 
20   Define  $CriaGrupo = 1$ 
21   Para  $i = 1$  Até  $i = c$  Faz
22     Se ( $R_{min} > 0$  E  $p(i) > 1 - R_{min}$ ) Ou ( $R_{min} = 0$  E ( $p(i) > 1 - (1.5 * s(i) / R_{max})$  Ou
23        $p(i) > 0.8$ )) Então
24       Define  $CriaGrupo = 0$ 
25     Fim Se
26   Fim Para
27   Se  $CriaGrupo = 1$  Então
28     Aumenta o array  $FilasGrupos$  para um novo grupo e armazena  $x^k$  nele
29     Aumenta a matriz  $v$  acrescentando nela o dado de entrada  $x^k$ 
30     Aumenta o vetor  $s$  fazendo  $s = [s, zeros(1,1)]$ 
31     Aumenta o vetor  $p$  fazendo  $p = [p, ones(1,1)]$ 
32     Aumenta o vetor  $NAG$  fazendo  $NAG = [NAG, ones(1,1)]$ 
33     Aumenta o vetor  $NED$  fazendo  $NED = [NED, zeros(1,1)]$ 
34     Acrescenta o novo grupo ao vetor  $TiposOperação$  indicando-o como candidato
35   Senão
36     Obtém o grupo  $g(p_{max})$  mais compatível com o dado de entrada  $x^k$ 
37     Atualiza o array  $FilasGrupos$  armazenando  $x^k$  na fila do grupo  $g(p_{max})$ 
38     Calcula o novo centro do grupo  $g(p_{max})$  usando os dados não nulos da sua fila
39     Atualiza a matriz  $v$  com o novo centro do grupo  $g(p_{max})$ 
40     Calcula o novo desvio padrão do grupo  $g(p_{max})$  usando os dados não nulos da sua fila
41     Atualiza o vetor  $s$  com o novo desvio padrão do grupo  $g(p_{max})$ 
42     Incrementa o contador  $NAG$  do grupo  $g(p_{max})$ 
43     Se  $NAG$  do grupo  $g(p_{max}) = \mu$  Então
44       Solicita ao operador a classificação do novo tipo de operação
45       Atualiza o vetor  $TiposOperação$  indicando grupo  $g(p_{max})$  como consolidado
46     Fim Se
```

```

47     Reseta o contador NED do grupo  $g(p_{max})$ 
48     Incrementa os contadores NED dos grupos diferentes de  $g(p_{max})$ 
49     Fim Se
50     Define VerificaAgrup = 1
51     Enquanto VerificaAgrup = 1 E  $c > 2$  Faz
52         Calcula vetor de índices de compatibilidade pij entre todos os centros definidos em v
53         Define FundeGrupos = 0
54         Define n = 1
55         Para  $i = 1$  Até  $i = c-1$  Faz
56             Para  $j = i+1$  Até  $j = c$  Faz
57                 Se ( $R_{min} > 0$  E  $p_{ij}(n) > 1-0.75*R_{min}$ ) Ou
58                 ( $R_{min} = 0$  E ( $p_{ij}(n) > 1-(1.5*(s(i)+s(j))/(2*R_{max}))$ ) Ou  $p(i) > 0.9$ ) Então
59                     Define FundeGrupos = 1
60                 Fim Se
61                 Se FundeGrupos = 1 Então
62                     Mescla as filas de dados dos grupos i e j obedecendo ao limite da janela w
63                     Atualiza o grupo i do array FilasGrupos com a mescla de dados
64                     Calcula o novo centro do grupo i
65                     Atualiza a matriz v com o novo centro do grupo i
66                     Calcula o novo desvio padrão do grupo i
67                     Atualiza o vetor s com o novo desvio padrão do grupo i
68                     Atualiza o contador NAG do grupo i de acordo com o novo tamanho da fila
69                     Reseta o contador NED do grupo i
70                     Exclui o grupo j do array FilasGrupos
71                     Exclui o grupo j dos vetores v, s, p, NAG, NED e TiposOperação
72                 Senão
73                     Incrementa n
74                 Fim Se
75             Fim Para
76             Se FundeGrupos = 1 Então
77                 Sai do Loop “Para” (comando “break”)
78             Senão
79                 Se  $i = (c-1)$  Então
80                     Define VerificaAgrup = 0 (sai do loop “Enquanto”)
81                 Fim Se
82             Fim Se
83         Fim Para
84     Fim Enquanto
85     Calcula vetor de índices de alerta a
86     Para  $j = 1$  Até  $j = c$  Faz
87         Se  $a(j) \leq 0.75$  Então
88             Exclui o grupo j do array FilasGrupos
89             Exclui o grupo j dos vetores v, s, p, NAG e NED.
90         Fim Se
91     Fim Para
92 Fim Para

```

4. Aplicação do AAPM com Dados Simulados

4.1 Condições de Simulação

Nesta aplicação é feita a simulação de um motor de indução em ambiente computacional do software MatLab, onde o AAPM é usado para detecção e diagnóstico de falhas de operação deste motor. Esta simulação utiliza dados do modelo dinâmico de um motor de indução, modelo este que é baseado em um modelo de transitório de sétima ordem para máquinas de indução assimétricas. O modelo é capaz de simular a condição operacional normal do motor, assim como várias condições de falhas. Em [CAM 97] pode-se obter uma completa descrição do modelo dinâmico utilizado.

O modelo completo do motor de indução pressupõe uma fonte de alimentação elétrica trifásica (fases A, B e C), o motor de indução propriamente dito e uma carga mecânica. Para simular ruído nos dados de corrente e tensão foi acrescentado um ruído Gaussiano de 1% nas variáveis do modelo. As sete condições de operação mostradas na Tabela 4.1 foram simuladas em nossa aplicação.

Tabela 4.1 – Condições de Operação do motor de indução.

<i>Operação</i>	<i>Descrição</i>
1	Condição normal
2	Curto-circuito na fase A
3	Curto-circuito na fase B
4	Curto-circuito na fase C
5	Curto-circuito nas fases A e B
6	Curto-circuito nas fases A e C
7	Curto-circuito nas fases B e C

Os procedimentos e sequências para simulação das condições de operação mostradas na Tabela 4.1 foram os seguintes:

- O tempo total de simulação é de aproximadamente 155 segundos, incluindo o regime transitório da partida que gira em torno de 0,5 segundos. Após o transitório o motor é mantido em operação normal por 15 segundos.

- Em seguida a condição de operação n° 2 é mantida por 5 segundos e retornada à condição normal, que por sua vez é mantida por 4,6 segundos.
- O procedimento anterior é repetido para as condições de operação 3 a 7. A partir daí mais nove situações aleatórias de falha são simuladas, sempre com os mesmos tempos de duração indicados anteriormente.
- Os dados coletados do simulador foram as correntes e tensões *rms* das fases *A*, *B* e *C* ($I_A, I_B, I_C, V_A, V_B, V_C$), o instante de cada amostragem (t) e o número da operação em cada instante (Op). O intervalo entre amostragens é de 16,7 ms (60 Hz). Nesta matriz de dados apresentada ao AAPM foram excluídos os dados coletados no início da simulação, abrangendo todo o regime transitório e parte da condição normal.

A Figura 4.1 mostra a janela de interface do AAPM com o operador.

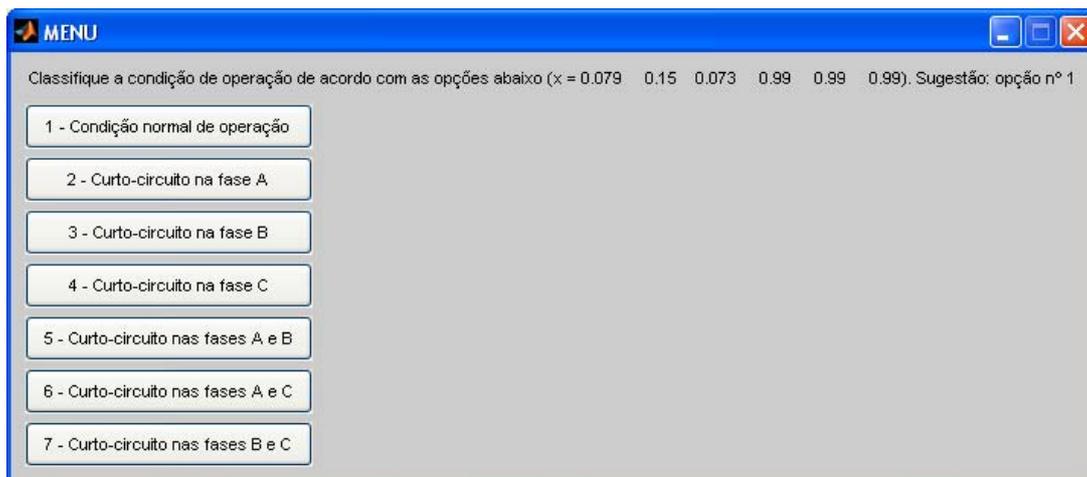


Figura 4.1 – Janela para rotulagem das condições de operação.

Assim como na aplicação do AAPM no controle de formação de laço, foram criados dois vetores (V_1 e V_2), com dimensões iguais ao número total de amostras. Durante a geração da massa de dados foi registrada em V_1 a condição de operação para cada ponto amostrado, conforme Tabela 4.1. Já em V_2 foram registrados pelo AAPM os resultados da classificação das amostras. Além das sete condições previstas em V_1 , encontra-se também em V_2 o valor 0 (zero) para indicar amostra não classificada.

A partir da comparação entre os vetores V_1 e V_2 foram gerados quatro indicadores:

- IP_1 (%) - Percentual de amostras não classificadas, isto é, amostras pertencentes a grupos candidatos.
- IP_2 (%) - Percentual de amostras classificadas, ou seja, amostras definidas pelo AAPM como pertencentes a um grupo qualquer, com classificação correta ou não.
- IP_{21} (%) – Percentual de acertos na classificação, que representa o percentual de coincidências entre os vetores V_1 e V_2 , tomando-se como base de 100% o indicador IP_2 .
- IP_{22} (%) – Percentual de erros na classificação, que é o complemento do indicador IP_{21} .

O AAPM foi executado com $R_{min} = 0,500$, $\mu = 3$ (nº mínimo de amostras para validação do grupo) e $\omega = 100$ (tamanho da janela de amostras). Foram realizados dois testes diferentes para aplicação do AAPM: o primeiro utilizando as correntes e tensões das fases A, B e C do motor; o segundo utilizando somente a corrente e a tensão da fase A. Os resultados destes testes são apresentados e discutidos a seguir.

4.2 Resultados

4.2.1 Classificação Utilizando Tensão e Corrente das Três Fases

Os indicadores de desempenho calculados para este conjunto de amostras foram os seguintes: $IP_1 = 0,30$ %, $IP_2 = 99,70$ %, $IP_{21} = 100,00$ % e $IP_{22} = 0,00$ %.

Uma vez que nesta aplicação do AAPM são utilizadas seis variáveis de entrada, não existe um gráfico para representar os centros dos grupos e suas regiões de ação. Entretanto, a Tabela 4.2 apresenta o resultado final da classificação com 7 grupos consolidados, onde pode-se ver a condição de operação atribuída a cada grupo e os seus respectivos centros.

Tabela 4.2 – Grupos consolidados usando seis variáveis de entrada.

Classificação		Centro do Grupo					
Grupo	Operação	I_A	I_B	I_C	V_A	V_B	V_C
G01	condição normal	0,13	0,38	0,08	0,99	0,99	0,99
G02	curto-circuito na fase A	0,42	0,70	0,48	0,00	0,99	0,99
G03	curto-circuito na fase B	0,60	0,59	0,46	0,99	0,00	0,99
G04	curto-circuito na fase C	0,57	0,72	0,33	0,99	0,99	0,00
G05	curto-circuito nas fases A e B	0,11	0,33	0,81	0,00	0,00	0,99
G06	curto-circuito nas fases A e C	0,07	0,99	0,06	0,00	0,99	0,00
G07	curto-circuito nas fases B e C	0,98	0,37	0,02	0,99	0,00	0,00

A Tabela 4.3 apresenta as intervenções do operador para rotulagem das condições de operação. Foram 7 as intervenções do operador. Os dados desta tabela também podem ser vistos em forma gráfica na Figura 4.2-b.

Tabela 4.3 – Intervenções do operador para seis variáveis de entrada.

Nº da Amostra	Tempo (s)	Rotulagem Realizada
3	0,05	condição normal
859	14,26	curto-circuito na fase A
1436	23,85	curto-circuito na fase B
2014	33,45	curto-circuito na fase C
2593	43,06	curto-circuito nas fases A e B
3171	52,66	curto-circuito nas fases A e C
3749	62,26	curto-circuito nas fases B e C

A Figura 4.2 mostra as variações de corrente e tensão na fase A do motor durante a simulação e as condições de operação simuladas e detectadas. Pode-se observar na Figura 4.2-b que existem diversos pontos em azul sobre o eixo das abscissas, indicando condição de operação número 0 (zero). O AAPM foi desenvolvido para registrar com número 0 as amostras pertencentes a grupos candidatos. Vale salientar que nestes instantes o algoritmo não solicita a intervenção do operador, mesmo porque não há uma classificação conclusiva.

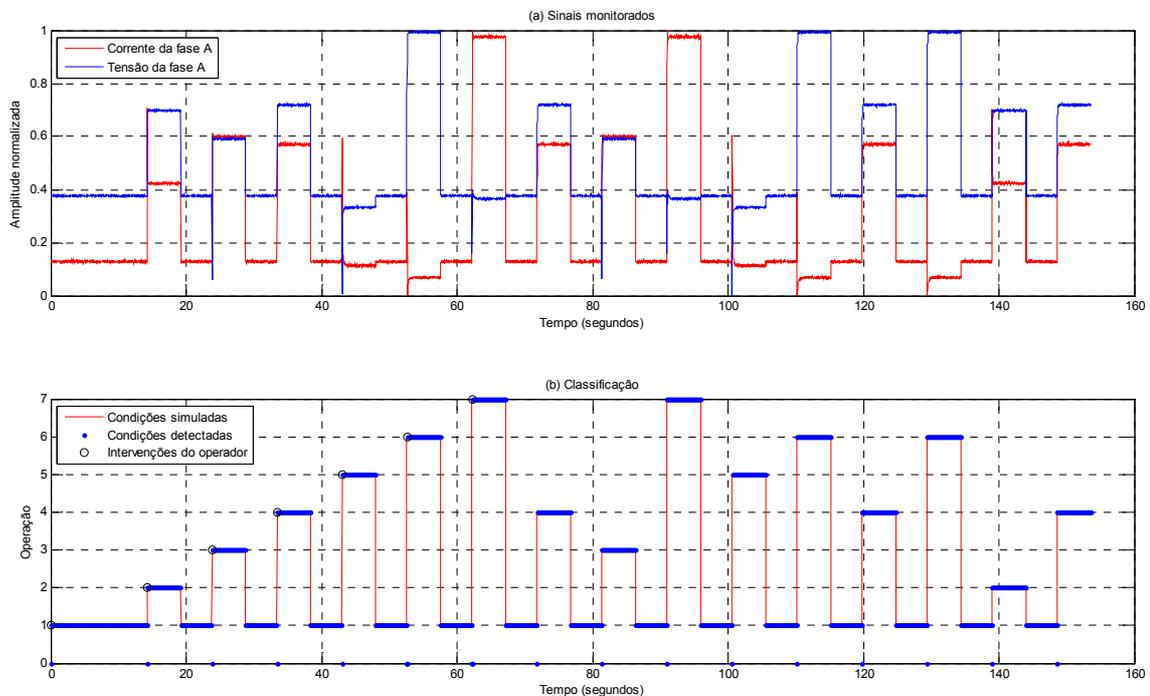


Figura 4.2 – Classificação usando seis variáveis de entrada.

Observa-se também que após a apresentação das sete condições de operação, tendo sido realizadas as respectivas intervenções do operador, o AAPM foi capaz de detectar e identificar todos os modos de operação subsequentes.

A condição de operação 0 (amostras de grupos candidatos), registradas em azul na transição dos modos de operação do motor a partir de 70 segundos, ocorreu porque nestes momentos os níveis de tensão e corrente estão em transitório (Figura 4.2-a), o que gera um condição operacional não classificada anteriormente (grupos candidatos). Este fato comprova a eficiência do mecanismo de alerta proposto neste trabalho, que atua como um filtro e torna o algoritmo robusto.

4.2.2 Classificação Utilizando Tensão e Corrente da Fase A

Os indicadores de desempenho calculados para este conjunto de amostras foram os seguintes: $IP_1 = 0,92 \%$, $IP_2 = 99,08 \%$, $IP_{21} = 99,99 \%$ e $IP_{22} = 0,01 \%$.

A Tabela 4.4 apresenta o resultado final da classificação com 10 grupos consolidados. Nesta tabela vê-se a condição de operação atribuída a cada grupo (por meio da intervenção do operador), bem como os seus respectivos centros.

Tabela 4.4 – Grupos consolidados usando duas variáveis de entrada.

Classificação		Centro do Grupo	
Grupo	Operação	I_A	V_A
G01	condição normal	0,13	0,99
G02	curto-circuito na fase A	0,42	0,00
G03	curto-circuito na fase B	0,60	0,99
G04	curto-circuito na fase C	0,57	0,99
G05	curto-circuito nas fases A e B	0,16	0,00
G06	curto-circuito nas fases A e B	0,11	0,00
G07	curto-circuito nas fases A e C	0,07	0,00
G08	curto-circuito nas fases B e C	0,98	0,99
G09	curto-circuito nas fases A e C	0,04	0,00
G10	curto-circuito na fase C	0,53	0,00

A Tabela 4.5 apresenta as intervenções do operador para rotulagem das condições de operação. Foram 13 as intervenções do operador. Os dados desta tabela também podem ser vistos em forma gráfica na Figura 4.3-b.

Tabela 4.5 – Intervenções do operador para duas variáveis de entrada.

Nº da Amostra	Tempo (s)	Rotulagem Realizada
3	0,05	condição normal
862	14,31	curto-circuito na fase A
1440	23,91	curto-circuito na fase B
1441	23,93	curto-circuito na fase B
2017	33,50	curto-circuito na fase C
2598	43,15	curto-circuito nas fases A e B
2602	43,21	curto-circuito nas fases A e B
3173	52,70	curto-circuito nas fases A e C
3752	62,31	curto-circuito nas fases B e C
4330	71,91	curto-circuito na fase C
6070	100,81	curto-circuito nas fases A e B
6641	110,30	curto-circuito nas fases A e C
8950	148,65	curto-circuito na fase C

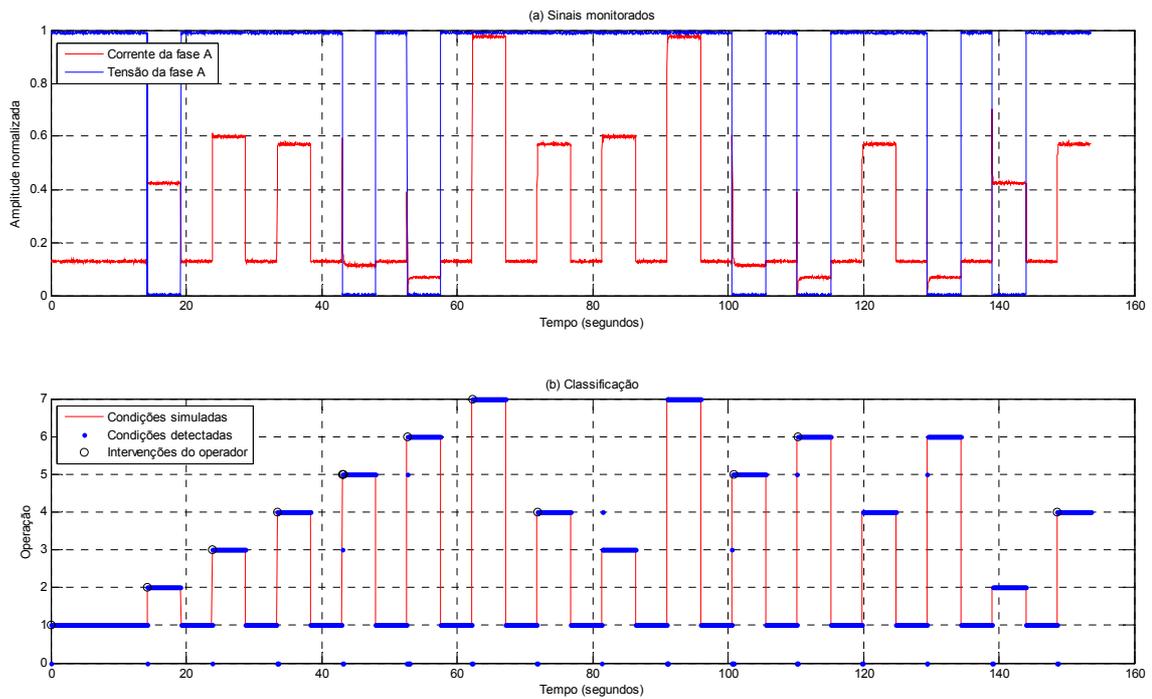


Figura 4.3 – Classificação usando duas variáveis de entrada.

5. Aplicação do AAPM com Dados Reais

5.1 Visão Geral de um Laminador de Fio Máquina

A laminação é o processo de conformação mecânica no qual se modifica a geometria e dimensões de um corpo metálico por meio de esforço mecânico. Na laminação o material metálico, quente ou frio, passa entre cilindros laminadores que giram à mesma velocidade, porém em sentidos contrários. O material sofre deformação plástica que resulta em diminuição da seção transversal e aumento do comprimento. As deformações plásticas são provocadas pela pressão dos cilindros sobre o material passante. Além de cilindros também podem ser usados discos de laminação.

O fio-máquina é o resultado de uma laminação à quente onde se transforma o tarugo num produto final longo, de seção transversal circular e enrolado em forma de bobina. Os tarugos são barras de aço de seção quadrada (por exemplo, 160 x 160 x 10.000 mm), oriundos de um lingotamento contínuo ou de uma laminação primária. No processo de laminação de fio-máquina o tarugo é previamente aquecido a uma temperatura aproximada de 1.100 °C, para então ser conformado por cadeiras laminadoras não reversíveis dispostas em série, formação também conhecida como trem contínuo.

O Laminador de Fio Máquina do qual foram coletados os dados para aplicação do AAPM é composto por três trens contínuos (totalizando 16 cadeiras), e três blocos laminadores (totalizando 14 cadeiras). As cadeiras de laminação dos trens contínuos utilizam cilindros como elementos de conformação mecânica e os blocos utilizam discos. Estes blocos têm as seguintes características:

- *Mini Bloco Pré-acabador*: Está localizado após o último trem contínuo e é composto pelas cadeiras 17 e 18. Estas cadeiras são do tipo *cantlever*.
- *Bloco Pré-acabador (FB)*: Realiza o passe de pré-acabamento do material. É composto por 8 cadeiras de laminação (cadeiras 19 a 26).
- *Bloco Acabador (FRS)*: Realiza o passe de acabamento em todas as bitolas. É composto por 4 cadeiras de laminação (cadeiras 27 a 30).

5.2 Controle de Velocidade e Formação de Laços

As cadeiras de laminação de número 1 a 18 são movidas individualmente por motores c.a., cada qual acionado por inversor de frequência. O mesmo não acontece com as cadeiras dos blocos FB e FRS, que são movidas de forma sincronizada pelo conjunto de engrenagens do respectivo bloco, ou seja, cada bloco possui um único sistema motor-inversor.

A referência mestre de velocidade em uma planta de laminação é usada para controlar automaticamente a velocidade de todas as cadeiras e blocos laminadores da planta e, eventualmente, também a velocidade das mesas de rolos de entrada e saída do laminador. O controle feito no Laminador de Fio Máquina em análise é do tipo cascata a montante (para trás), isto é, do bloco FRS para os trens laminadores. Neste caso o controle de velocidade das cadeiras é ajustado em cascata no sentido do fluxo descendente, tomando-se a velocidade do FRS como referência mestre.

A referência mestre faz um controle em que a velocidade de cada cadeira varia singularmente. Em outras palavras, todos os percentuais de variação da velocidade do motor de uma cadeira são recebidos por todos os motores das cadeiras anteriores. Isto é feito para que a parcela do tarugo, passando na cadeira anterior, não seja afetada pelas variações causadas na cadeira em questão.

Dois tipos diferentes de controle fazem parte do controle de velocidade em cascata: o controle de tensão e o controle de laço. O controle de tensão é realizado entre as cadeiras de número 1 a 10 e tem o objetivo de ajustar as velocidades das cadeiras de forma a manter a mesma vazão mássica em todas as cadeiras, que é um princípio básico da laminação. Obviamente o controle de tensão é utilizado somente nas cadeiras onde a seção transversal do material é muito grande, ou seja, não existe a possibilidade de se formar laços.

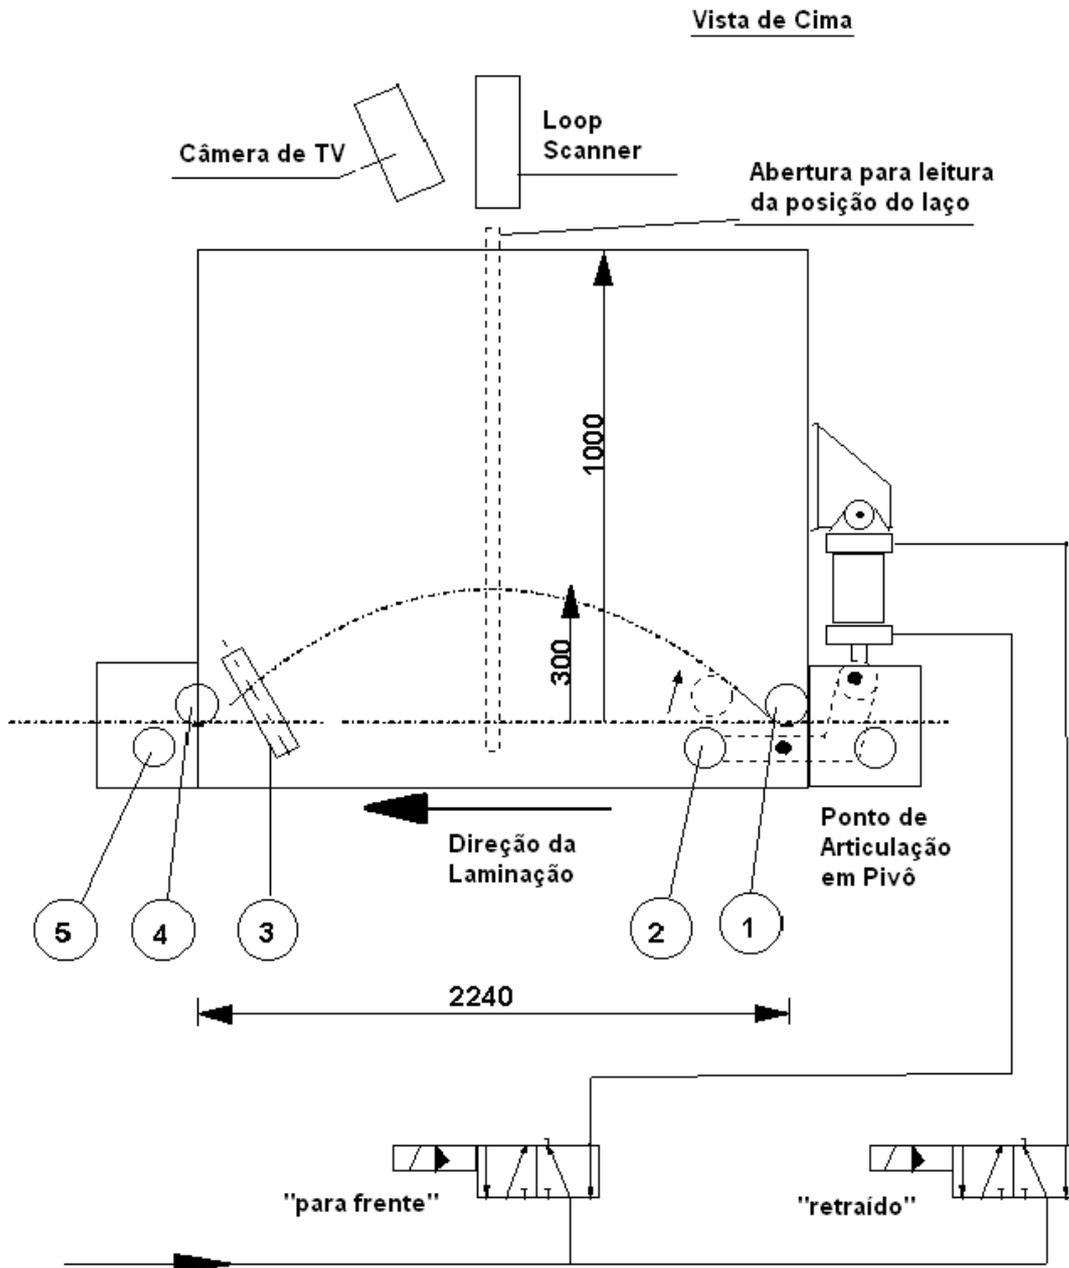
Já o controle de laço visa obter uma sobra controlada de material entre duas cadeiras. Isto é conseguido basicamente por meio do controle de velocidade da cadeira anterior ao laço. O objetivo do laço é fazer com que as variações de velocidade das cadeiras não provoquem compressão ou tração no material, fato que poderia causar sucata do material ou comprometer as tolerâncias dimensionais da sua seção transversal.

Existem laços *verticais* e *horizontais*. Os laços verticais, num total de cinco, são formados entre as cadeiras de número 11 a 16. Os laços horizontais por sua vez,

num total de quatro, são formados na região dos blocos laminadores. Como o diâmetro do material é muito pequeno nesta região do laminador, e por consequência o material não é capaz de se sustentar na posição vertical, a formação do laço horizontal se dá sobre uma mesa denominada *looper table*. Os laços horizontais são divididos em dois tipos:

- *Laço horizontal em linha* – O laminador possui dois laços deste tipo, sendo um deles formado imediatamente à frente do bloco FB e outro imediatamente à frente do bloco FRS.
- *Laço horizontal em curva 180°* - O laminador possui dois laços deste tipo. Um deles é formado na curva 180° à frente do bloco FB e outro na curva 180° à frente do bloco FRS.

5.3 Laço Horizontal em Linha



Fonte: [WOR 03].

Figura 5.1 –Mesa de formação de laço horizontal em linha.

Para fins deste trabalho será explorada a formação e o controle do laço horizontal em linha. Para melhor entendimento da descrição que se segue, chama-se de “cabeça” à extremidade posterior do material que está sendo laminado e de “cauda” à sua extremidade final.

A Figura 5.1 mostra em detalhes a mesa onde se forma o laço horizontal em linha. Nela o material se apóia e escorre durante a laminação. Os principais elementos da mesa de formação do laço horizontal em linha são os seguintes:

- (1) - Rolo de guia lateral em arranjo fixo na entrada da mesa. O rolo é do tipo roda livre com eixo na vertical.
- (2) – Rolo formador de laço com ponto de articulação em pivô, montado imediatamente após o rolo de guia lateral na entrada da mesa. O rolo é do tipo roda livre com eixo na vertical.
- (3) - Rolo de guia superior em arranjo fixo na saída da mesa. O rolo é do tipo roda livre com eixo na horizontal.
- (4) e (5) – Dois rolos de guia lateral em arranjo fixo na saída da mesa, montados imediatamente após o rolo de guia superior. Os rolos são do tipo roda livre com eixo na vertical.

Seguem algumas considerações para entendimento do controle de formação do laço horizontal em linha.

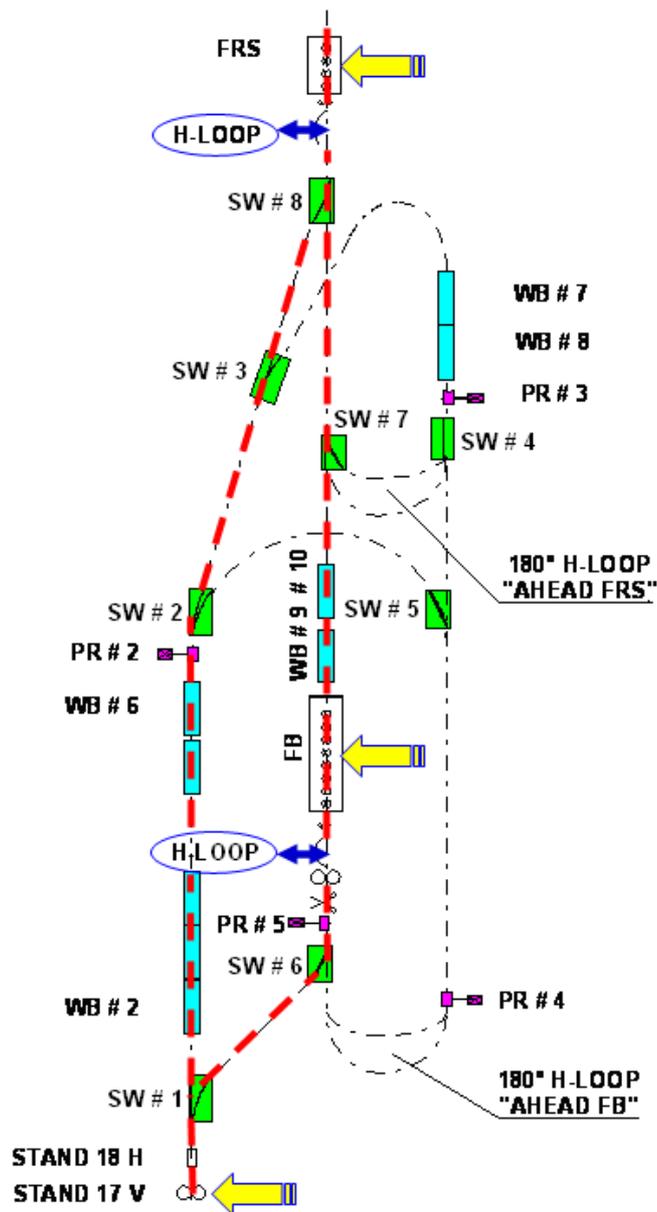
- Ao entrar na mesa de formação do laço, a cabeça do material passa em linha reta através dos rolos (1) e (2) / (4) e (5). Neste momento o rolo formador de laço está em sua posição retraída.
- A formação do laço se inicia imediatamente após a cabeça do material ter entrado na primeira cadeira ativa do bloco laminador à frente da mesa, ou seja, a cadeira dentro do bloco FB ou do bloco FRS, dependendo da rota utilizada.
- A formação ocorre pela ação combinada do deslocamento do rolo formador em direção ao material, impulsionando-o para cima, mais a aceleração da cadeira #18.
- A malha fechada de controle do laço é liberada no momento em que o rolo formador de laço inicia o seu movimento. O rolo formador de laço permanece atuado durante todo o tempo em que a barra está passando pela mesa.
- A posição do rolo formador dá a amplitude desejada para manter o laço livre passando sobre a mesa, enquanto o rolo de guia superior evita a elevação do laço na mesa.

- A altura máxima do laço ocorre quando o material fica esticado entre os rolos de guia lateral da entrada e da saída, ou seja, quando o material passa em linha reta.
- A amplitude do laço é medida continuamente por um dispositivo chamado *loop scanner*. Durante a passagem do material o laço é controlado para uma posição em torno de 300 mm (ajustável no sistema de operação).
- O loop scanner varre uma faixa de aproximadamente 1.000 mm na mesa de formação do laço.
- A regulação é feita variando-se a velocidade da cadeira 18, sempre.
- A regulação do laço é feita basicamente por meio de controle proporcional. Controle adicional de ação integral pode ser inserido através do sistema de operação.

5.4 Rotas de Laminação

Existem cinco rotas possíveis para se produzir os diversos tipos e bitolas de fio-máquina. A Figura 5.2 mostra o lay-out resumido onde as cinco rotas são formadas. As rotas são determinadas pelo posicionamento adequado de desviadores (*switches*) instalados na região entre o mini bloco pré-acabador e o bloco FRS. Além dos switches têm-se outros dispositivos e equipamentos importantes, tais como rolos impulsadores (*pinch rolls*), caixas d'água para resfriamento do material (*water boxes*), mesas de formação dos laços horizontais (*looper tables*), além dos blocos FB e FRS.

Ainda na Figura 5.2 pode-se ver destacados os três blocos de cadeiras de laminação (setas grandes na cor amarela) e os dois laços horizontais em linha (setas duplas em azul). Em cada uma das rotas somente um dos quatro laços horizontais é usado. Os laços horizontais em linha são utilizados nas rotas 1 e 5 (linhas tracejadas vermelhas), enquanto os laço horizontais em curva 180° são usados nas rotas 2, 3 e 4.



Fonte: [WOR 03].

Figura 5.2 – Lay-out do laminador na área dos blocos laminadores

5.5 Condições de Aplicação do AAPM

Para aplicação do AAPM no laminador de fio máquina foram utilizados dados históricos de controle de formação do laço horizontal em linha à frente do bloco FRS (rota 1). Os dados foram coletados por meio de um sistema de hardware e software denominado *PDA (Process Data Acquisition)*. A comunicação entre o PDA e o CLP que controla o laço, um controlador S7-400 da Siemens, é feita através de rede Profibus-DP. O intervalo entre aquisições é de 20,0 ms.

A Figura 5.3 apresenta os sinais de posição do laço (medida pelo *loop scanner*) e velocidade do motor da cadeira # 18 (saída do controlador), durante um ciclo completo de operação normal do laço. Estes sinais são utilizados como entradas do AAPM e estão normalizados. O sinal de posição do laço próximo de 0 (zero) indica que não há material na mesa de formação, enquanto próximo de 1 (um) indica que o laço está formado.

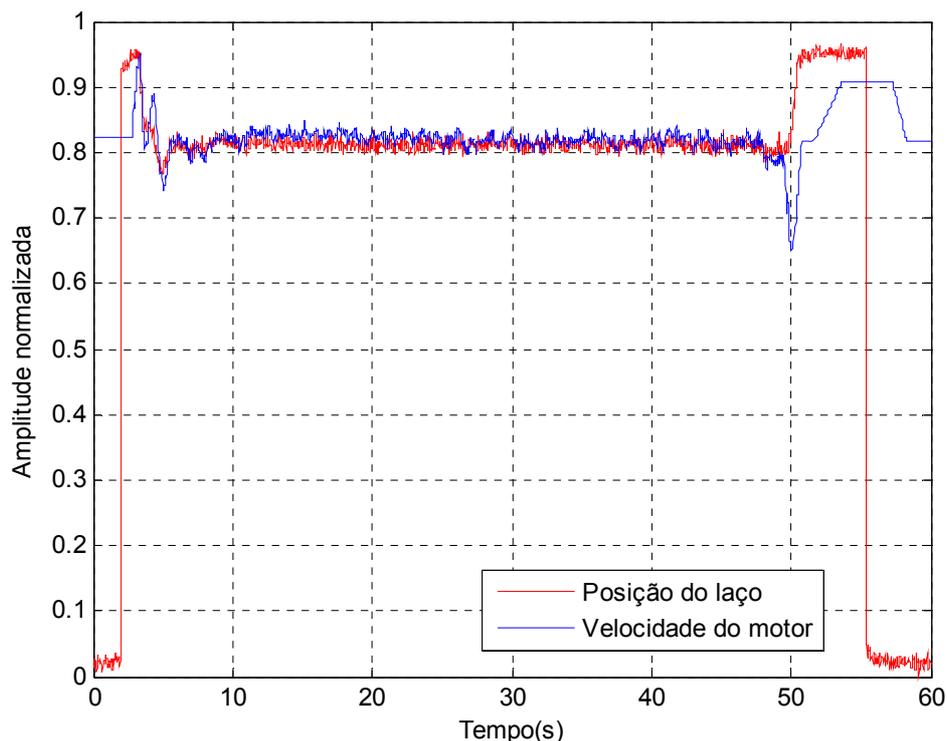


Figura 5.3 – Controle do laço horizontal sem falha.

Para a condição normal de operação foram utilizadas 3.000 amostras num total de 60 segundos de amostragem. O tempo total desde a entrada da cabeça do material na mesa de formação até a saída da cauda é de aproximadamente 53 segundos. Este tempo corresponde ao tempo total de laminação do tarugo e varia de acordo com a velocidade do FRS e bitola do fio-máquina que está sendo produzido, podendo durar 120 segundos para bitola de 5,50 mm.

Ainda com foco na Figura 5.3, pode-se observar que após a entrada do material na mesa (tempo = 2 s), ocorre um intervalo de transitório para formação e estabilização do laço. Neste intervalo acontece a mordedura do material na primeira cadeira do FRS, um aumento e uma posterior diminuição da velocidade da cadeira # 18, uma diminuição da altura do laço e finalmente a estabilização dos sinais (após tempo =

11 s). O laço é desfeito por retração do rolo formador de laço em conjunto com a redução da velocidade da cadeira # 18 (tempo = 50 s).

As Figuras 5.4 a 5.7 mostram quatro condições diferentes de operação do laço durante o seu controle de formação: a condição normal e três condições de falha. O fundo de escala de tempo dos quatro gráficos foi ajustado em 20 segundos para facilitar a comparação entre os sinais plotados. Para cada uma das três condições de falha foram utilizadas 600 amostras, representando 12 segundos de amostragem.

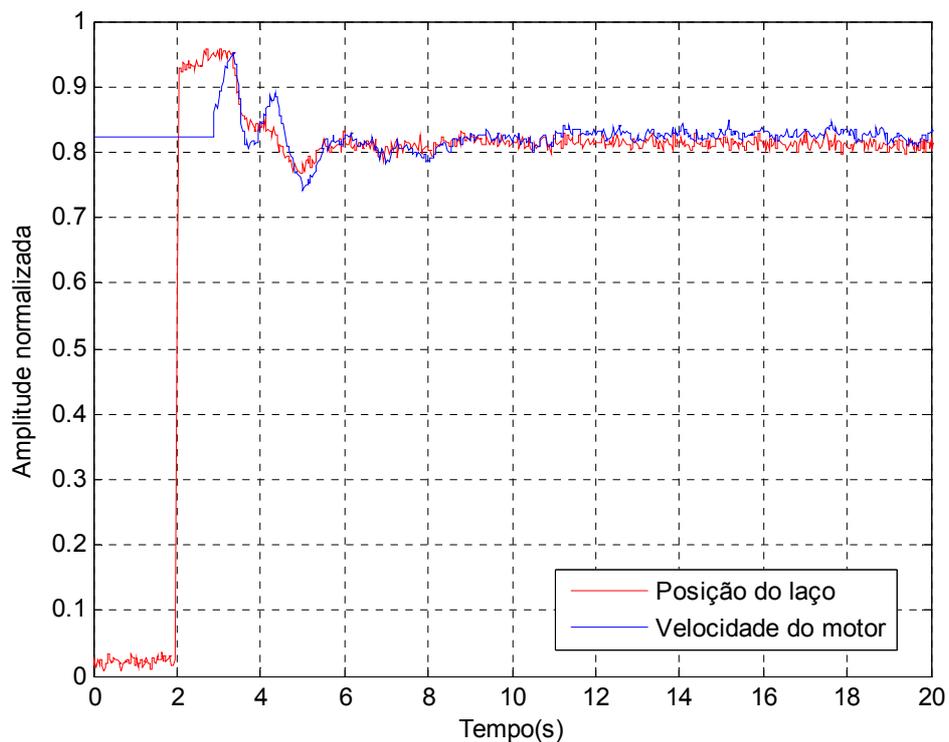


Figura 5.4 – Formação normal do laço.

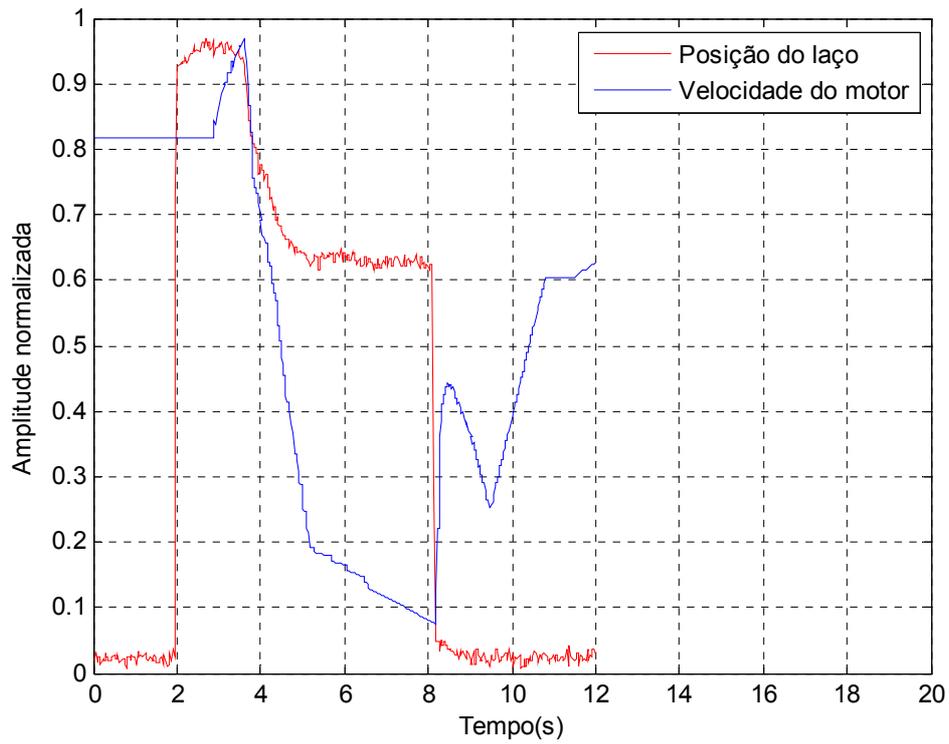


Figura 5.5 – Formação com falha 1 do laço.

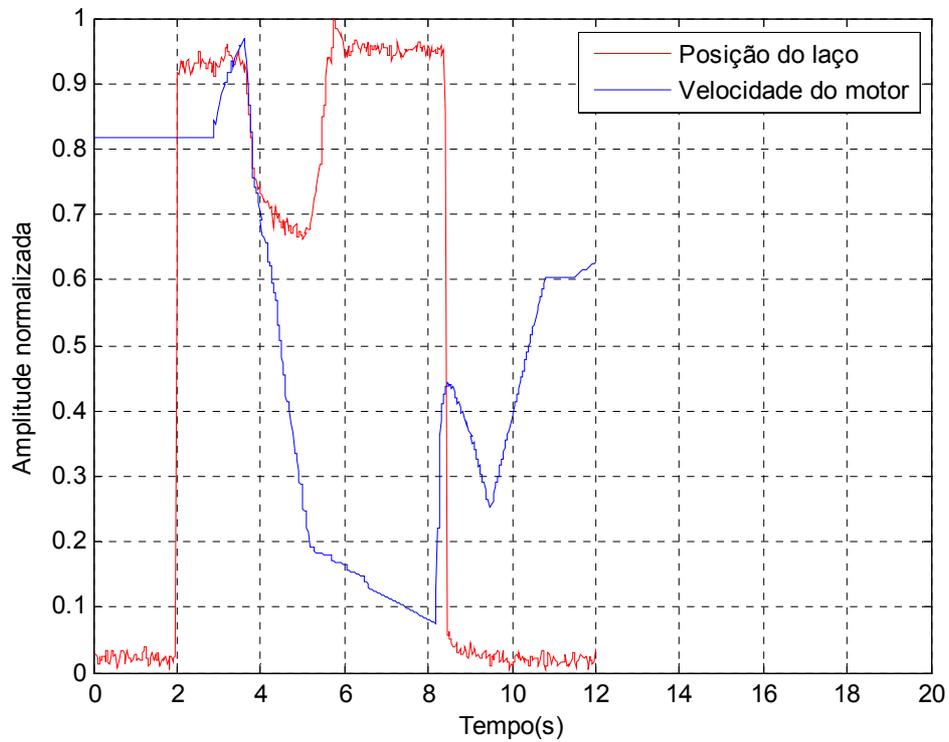


Figura 5.6 – Formação com falha 2 do laço.

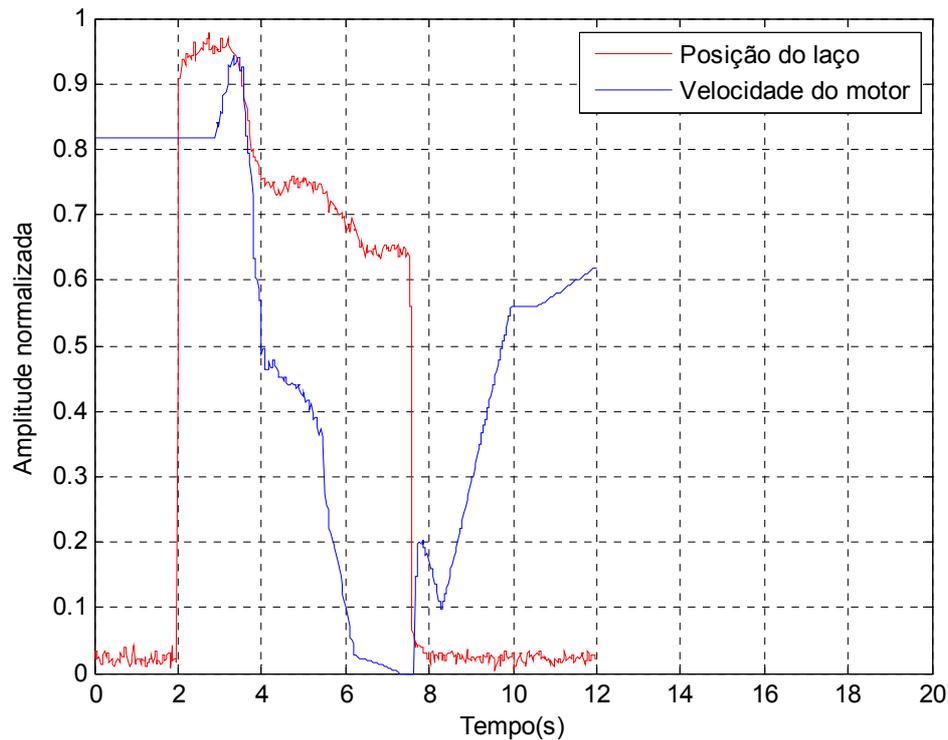


Figura 5.7 – Formação com falha 3 do laço.

Para aplicação do AAPM em formação de laço foram realizados cinco testes diferentes. As massas de dados foram submetidas ao algoritmo como se segue:

- 1) Somente amostras da operação normal (3.000 pontos);
- 2) Somente amostras da operação com falha 1 (600 pontos);
- 3) Somente amostras da operação com falha 2 (600 pontos);
- 4) Somente amostras da operação com falha 3 (600 pontos);
- 5) Conjunto completo de todas as amostras anteriores, agrupadas e seqüenciadas em um único arquivo de dados (5.400 pontos).

As três condições de falha mostradas nas Figuras 5.5, 5.6 e 5.7 ocorreram em datas diferentes. Ao analisarmos a dinâmica dos sinais em cada uma destas três figuras verifica-se que as falhas são de natureza diferente (elas têm comportamentos diferentes). Contudo, em determinados trechos das amostras o sistema de controle de formação de laço atua em regiões de operação semelhantes. Visando a simplificação do estudo, porém, foram usadas para classificação somente duas condições de operação: *normal* ou *falha*. A Figura 5.8 mostra a janela de interface do AAPM com o operador.

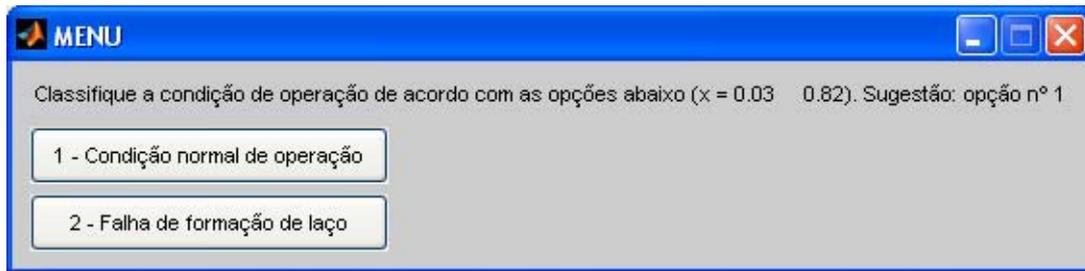


Figura 5.8 – Janela de intervenção do operador para formação de laço.

Dois vetores (V_1 e V_2), com dimensões iguais ao número total de amostras, foram criados como recurso para avaliação dos resultados obtidos com o AAPM. Através de uma análise prévia da massa de dados, para cada ponto amostrado foi registrado em V_1 a sua condição de operação, sendo atribuído 1 (um) para condição normal e 2 (dois) para condição de falha. Já em V_2 foram registrados pelo AAPM os resultados da classificação das amostras. Além das duas condições previstas em V_1 , encontra-se também em V_2 o valor 0 (zero) para indicar amostra não classificada, ou seja, pertencente a grupo candidato no momento da sua classificação.

A partir da comparação entre os vetores V_1 e V_2 foram gerados quatro indicadores:

- IP_1 (%) - Percentual de amostras não classificadas, isto é, amostras pertencentes a grupos candidatos.
- IP_2 (%) - Percentual de amostras classificadas, ou seja, amostras definidas pelo AAPM como pertencentes a um grupo qualquer, com classificação correta ou não.
- IP_{21} (%) – Percentual de acertos na classificação, que representa o percentual de coincidências entre os vetores V_1 e V_2 , tomando-se como base de 100% o indicador IP_2 .
- IP_{22} (%) – Percentual de erros na classificação, que é o complemento do indicador IP_{21} .

O AAPM foi executado com $R_{min} = 0,065$, $\mu = 3$ (nº mínimo de amostras para validação do grupo) e $\omega = 500$ (tamanho da janela de amostras). Os resultados destes testes são apresentados e discutidos a seguir.

5.6 Resultados

5.6.1 Amostras da Operação Normal

A Tabela 5.1 apresenta o resultado final dos grupos consolidados para o primeiro conjunto de amostras, identificados pelo AAPM durante sua execução. Nesta tabela vê-se a condição de operação atribuída a cada grupo (por meio da intervenção do operador), bem como os seus respectivos centros.

Tabela 5.1 – Grupos consolidados para operação normal.

Classificação		Centro do Grupo	
Grupo	Operação	X_1 (posição do laço)	X_2 (velocidade do motor)
G01	normal	0,02	0,85
G02	normal	0,81	0,81
G03	normal	0,95	0,87
G04	normal	0,85	0,68

Na Figura 5.9 tem-se o gráfico com todos os grupos identificados pelo AAPM (candidatos e consolidados). Nele estão plotados os centros dos grupos, as amostras de cada grupo armazenadas na janela ω e o círculo de ação do grupo (calculado em função de \bar{s} do grupo).

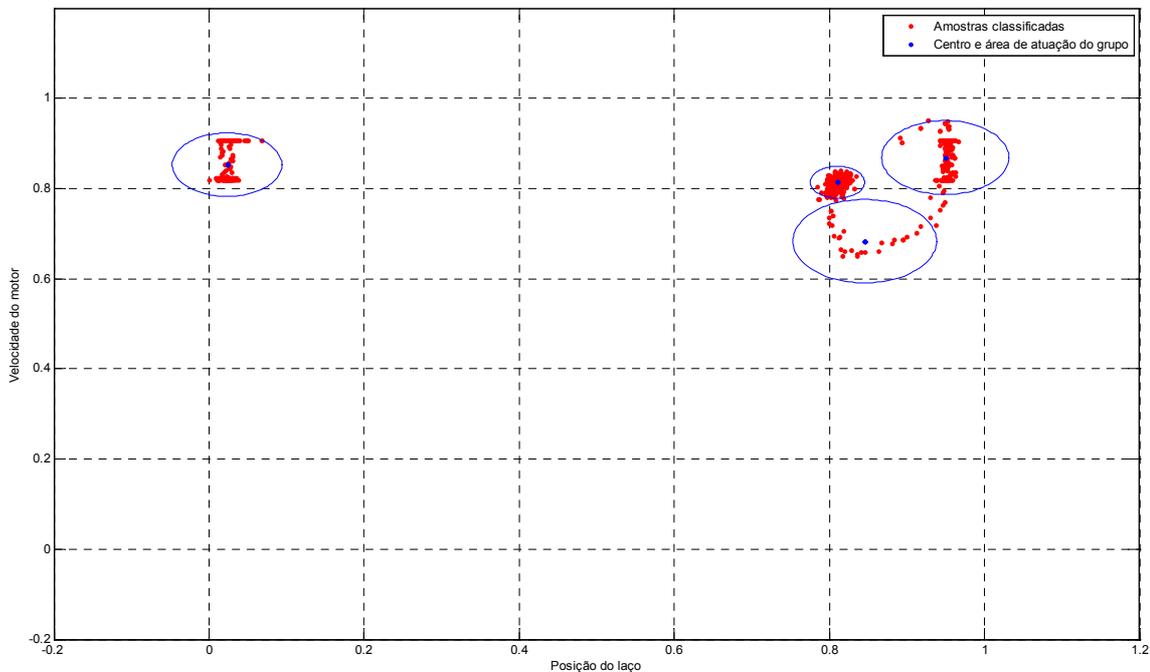


Figura 5.9 – Grupos identificados nas amostras de operação normal.

Sabe-se que os números das amostras são seqüenciais e que o intervalo de amostragem é de 20,0 ms. Desta forma, usando o número da amostra pode-se estabelecer de forma implícita uma linha de tempo para comparação dos eventos.

A Tabela 5.2 apresenta os instantes em que um grupo candidato se tornou um grupo consolidado, ou de outra forma, os instantes em que foi aberta pelo AAPM a interface para rotulagem do novo grupo consolidado. Como se pode ver, foram 9 as intervenções do operador, todas, logicamente, indicando condição normal de operação. Os dados desta tabela também podem ser vistos em forma gráfica na Figura 5.10-b.

Tabela 5.2 – Intervenções do operador para operação normal.

Nº da Amostra	Rotulagem Realizada
3	normal
104	normal
159	normal
187	normal
224	normal
229	normal
2486	normal
2524	normal
2769	normal

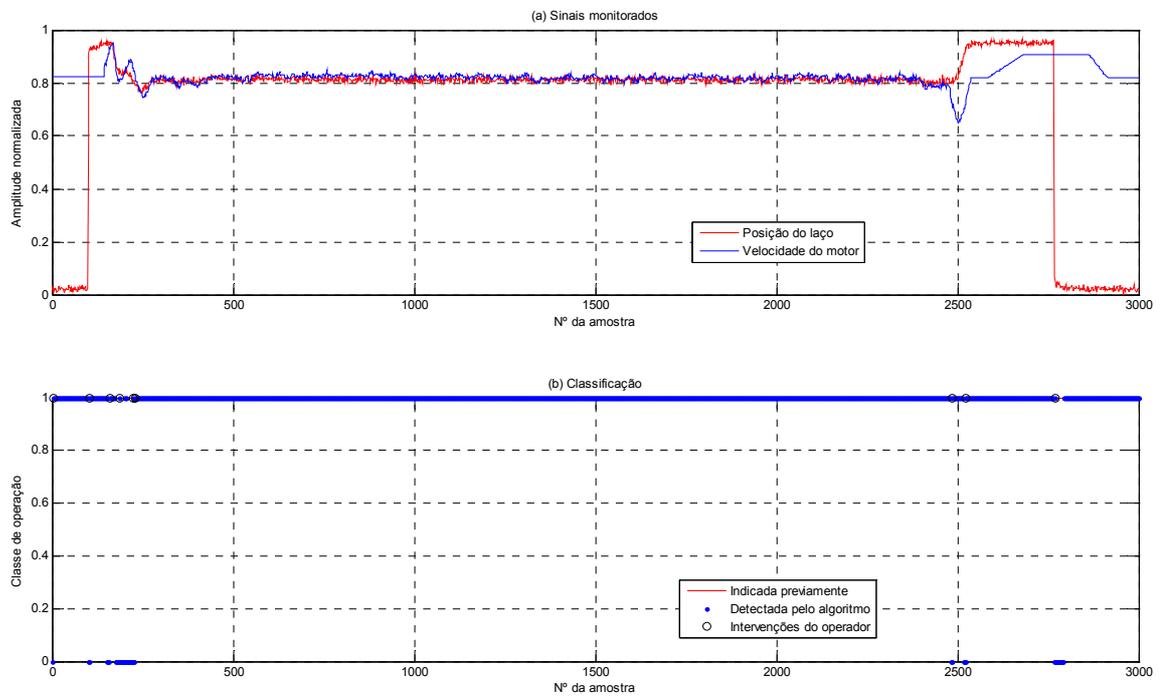


Figura 5.10 – Amostras da operação normal.

Os indicadores de desempenho calculados para este conjunto de amostras foram os seguintes: $IP_1 = 3,17 \%$, $IP_2 = 96,83 \%$, $IP_{21} = 100 \%$ e $IP_{22} = 0 \%$.

5.6.2 Amostras da Operação com Falha 1

A Tabela 5.3 apresenta o resultado final da classificação com 11 grupos consolidados. Na Figura 5.11 tem-se o gráfico com todos os grupos identificados pelo AAPM, e como pode ser verificado, existem 2 grupos a mais. Eles se referem a 2 grupos candidatos presentes ao final da avaliação.

Tabela 5.3 – Grupos consolidados para operação com falha 1.

Classificação		Centro do Grupo	
Grupo	Operação	X_1 (posição do laço)	X_2 (velocidade do motor)
G01	normal	0,02	0,82
G02	normal	0,95	0,84
G03	normal	0,93	0,95
G04	falha	0,75	0,65
G05	falha	0,67	0,48
G06	falha	0,65	0,30
G07	falha	0,63	0,14
G08	falha	0,06	0,09
G09	falha	0,03	0,28
G10	falha	0,03	0,40
G11	falha	0,02	0,59

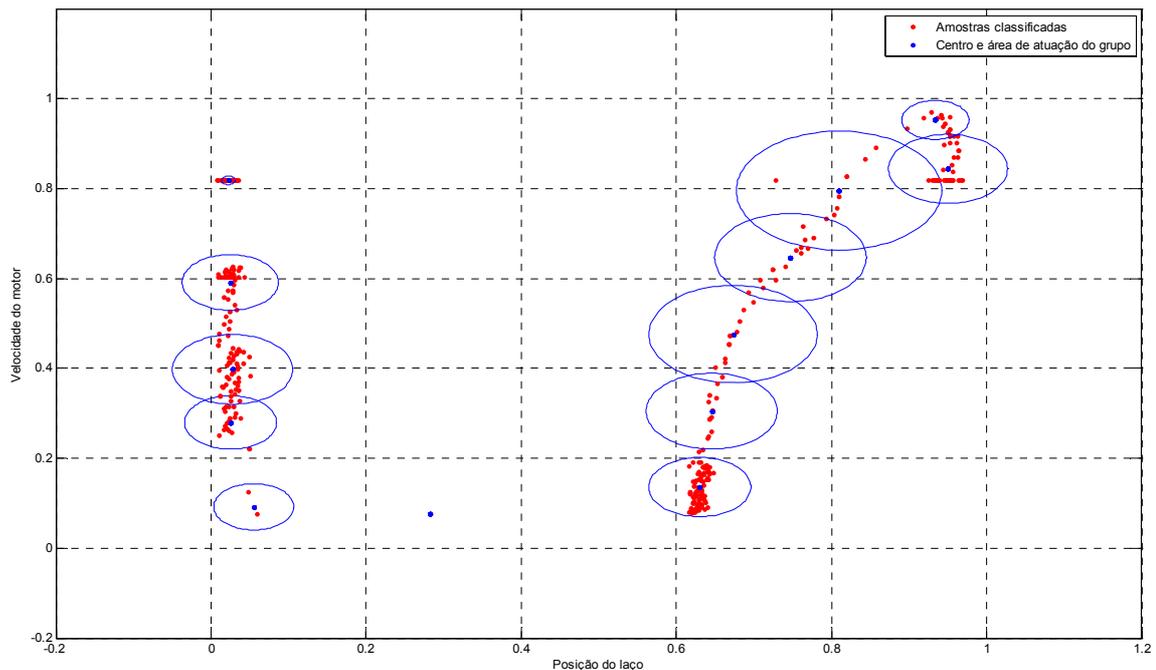


Figura 5.11 – Grupos identificados nas amostras de operação com falha 1.

A Tabela 5.4 apresenta as intervenções do operador para rotulagem das condições de operação. Foram 13 as intervenções do operador. Os dados desta tabela também podem ser vistos em forma gráfica na Figura 5.12-b.

Tabela 5.4 – Intervenções do operador para operação com falha 1.

Nº da Amostra	Rotulagem Realizada
3	normal
102	normal
167	normal
171	normal
187	normal
199	falha
220	falha
238	falha
258	falha
410	falha
413	falha
416	falha
520	falha

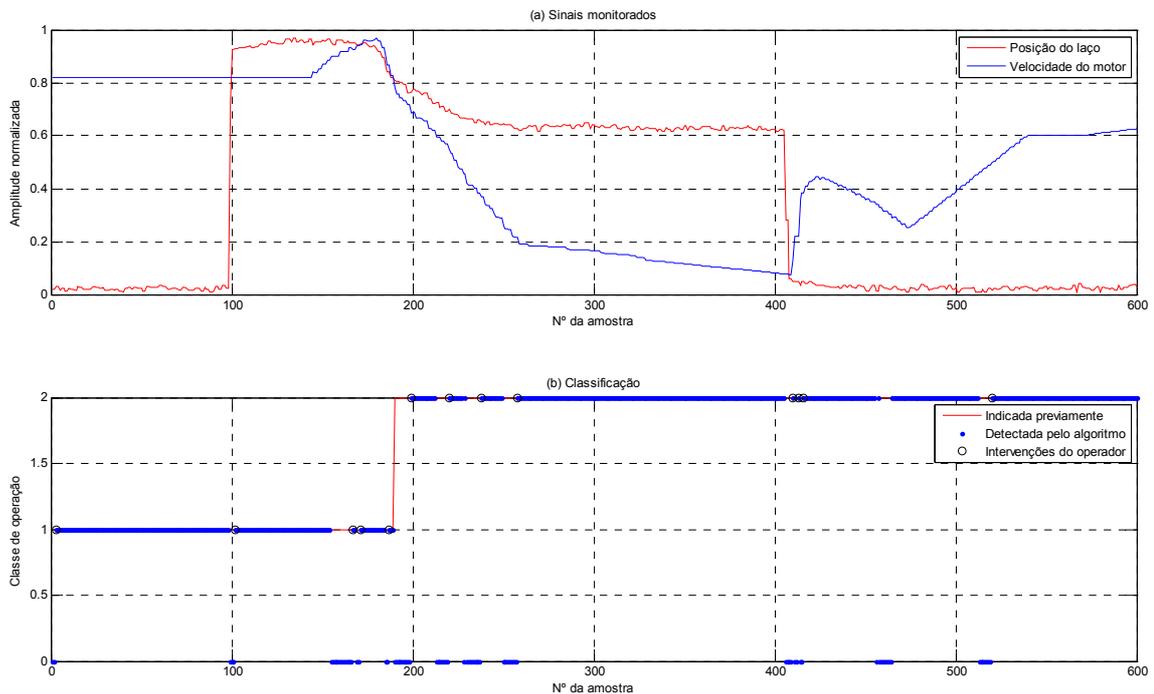


Figura 5.12 – Amostras da operação com falha 1.

Os indicadores de desempenho calculados para este conjunto de amostras foram os seguintes: $IP_1 = 12,83 \%$, $IP_2 = 87,17 \%$, $IP_{21} = 100 \%$ e $IP_{22} = 0 \%$

Ao compararmos estes resultados com aqueles do item 5.6.1 (amostras da condição normal), nota-se que aqui as intervenções foram relativamente maiores (9 intervenções em 3.000 contra 13 em 600).

5.6.3 Amostras da Operação com Falha 2

A Tabela 5.5 apresenta o resultado final da classificação com 10 grupos consolidados. Na Figura 5.13 tem-se o gráfico também com 10 grupos identificados pelo AAPM.

Tabela 5.5 – Grupos consolidados para operação com falha 2.

Classificação		Centro do Grupo	
Grupo	Operação	X_1 (posição do laço)	X_2 (velocidade do motor)
G01	normal	0,02	0,86
G02	normal	0,94	0,81
G03	normal	0,93	0,96
G04	normal	0,83	0,85
G05	falha	0,73	0,61
G06	falha	0,69	0,48
G07	falha	0,69	0,27
G08	falha </td <td>0,82</td> <td>0,26</td>	0,82	0,26
G09	falha	0,96	0,42
G10	falha	0,96	0,59

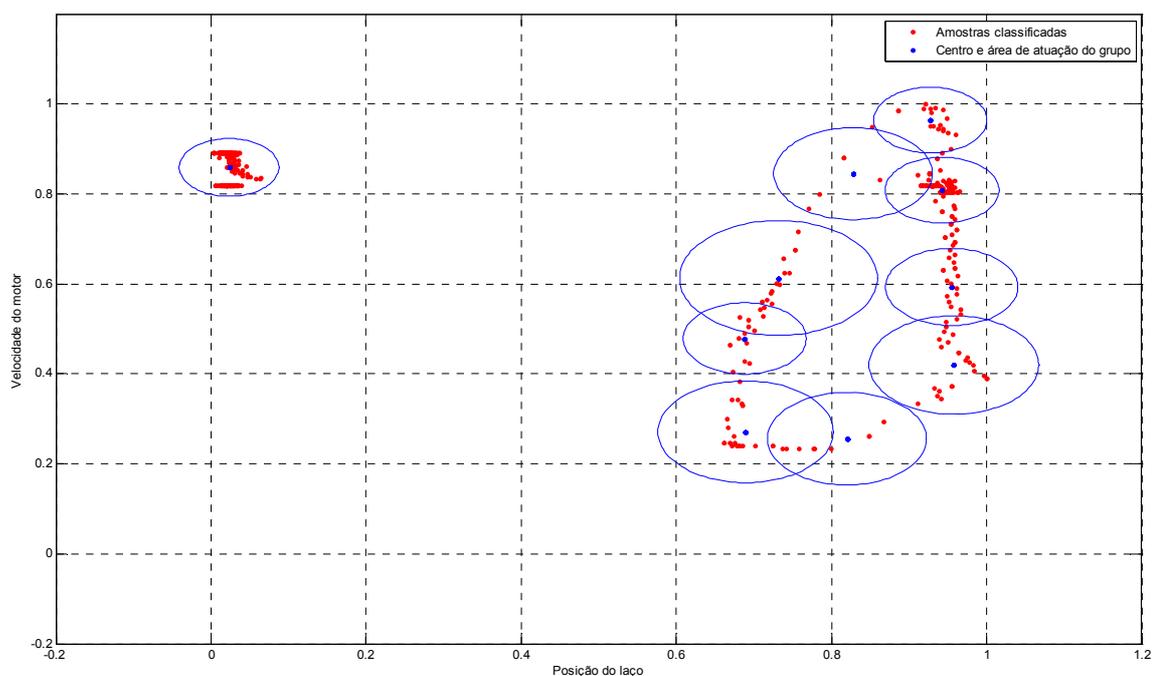


Figura 5.13 – Grupos identificados nas amostras de operação com falha 2.

A Tabela 5.6 apresenta as intervenções do operador para rotulagem das condições de operação. Foram 11 as intervenções do operador. Os dados desta tabela também podem ser vistos em forma gráfica na Figura 5.14-b.

Tabela 5.6 – Intervenções do operador para operação com falha 2.

Nº da Amostra	Rotulagem Realizada
3	normal
103	normal
162	normal
193	falha
217	falha
237	falha
272	falha
280	falha </td
311	falha
341	falha
420	normal

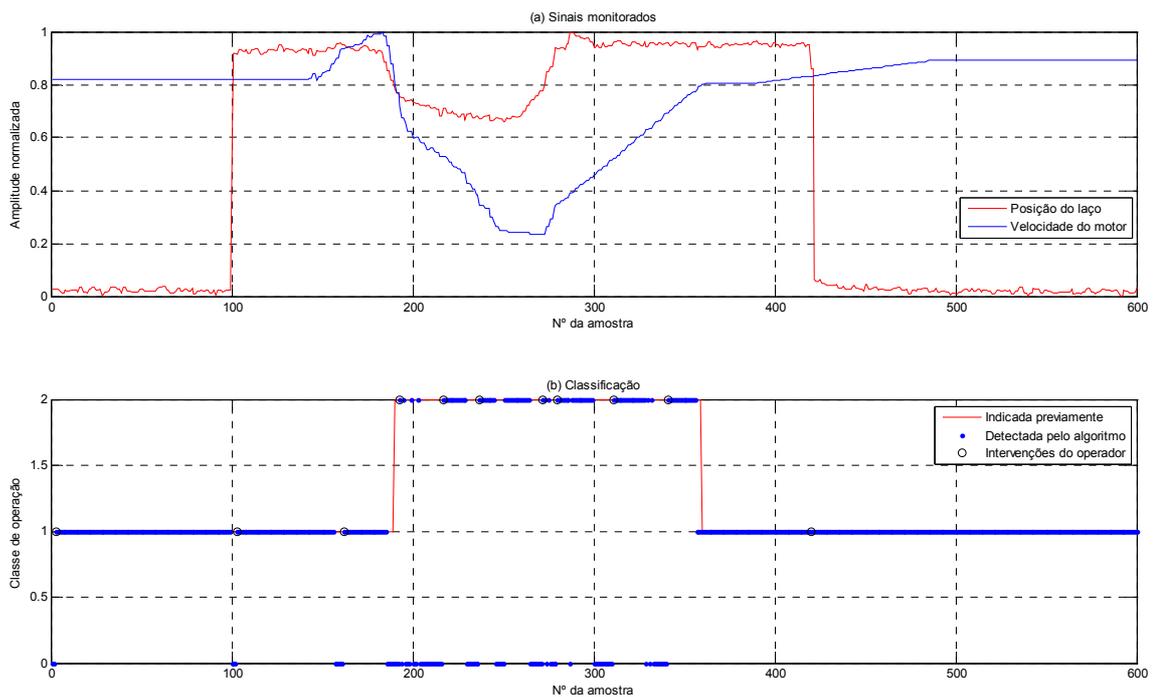


Figura 5.14 – Amostras da operação com falha 2.

Os indicadores de desempenho calculados para este conjunto de amostras foram os seguintes: $IP_1 = 13,83 \%$, $IP_2 = 86,17 \%$, $IP_{21} = 99,42 \%$ e $IP_{22} = 0,58 \%$.

5.6.4 Amostras da Operação com Falha 3

A Tabela 5.7 apresenta o resultado final da classificação com 12 grupos consolidados. Na Figura 5.15 tem-se o gráfico com todos os grupos identificados pelo AAPM, e como pode ser verificado, existe 1 grupo a mais. Ele se refere a 1 grupo candidato presente ao final da avaliação.

Tabela 5.7 – Grupos consolidados para operação com falha 3.

Classificação		Centro do Grupo	
Grupo	Operação	X_1 (posição do laço)	X_2 (velocidade do motor)
G01	normal	0,02	0,82
G02	normal	0,94	0,83
G03	normal	0,94	0,93
G04	normal	0,82	0,76
G05	falha	0,78	0,60
G06	falha	0,75	0,43
G07	falha	0,71	0,20
G08	falha	0,65	0,02
G09	falha	0,06	0,00
G10	falha	0,03	0,17
G11	falha	0,02	0,35
G12	falha	0,02	0,57

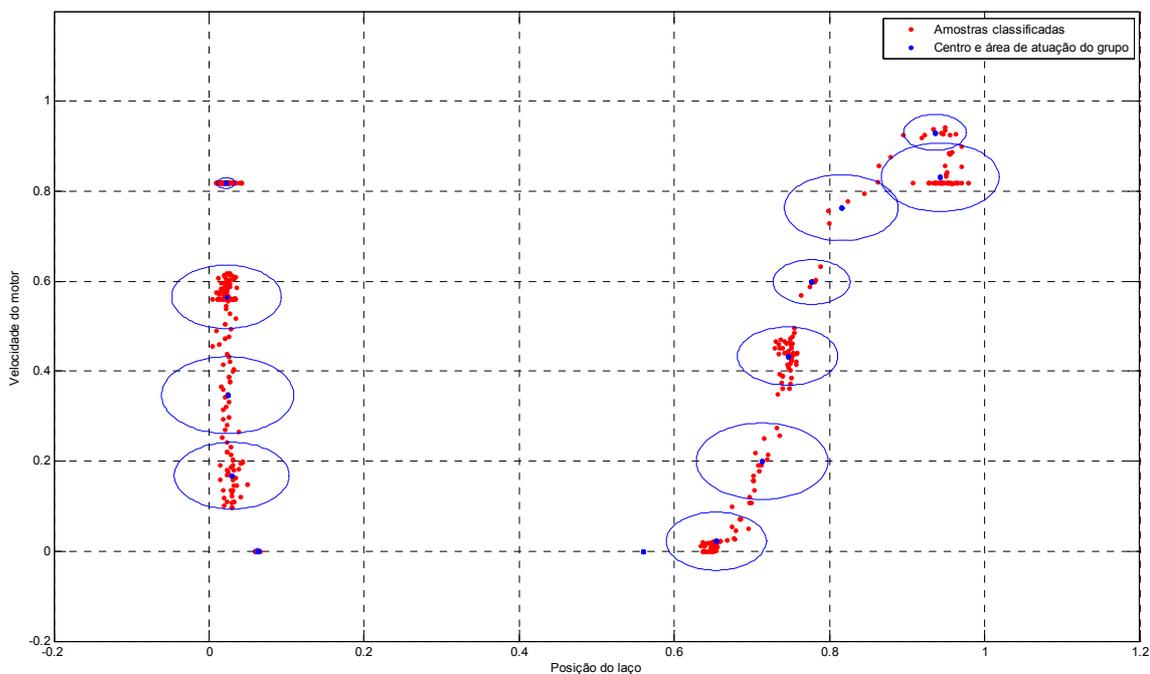


Figura 5.15 – Grupos identificados nas amostras de operação com falha 3.

A Tabela 5.8 apresenta as intervenções do operador para rotulagem das condições de operação. Foram 12 as intervenções do operador. Os dados desta tabela também podem ser vistos em forma gráfica na Figura 5.16-b.

Tabela 5.8 – Intervenções do operador para operação com falha 3.

Nº da Amostra	Rotulagem Realizada
3	normal
103	normal
163	normal
186	normal
193	falha
202	falha
277	falha
300	falha
381	falha
385	falha
447	falha
478	falha

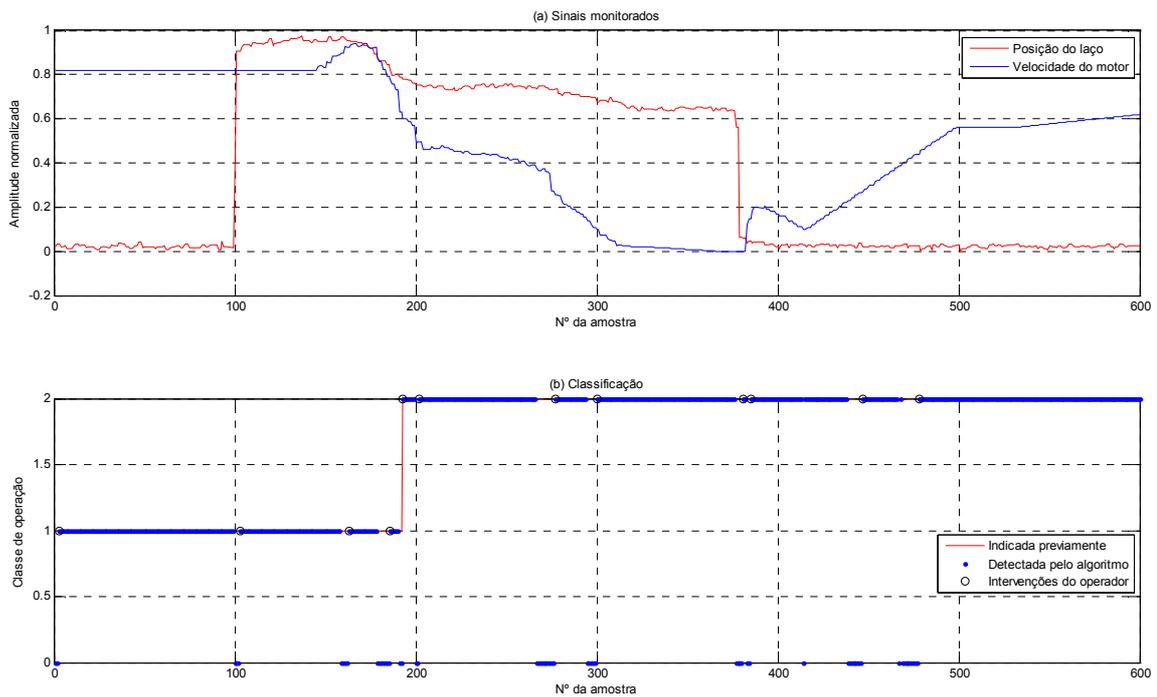


Figura 5.16 – Amostras da operação com falha 3.

Os indicadores de desempenho calculados para este conjunto de amostras foram os seguintes: $IP_1 = 10,00 \%$, $IP_2 = 90,00 \%$, $IP_{21} = 100 \%$ e $IP_{22} = 0 \%$

5.6.5 Conjunto Completo de Amostras

A Tabela 5.9 apresenta o resultado final da classificação com 19 grupos consolidados. Na Figura 5.17 tem-se o gráfico com todos os grupos identificados pelo AAPM, e como pode ser verificado, existe 1 grupo a mais. Ele se refere a 1 grupo candidato presente ao final da avaliação.

A Tabela 5.10 apresenta as intervenções do operador para rotulagem das condições de operação. Foram 26 as intervenções do operador. Os dados desta tabela também podem ser vistos em forma gráfica na Figura 5.18-b.

Os indicadores de desempenho calculados para este conjunto de amostras foram os seguintes: $IP_1 = 5,63 \%$, $IP_2 = 94,37 \%$, $IP_{21} = 99,82 \%$ e $IP_{22} = 0,18 \%$

Tabela 5.9 – Grupos consolidados para operação completa.

Classificação		Centro do Grupo	
Grupo	Operação	X_1 (posição do laço)	X_2 (velocidade do motor)
G01	normal	0,02	0,84
G02	normal	0,81	0,81
G03	normal	0,95	0,85
G04	normal	0,82	0,68
G05	normal	0,93	0,95
G06	falha	0,72	0,56
G07	falha	0,72	0,42
G08	falha	0,64	0,14
G09	falha	0,03	0,15
G10	falha	0,02	0,28
G11	falha	0,03	0,40
G12	falha	0,02	0,58
G13	falha	0,71	0,24
G14	falha	0,85	0,27
G15	falha	0,96	0,42
G16	falha	0,96	0,59
G17	falha	0,95	0,74
G18	falha	0,65	0,01
G19	falha	0,06	0,00

Tabela 5.10 – Intervenções do operador para operação completa.

Nº da Amostra	Rotulagem Realizada
3	normal
104	normal
159	normal
187	normal
224	normal
229	normal
2486	normal
2524	normal
2769	normal
3175	normal
3211	falha
3227	falha
3247	falha
3410	falha
3413	falha
3416	falha
3520	falha
3845	falha
3875	falha
3880	falha
3911	falha
3941	falha
4406	falha
4508	falha
4581	falha
4688	falha

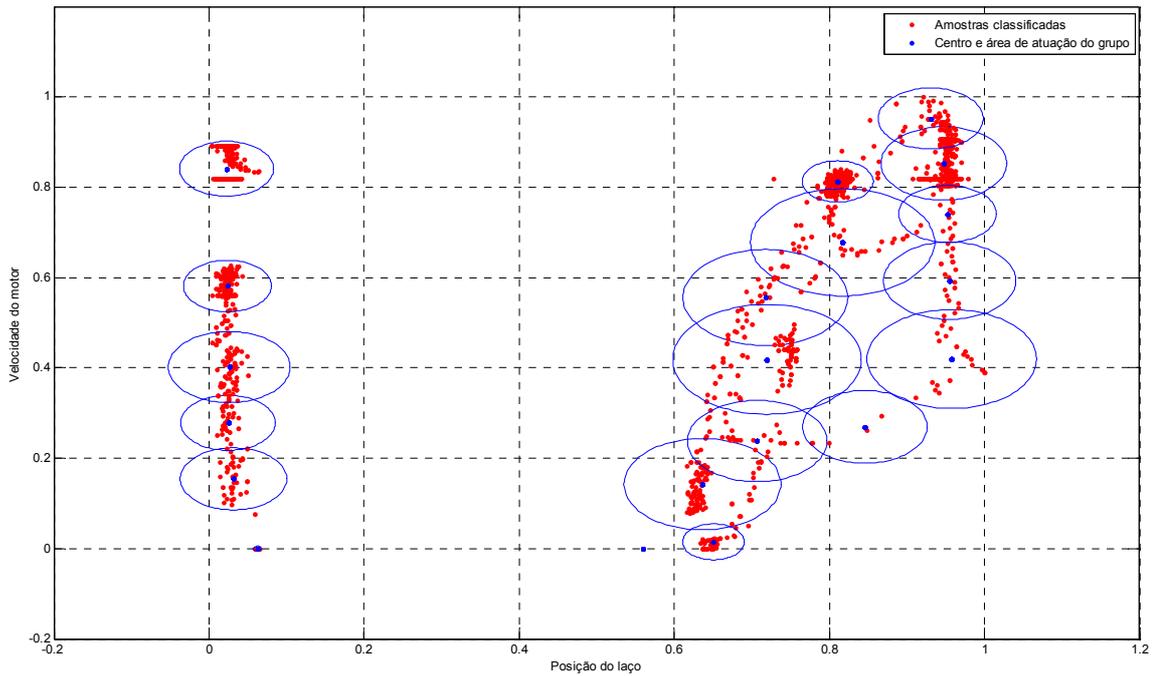


Figura 5.17 – Grupos identificados no conjunto completo de amostras.

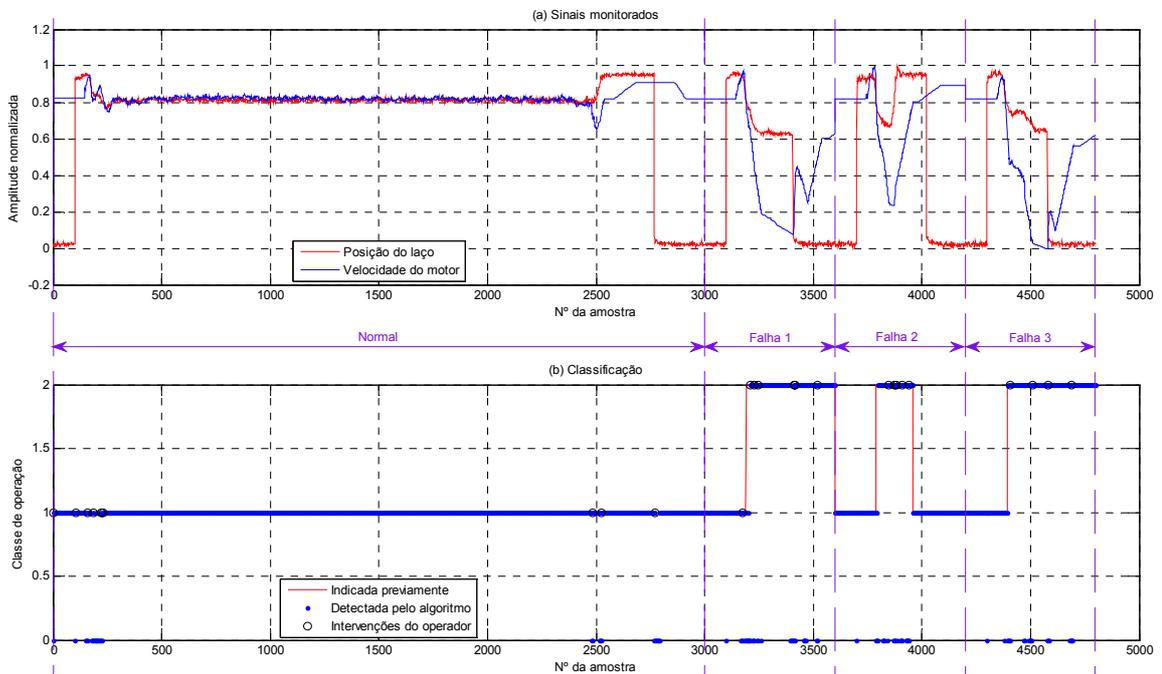


Figura 5.18 – Amostras da operação completa.

5.6.6 Síntese dos Resultados

Os resultados dos cinco testes apresentados nas Tabelas 4.1, 4.3, 4.5, 4.7 e 4.9 estão rearranjados na Tabela 5.11. Todos os grupos identificados nos testes com arquivos separados (normal, falha 1, falha 2 e falha 3), foram associados aos grupos consolidados G01 a G19 considerando o critério de maior grau de pertinência entre eles.

Os centros dos 19 grupos identificados pelo AAPM a partir do conjunto completo de amostras e os respectivos círculos de ação estão plotados na Figura 5.19 (em azul). Também estão plotados nesta figura (conforme legenda), os centros dos grupos identificados nos testes com arquivos separados.

Pode-se notar que os grupos G01 e G03 são condições de operação comuns aos quatro conjuntos de amostras. Outros grupos representam condições de operação exclusivas de cada conjunto de amostras (G08 e G10 para falha 1; G14 a G16 para falha 2; G18 e G19 para falha 3). Existem ainda outros grupos que são condições de operação comuns a dois ou mais conjuntos de amostras, mas não a todos (G02, G04 a G07, etc.).

Tabela 5.11 – Comparação dos grupos consolidados nos cinco testes.

Classificação		Completo		Normal		Falha 1		Falha 2		Falha 3	
Grupo	Operação	X₁	X₂								
G01	normal	0,02	0,84	0,02	0,85	0,02	0,82	0,02	0,86	0,02	0,82
G02	normal	0,81	0,81	0,81	0,81	-	-	0,83	0,85	-	-
G03	normal	0,95	0,85	0,95	0,87	0,95	0,84	0,94	0,81	0,94	0,83
G04	normal	0,82	0,68	0,85	0,68	-	-	-	-	0,82	0,76
G05	normal	0,93	0,95	-	-	0,93	0,95	0,93	0,96	0,94	0,93
G06	falha	0,72	0,56	-	-	0,75	0,65	0,73	0,61	0,78	0,60
G07	falha	0,72	0,42	-	-	0,67	0,48	0,69	0,48	0,75	0,43
G08	falha	0,64	0,14	-	-	0,63	0,14	-	-	-	-
G09	falha	0,03	0,15	-	-	0,06	0,09	-	-	0,03	0,17
G10	falha	0,02	0,28	-	-	0,03	0,28	-	-	-	-
G11	falha	0,03	0,40	-	-	0,03	0,40	-	-	0,02	0,35
G12	falha	0,02	0,58	-	-	0,02	0,59	-	-	0,02	0,57
G13	falha	0,71	0,24	-	-	0,65	0,30	0,69	0,27	0,71	0,20
G14	falha	0,85	0,27	-	-	-	-	0,82	0,26	-	-
G15	falha	0,96	0,42	-	-	-	-	0,96	0,42	-	-
G16	falha	0,96	0,59	-	-	-	-	0,96	0,59	-	-
G17	falha	0,95	0,74	-	-	-	-	-	-	-	-
G18	falha	0,65	0,01	-	-	-	-	-	-	0,65	0,02
G19	falha	0,06	0,00	-	-	-	-	-	-	0,06	0,00

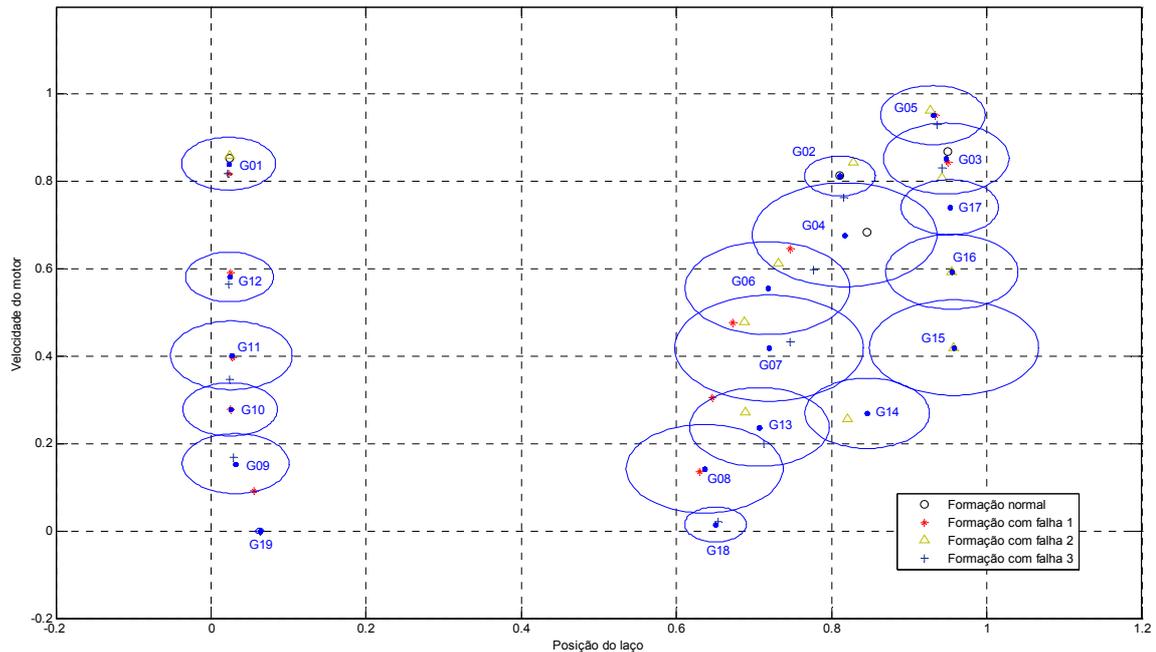


Figura 5.19 – Mapa geral de identificação dos grupos consolidados.

A Tabela 5.12 deve ser entendida como uma justaposição da Tabela 5.10 (do lado esquerdo) com as Tabelas 5.2, 5.4, 5.6 e 5.8 (do lado direito), indicando de forma comparativa as intervenções do operador nos cinco testes realizados. Enquanto o somatório de intervenções nos quatro arquivos separados de amostras chega a 45, no arquivo completo ele não passa de 26.

O número menor de intervenções do operador no arquivo completo ocorreu porque o AAPM foi acumulando o conhecimento sobre as condições de operação apresentadas. Em outras palavras, o AAPM não teve necessidade de criar novos grupos quando condições de operação se repetiram nos conjuntos de amostras subsequentes.

Observe que as condições de operação normal identificadas no primeiro conjunto de amostras dos dois arquivos são idênticas (9 intervenções nas mesmas amostras: 3 a 2769). Por outro lado as 4 primeiras intervenções do operador no conjunto de amostras da falha 1 (amostras 3, 102, 167 e 171), relativas às condições de operação normal, não tiveram as suas equivalentes intervenções no arquivo completo (amostras 3003, 3102, 3167 e 3171).

Se continuarmos analisando os dados da tabela com este foco, verifica-se que a situação se repete para diversas outras condições de falha (por exemplo, para as

amostras 3793, 3817, 4393, 4647, etc.). Estas observações são congruentes com as discussões feitas anteriormente sobre os grupos apresentados na Tabela 5.11 e Figura 5.17. Este comportamento de aprendizagem é um dos preceitos do classificador evolutivo discutido no capítulo 1 (item 1.3).

Tabela 5.12 – Comparação das intervenções do operador nos cinco testes.

Arquivo Completo		Arquivos Separados		
Amostra	Rotulagem	Amostra	Rotulagem	Tipo
3	normal	3	normal	Normal
104	normal	104	normal	
159	normal	159	normal	
187	normal	187	normal	
224	normal	224	normal	
229	normal	229	normal	
2486	normal	2486	normal	
2524	normal	2524	normal	
2769	normal	2769	normal	Falha 1
3003	-	3	normal	
3102	-	102	normal	
3167	-	167	normal	
3171	-	171	normal	
3175	normal	175	-	
3187	-	187	normal	
3199	-	199	falha	
3211	falha	211	-	
3220	-	220	falha	
3227	falha	227	-	
3238	-	238	falha	
3247	falha	247	-	
3258	-	258	falha	
3410	falha	410	falha	
3413	falha	413	falha	
3416	falha	416	falha	
3520	falha	520	falha	Falha 2
3603	-	3	normal	
3703	-	103	normal	
3762	-	162	normal	
3793	-	193	falha	
3817	-	217	falha	
3837	-	237	falha	
3845	falha	245	-	
3872	-	272	falha	
3875	falha	275	-	
3880	falha	280	falha	
3911	falha	311	falha	
3941	falha	341	falha	
4020	-	420	normal	

Arquivo Completo		Arquivos Separados		
Amostra	Rotulagem	Amostra	Rotulagem	Tipo
4203	-	3	normal	Falha 3
4303	-	103	normal	
4363	-	163	normal	
4386	-	186	normal	
4393	-	193	falha	
4402	-	202	falha	
4406	falha	206	-	
4477	-	277	falha	
4500	-	300	falha	
4508	falha	308	-	
4581	falha	381	falha	
4585	-	385	falha	
4647	-	447	falha	
4678	-	478	falha	
4688	falha	488	-	
Total intervenções = 26		Total intervenções = 45		

Na Tabela 5.13 podem-se comparar rapidamente os indicadores de desempenho apresentados anteriormente. Imediatamente nota-se que o indicador IP_1 do arquivo de amostras completo (5,63%), reflete o menor percentual de intervenções do operador, conforme comentado anteriormente. Outra observação importante é que o indicador IP_{21} deste mesmo arquivo (99,82%), realça o alto grau de confiabilidade do AAPM após a identificação dos grupos consolidados.

Tabela 5.13 – Comparação dos indicadores nos cinco testes.

Arquivo de Amostras	Indicadores de desempenho do AAPM (%)			
	IP_1 (não classificado)	IP_2 (classificado)	IP_{21} (acerto)	IP_{22} (erro)
Normal	3,17	96,83	100,00	0,00
Falha 1	12,83	87,17	100,00	0,00
Falha 2	13,83	86,17	99,42	0,58
Falha 3	10,00	90,00	100,00	0,00
Completo	5,63	94,37	99,82	0,18

6. Conclusão

6.1 Problemas Encontrados

Sem dúvida nenhuma a grande dificuldade encontrada foi fazer com que a mudança de perspectiva de agrupamento dos dados ao longo da amostragem não interferisse na identificação dos grupos de forma a perder informações. Durante os primeiros testes era comum a ocorrência de agrupamentos indesejados, onde condições de operação distintas estavam em uma vizinhança muito próxima. Foi por causa desta dificuldade que surgiu a idéia de se usar o conceito de R_{min} , garantindo a correta identificação dos grupos e uma maior eficiência do gerenciamento de criação e fusão dos mesmos.

6.2 Principais Contribuições

Dentre as contribuições deste trabalho pode-se destacar:

- Redução do número de parâmetros a serem ajustados quando se compara o AAPM com o algoritmo original.
- Inovação no tratamento dos *outliers* com a introdução do conceito de grupos candidatos e grupos consolidados, incluindo os novos métodos de gerenciamento dos índices de alerta.

6.3 Conclusão Final

A metodologia do *Algoritmo de Agrupamento Participativo Modificado*, proposta neste trabalho, é o resultado de pesquisas na área de *Detecção e Diagnóstico de Falhas* usando *Sistemas Evolutivos Inteligentes*, especificamente na área de *Aprendizado Participativo*. O *Agrupamento Participativo* tem semelhanças com o agrupamento do tipo particional. As diferenças estão no fato do número de grupos não ser definido a priori e este número variar dinamicamente durante a execução do algoritmo; além dos centros dos grupos serem ajustados gradativamente utilizando o conceito de aprendizagem participativa. Este algoritmo é capaz de definir o número de grupos de acordo com os dados de entrada e por isto é chamado de não supervisionado.

O AAPM foi aplicado para detecção e diagnóstico de falhas em dois sistemas dinâmicos diferentes, sendo um com dados de simulação e outro com dados reais de uma planta industrial. O algoritmo foi capaz de detectar e identificar todas as condições de operação e se mostrou robusto aos ruídos gerados na transição dos modos de operação graças ao eficiente mecanismo de alerta.

6.4 Trabalhos Futuros

As aplicações do AAPM aqui apresentadas utilizaram dados de simulação e dados históricos, isto é, o algoritmo não foi testado operando em tempo real. Avaliações de desempenho do tipo *tempo de processamento* e *tempo de atraso na detecção* deverão ser feitas com o AAPM operando *online*, principalmente em sistemas dinâmicos rápidos como os motores de indução. A continuação deste trabalho seria codificar o AAPM em uma linguagem de máquina aplicável aos sistemas de automação do ambiente industrial e verificar seu comportamento em tempo real.

Existem sistemas dinâmicos cujas falhas são sinalizadas em forma de tendência. Dentre eles podem-se citar as falhas causadas por excesso de vibração de máquinas, onde a análise dos sinais de vibração no domínio da frequência pode indicar uma mudança das condições de operação da máquina. A experiência do autor deste trabalho na área sistemas de automação industrial ao longo de anos permite-lhe dizer que as perspectivas de aplicação imediata do AAPM em sistemas deste tipo são animadoras.

Uma vez que os centros dos grupos estão associados aos pontos de operação de um equipamento industrial qualquer, vislumbra-se para este algoritmo a aplicação no campo das manutenções preditiva e corretiva, possibilitando diagnóstico de falhas incipientes. Neste caso a ideia é acompanhar a tendência dos pontos de operação dos equipamentos e tratar os desvios. Os ganhos esperados são a maior disponibilidade dos equipamentos, uma vez que se reduzem as paradas operacionais e as perdas decorrentes de manutenções corretivas, assim como a melhor utilização dos equipamentos, pois os componentes somente serão substituídos ao final de sua vida útil.

Bibliografia

- [CAM 96] CAMINHAS, W. M.; TAVARES, H. M. F.; GOMIDE, F. Rede Lógica Neurofuzzy: Aplicação em Diagnóstico de Falhas em Sistemas Dinâmicos. *Anais do XI Congresso Brasileiro de Automática*, v. 1, p. 459-464, 1996.
- [CAM 97] CAMINHAS, W. M. Estratégias de Detecção e Diagnóstico de Falhas em Sistemas Dinâmicos. *Tese de Doutorado apresentada à Universidade Estadual de Campinas*, 1997.
- [FIL 06] FILEV, D.; TSENG, F. Novelty detection based machine health prognostics, *Evolving Fuzzy Systems, 2006 International Symposium*, p. 193–199, 2006.
- [FRA 90] FRANK, P. M. Fault Diagnosis in Dynamic Systems using Analytical and Knowledge Based Redundancy – A Survey and Some New Results. *Automática*, v. 26, n. 3, p. 459-474, 1990.
- [INA 09] INÁCIO, M. J.; MAIA, R. D.; LE-SE, A. P.; CAMINHAS, W.M. Aprendizado Participativo Aplicado à Detecção e Diagnóstico On-Line de Falhas em Sistemas Dinâmicos. *Anais do IX Congresso Brasileiro de Redes Neurais / Inteligência Computacional*, 2009.
- [KAS 06] KASABOV, N.; FILEV, D. Evolving Intelligent Systems: Methods, Learning & Applications. *2006 International Symposium on Evolving Fuzzy Systems*, IEEE Press, p. 8-18, 2006.
- [LEM 10] LEMOS, A. P.; CAMINHAS, W.M.; GOMIDE, F. Modelo Adaptativo Nebuloso Para Detecção e Diagnóstico de Falhas. *Anais do XVIII Congresso Brasileiro de Automática*, 2010.
- [LIM 08] LIMA, E. M. Modelagem Fuzzy Funcional Evolutiva Participativa. *Dissertação apresentada à Faculdade de Engenharia Elétrica e de Computação da UNICAMP*, 2008.
- [LUG 08] LUGHOFFER, E.; C., G. On-line fault detection with data-driven evolving fuzzy models, *Control and Intelligent Systems*, v 36, n. 4, p. 307–317, 2008.
- MAR 03a] MARKOU, M.; SINGH, S. Novelty detection: A review part 1: Statistical approaches, *Signal Processing*, v. 83, p. 2499–2521, 2003.

- [MAR 03b] MARKOU, M.; SINGH, S. Novelty detection: A review part 2: Neural networks based approaches, *Signal Processing*, v. 83, p. 2481–2497, 2003.
- [MON 01] MONTGOMERY, D. Introduction to Statistical Quality Control, fourth edition, Wiley, 2001.
- [RAJ 06] RAJAGOPALAN, V.; RAY, A. Symbolic time series analysis via wavelet-based partitioning, *Signal Processing*, v. 86, n. 11, p. 3309 – 3320, 2006.
- [SIL 03] SILVA, L. Aprendizagem Participativa em Agrupamento Nebuloso de Dados. *Dissertação apresentada à Faculdade de Engenharia Elétrica e de Computação da UNICAMP*, 2003.
- [TIM 08] TIMUSK, M.; LIPSETT, M.; MECHEFSKE, C.K. Fault detection using transient machine signals, *Mechanical Systems and Signal Processing*, v. 22, n. 7, p. 1724–1749, 2008.
- [VEN 02a] VENKATASUBRAMANIAN, V; RENGASWAMY, R; YIN, K; KAVURI, S. N. A review of process fault detection and diagnosis – part I: Quantitative model-based methods, *Computers and Chemical Engineering*, v 27, p. 293–311, 2002.
- [VEN 02b] VENKATASUBRAMANIAN, V; RENGASWAMY, R; YIN, K; KAVURI, S. N. A review of process fault detection and diagnosis – part II: Qualitative models and search strategies, *Computers and Chemical Engineering*, v 27, p. 313–326, 2002.
- [VEN 02c] VENKATASUBRAMANIAN, V; RENGASWAMY, R; YIN, K; KAVURI, S. N. A review of process fault detection and diagnosis – part III: Process history based methods, *Computers and Chemical Engineering*, v 27, p. 327–346, 2002.
- [WAN 08] WANG, W; VRBANEK, J. An evolving fuzzy predictor for industrial applications, *Fuzzy Systems, IEEE Transactions*, v 16, n. 6, p. 1439–1449, 2008.
- [WON 06] WONG, M.; JACK, L.; NANDI, A. Modified self-organizing map for automated novelty detection applied to vibration signal monitoring, *Mechanical Systems and Signal Processing*, v. 20, n. 3, p. 593–610, 2006.
- [WOR 03] Working Sequences Manual - Loops, Loop Regulations and Tension Control. *Wire Rod Mill by SMS Demag Group*, 2003.

- [YAG 90] YAGER, R. R. A model of participatory learning, *IEEE Transactions on Systems, Man and Cybernetics*, v. 20, n. 05, p. 1229-1234, 1990.
- [YAG 04] YAGER, R. R. Participatory learning: a paradigm for more human like learning. *2004 IEEE International Conference on Fuzzy Systems, FUZZ-IEEE*, Budapest, Hungary, p. 79-84, 2004.