



Universidade Federal do Amazonas  
Faculdade de Tecnologia  
Programa de Pós-Graduação em Engenharia Elétrica

# Esquema de Detecção e Diagnóstico de Falhas Baseado em Dados para Benchmark de Turbina Eólica

Iury Valente de Bessa

Manaus – Amazonas  
Setembro de 2015

Iury Valente de Bessa

**Esquema de Detecção e Diagnóstico de Falhas  
Baseado em Dados para Benchmark de Turbina Eólica**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, como requisito parcial para obtenção do Título de Mestre em Engenharia Elétrica. Área de concentração: Automação e Controle.

Orientador: João Edgar Chaves Filho

Coorientador: Reinaldo Martinez Palhares (UFMG)

Iury Valente de Bessa

**Esquema de Detecção e Diagnóstico de Falhas  
Baseado em Dados para Benchmark de Turbina Eólica**

Banca Examinadora

Prof. Dr. Reinaldo Martinez Palhares – Presidente e Coorientador

Departamento de Engenharia Eletrônica – UFMG

Prof. Dr. Flávio José Aguiar Soares

Departamento de Automação e Produção– IFAM

Prof. Dr-Ing Vicente Ferreira de Lucena Junior

Departamento de Eletrônica e Computação – UFAM

Manaus – Amazonas

Setembro de 2015

# Agradecimentos

Agradeço primeiramente à minha mãe e meu pai, Ana Cláudia e Arthur, por me acompanharem, apoiarem e guiarem desde sempre. À minha noiva, Dani, por todo amor, compreensão e apoio, e por ter sido a razão da minha luta ao longo dos últimos anos.

Agradeço aos amigos e colegas da UFAM que acumulei ao longo da graduação e do mestrado.

Agradeço ao Prof. João Edgar por todos os ensinamentos, conselhos, orientações, suporte ao longo da graduação e mestrado.

Agradeço aos Prof. Reinaldo Palhares e Marcos Flávio D'Angelo pela grande contribuição e orientação nesta pesquisa.

Agradeço ao Prof. Lucas Cordeiro pelas oportunidades, confiança, colaboração e exemplo.

Agradeço às instituições que fomentaram esta pesquisa: FAPEAM, CETELI e SAM-SUNG.

Agradeço finalmente a toda a equipe de professores PPGEE/UFAM que ajudaram a sedimentar essa formação.

*The learner always begins by finding fault, but  
the scholar sees the positive merit in  
everything.*

*Georg Wilhelm Friedrich Hegel*

# Resumo

Esse trabalho apresenta um novo esquema para detecção e isolamento de falhas baseado na análise de séries temporais e dados do processo. A metodologia é aplicada a um modelo de turbina eólica, e ilustra o potencial da abordagem proposta no contexto de energia renovável. A estratégia proposta é realizada em duas etapas e se baseia apenas em dados do processo sem o uso de qualquer tipo de modelo matemático do sistema. O primeiro passo, a detecção de falha, é realizado com base em amostragem de Gibbs, no qual a ocorrência de uma falha, seja ela num sensor, num atuador ou na planta, é modelada como uma detecção de novidades em séries temporais. O segundo passo, é o isolamento de falhas, realizado por meio de redes fuzzy/Bayesianas capazes de classificar cada tipo de falha de forma isolada ou simultânea. A abordagem proposta apresentou bons resultados para detecção e diagnóstico de falhas em sensores num benchmark padrão de turbina eólica. O trabalho ainda apresenta propostas de extensão da pesquisa com melhorias no sistema de detecção e isolamento de falhas e formulação de sistemas de controle tolerante a falhas também baseados em dados.

Palavras-chave: detecção e isolamento de falhas (FDI), turbinas eólicas, redes fuzzy/Bayesianas, amostragem de Gibbs.

# Abstract

This paper investigates a new scheme for fault detection and isolation based on time series and data analysis. This scheme is applied in a wind turbine model and illustrates the power of the proposed approach in the context of renewable energy. The proposed scheme is performed in two steps and it is based on process data without using any kind of mathematical modeling. The first step, the fault detection, is based on an alternative method based on the Gibbs sampling algorithm in which the occurrence of a sensor fault is modeled as a change point detection in a time series. The second step, the fault isolation, is handled via a Fuzzy/Bayesian network scheme classifying the kind of fault. This approach presented a good performance for detection and diagnostics of sensor faults in a standard wind turbine benchmark. In addition, this work presents proposals for research extension with enhancements of the fault detection and isolation system and formulation of fault tolerant control system.

Keywords: Fault detection and isolation (FDI), wind turbines, fuzzy/Bayesian networks, Gibbs sampling.

# Sumário

<b>Lista de Figuras</b>	<b>iv</b>
<b>Lista de Tabelas</b>	<b>vi</b>
<b>Abreviações</b>	<b>vii</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Energia Eólica: Evolução e Paradigma . . . . .	1
1.1.1 Desenvolvimento Histórico da Energia Eólica . . . . .	1
1.1.2 Energia Eólica no Brasil . . . . .	4
1.1.3 Vantagens e Desvantagens da Energia Eólica . . . . .	6
1.2 Objetivos e Escopo do trabalho . . . . .	7
1.3 Metodologia . . . . .	8
1.4 Organização do trabalho . . . . .	9
<b>2 Turbinas eólicas</b>	<b>10</b>
2.1 Visão geral sobre as Turbinas Eólicas . . . . .	10
2.1.1 Aerodinâmica das Turbinas Eólicas . . . . .	11
2.1.2 Velocidade do Vento . . . . .	12
2.1.3 Controle da turbina eólica . . . . .	13
2.2 Benchmark da Turbina Eólica . . . . .	15
2.2.1 Subsistemas do <i>benchmark</i> . . . . .	15
2.2.2 Perfil do vento e falhas . . . . .	19
2.3 Falhas em Turbinas Eólicas . . . . .	22
2.3.1 Falhas comuns em Turbinas Eólicas . . . . .	22
2.3.2 Sistemas de FDI para Turbinas Eólicas . . . . .	23

---

2.4	Conclusão . . . . .	28
<b>3</b>	<b>Fundamentação Teórica</b>	<b>29</b>
3.1	Transformação de séries temporais em processos de contagem Poisson via conjuntos <i>fuzzy</i> . . . . .	29
3.2	Amostragem de Gibbs para detecção de pontos de mudança . . . . .	32
3.2.1	Um modelo de ponto de mudança . . . . .	33
3.2.2	Distribuições Condicionais Completas . . . . .	34
3.2.3	Um exemplo ilustrativo . . . . .	35
3.3	Redes <i>fuzzy</i> /Bayesianas . . . . .	35
3.4	Conclusão . . . . .	37
<b>4</b>	<b>Arquitetura e Metodologia de FDI</b>	<b>38</b>
4.1	Arquitetura do Sistema de FDI . . . . .	38
4.2	Algoritmo de FDI proposto . . . . .	39
4.3	Implementação do sistema de FDI proposto . . . . .	40
4.3.1	Geração do banco de sinais . . . . .	41
4.3.2	Ajuste do amostrador de Gibbs . . . . .	41
4.3.3	Seleção de sinais representativos . . . . .	42
4.3.4	Treinamento das redes fuzzy-Bayesianas . . . . .	43
4.4	Conclusão . . . . .	43
<b>5</b>	<b>Aplicação da metodologia de FDI para o <i>benchmark</i> de turbina eólica</b>	<b>45</b>
5.1	Perfil de vento e potência gerada . . . . .	45
5.2	Aspectos críticos da implementação . . . . .	46
5.3	Resultados . . . . .	49
5.3.1	Sequência de padrão de falhas . . . . .	49
5.3.2	Testes com falhas simultâneas . . . . .	54
5.4	Conclusão . . . . .	55
<b>6</b>	<b>Conclusões</b>	<b>61</b>
6.1	Proposta para Trabalhos Futuros . . . . .	62
6.1.1	Adição de novos sinais representativos . . . . .	63

---

6.1.2	Um sistema de FTC data-driven baseado em dados . . . . .	63
<b>A</b>	<b>Supervisão, Detecção e Diagnóstico de Falhas: Perspectivas Históricas</b>	<b>65</b>
A.1	Definições e Terminologia . . . . .	66
A.2	Propriedades relativas ao funcionamento dos sistemas . . . . .	68
A.3	Tipologia das falhas . . . . .	69
A.4	Avaliação de Sistemas de FDI . . . . .	70
A.5	Revisão de Técnicas de Detecção de Falhas . . . . .	71
A.5.1	Técnicas de Detecção de Falhas Baseadas em Modelo . . . . .	72
A.5.2	Técnicas de Detecção de Falhas Baseadas em Dados . . . . .	76
A.6	Revisão de Técnicas de Isolamento de Falhas . . . . .	79
A.6.1	$K$ Vizinhos Mais Próximos (KNN) . . . . .	80
A.6.2	Redes Neurais Artificiais (ANN) . . . . .	80
A.6.3	Máquina de Vetores de Suporte (SVM) . . . . .	81
A.6.4	Lógica <i>fuzzy</i> . . . . .	81
A.6.5	Sistemas Imunológicos Artificiais (AIS) . . . . .	82
A.6.6	Redes Bayesianas . . . . .	83
<b>B</b>	<b>Controle Tolerante a Falhas</b>	<b>84</b>
B.0.7	Controle tolerante a falhas passivo . . . . .	85
B.0.8	Acomodação de Falhas . . . . .	85
B.0.9	Controle Reconfigurável . . . . .	85
	<b>Referências Bibliográficas</b>	<b>93</b>

# Lista de Figuras

1.1	Parque Eólico <i>onshore</i> em Palm Spring na Califórnia. Fonte: Acervo pessoal de Reinaldo Martinez Palhares. . . . .	3
1.2	Parque Eólico <i>offshore</i> de London Array no Reino Unido. Fonte: <a href="http://www.londonarray.com">www.londonarray.com</a> . . . . .	4
1.3	Parque Eólico de Osório no Rio Grande do Sul. Fonte: <a href="http://www.forumdaenergia.com.br">www.forumdaenergia.com.br</a> . . . . .	5
2.1	Principais componentes de uma turbina eólica [1]. . . . .	11
2.2	Visão geral do <i>benchmark</i> de Turbina Eólico [2]. . . . .	16
2.3	Zonas de operação da turbina eólica [2]. . . . .	19
3.1	Funções de pertinência . . . . .	32
3.2	Resultados da aplicação da amostragem de Gibbs. . . . .	36
4.1	Implementação do Sistema de FDI. . . . .	39
4.2	<i>framework</i> para FDI. . . . .	44
5.1	Perfil da velocidade de vento utilizada para o teste do esquema de FDI. . . . .	46
5.2	Torque no gerador na simulação do <i>benchmark</i> com o perfil de velocidade da Figura 5.1. . . . .	46
5.3	Potência gerada pelo modelo de turbina eólica diante do perfil de velocidade da Figura 5.1. . . . .	47
5.4	Indicação da Falha 1. . . . .	50
5.5	Indicação da Falha 3. . . . .	50
5.6	Indicação da Falha 4. . . . .	51
5.7	Indicação da Falha 5. . . . .	51
5.8	Indicação da Falha 2. . . . .	52
5.9	Indicação da Falha 9. . . . .	52

---

5.10	Indicação da Falha 8. . . . .	53
5.11	Indicação de probabilidade para as falhas detectadas e isoladas. . . . .	54
5.12	Indicação de probabilidade para uma falha incipiente de baixa magnitude. . . . .	55
5.13	Indicação da Falha 1 em teste com falhas simultâneas. . . . .	57
5.14	Indicação da Falha 3 em teste com falhas simultâneas. . . . .	57
5.15	Indicação da Falha 5 em teste com falhas simultâneas. . . . .	58
5.16	Indicação da Falha 2 em teste com falhas simultâneas. . . . .	58
5.17	Indicação da Falha 4 em teste com falhas simultâneas. . . . .	59
5.18	Indicação da Falha 6 em teste com falhas simultâneas. . . . .	59
5.19	Indicação da Falha 8 em teste com falhas simultâneas. . . . .	60
A.1	Classificação das técnicas de detecção de falhas. . . . .	72

# Lista de Tabelas

2.1	Sensores disponíveis no <i>benchmark</i> de turbina eólica. . . . .	20
2.2	Configuração padrão de falhas. . . . .	21
5.1	Configuração de falhas simultâneas. . . . .	56

# Abreviações

- FDI** - *Detecção e Isolamento de Falhas - do inglês **F**ault **D**etection and **I**solation*
- FTC** - *Controle Tolerante a Falhas - do inglês **F**ault **T**olerant **C**ontrol*
- PROINFA** - *Programa de Incentivo às Fontes Alternativas de Energia*
- IFAC** - *Federação e Internacional de Controle Automático - do inglês **I**nternational **F**ederation of **A**utomatic **C**ontrol*
- RAM** - *Confiabilidade, Disponibilidade e Manutenibilidade - do inglês **R**eliability, **A**vailability and **M**aintainability*
- MTTF** - *Tempo médio para falta - do inglês **M**ain **T**ime **T**o **F**ailure*
- MTTR** - *Tempo médio para conserto - do inglês **M**ain **T**ime **T**o **R**epair*
- FAR** - *Taxa de Alarmes Falsos - do inglês **F**alse **A**larms **R**ate*
- FDR** - *Taxa de Detecção de Falhas - do inglês **F**ault **D**etection **R**ate*
- LIT** - *Linear Invariante no Tempo*
- PI** - *Proporcional Integral*
- PMI** - *Proporcional Multivariável Integral*
- PD** - *Proporcional Derivativo*
- EKF** - *Filtro de Kalman Estendido - do inglês **E**xtended **K**alman **F**ilter*
- UKF** - *Filtro de Kalman unscented - do inglês **U**nscented **K**alman **F**ilter*
- ANFIS** - *Sistema de Inferência Fuzzy baseada em Redes Adaptativas - do inglês **A**daptative-**N**etwork-based **F**uzzy **I**nterference **S**ystem*
- STFT** - *Transformada de Fourier de curto termo - do inglês **S**hort **T**ime **F**ourier **T**ransform*
- FFT** - *Transformada Rápida de Fourier - do inglês **F**ast **F**ourier **T**ransform*
- HHT** - *Transformada de Hilberg-Huang - do inglês **H**ilberg-**H**uang **T**ransform*
- WVD** - *Transformada de Wigner-Ville - do inglês **W**igner-**V**ille **T**ransform*
- QTA** - *Análise Qualitativa de Tendências - do inglês **Q**ualitative **T**rends **A**nalysis*

- PCA** - *Análise de Componentes Principais - do inglês Principal Component Analysis*
- ICA** - *Análise de Componentes Independentes - do inglês Independent Components Analysis*
- SVM** - *Máquina de Vetores de Suporte - do inglês Support Vector Machine*
- PLS** - *Mínimos Quadrados Parciais - do inglês Partial Least Squares*
- KNN** - *K Vizinhos mais Próximos - do inglês K Nearest Neighbor*
- WKNN** - *K Vizinhos mais Próximos Ponderados - do inglês Weighted K Nearest Neighbor*
- EWKNN** - *K Vizinhos mais Próximos Ponderados Melhorado - do inglês Enhanced Weighted K Nearest Neighbor*
- SCADA** - *Sistema de Supervisão e Aquisição de Dados - do inglês Supervisory Control And Data Acquisition*
- ANN** - *Rede Neural Artificial - do inglês Artificial Neural Network*
- RBF** - *Função de Base Radial - do inglês Radial Basis Function*
- SOM** - *Mapa Auto-organizável - do inglês Self-Organizing Map*
- SVDD** - *Descrição de Dados de Vetores de Suporte - do inglês Support Vector Data Description*
- AIS** - *Sistema Imunológico Artificial - do inglês Artificial Immune System*
- NK** - *do inglês Natural Killers*
- DFIG** - *Gerador de Indução Duplamente Alimentado - do inglês Doubly Fed Induction Generator*
- FMECA** - *Análise de Modos de Falha e seus Efeitos e Criticalidade - do inglês Failure Mode, Effects, Criticality Analysis*
- GLR** - *Razão de Verossimilhança Generalizada - do inglês Generalized Likelihood Ratio*
- MCMC** - *Monte Carlo via Cadeia de Markov*
- AFTC** - *Controle Tolerante a Falhas Ativo - do inglês Active Fault Tolerant Control*
- PFTC** - *Controle Tolerante a Falhas Passivo - do inglês Passive Fault Tolerant Control*
- CR** - *Reconfiguração de Controle - do inglês Control Reconfiguration*
- FA** - *Acomodação de Falhas - do inglês Fault Accommodation*
- MM** - *Modelos Múltiplos*
- LPV** - *Lineares com parâmetros variantes - do inglês Linear Parameter Varying*
- PWA** - *do inglês Piecewise Affine*

# Capítulo 1

## Introdução

A detecção de falhas é uma tecnologia multidisciplinar, a qual emprega conhecimentos de diversas disciplinas, como teoria de controle, reconhecimento de padrões, processos estocásticos entre outras, e apresenta aplicações em diversos campos da engenharia, como em processos automotivos, petroquímicos, de geração e transmissão de energia, aeroespaciais, entre outros. Estes processos vêm se desenvolvendo se tornando cada vez mais complexos e automático. Nesse desenvolvimento é crescente a demanda por confiabilidade e segurança o que motiva a formulação de sistemas de diagnóstico de falhas e de controle tolerante a falhas. Este trabalho propõe uma nova metodologia de diagnóstico e isolamento de falhas se preocupando com requisitos de desempenho relevantes para o seu emprego em controle tolerante a falhas. O sistema proposto é empregado em um sistema de turbina eólica que oferece naturalmente diversos desafios para a tarefa e diagnóstico de falhas, como um modelo complexo e a forte interferência do vento nas medidas do processo, cujo comportamento é de difícil previsão.

### 1.1 Energia Eólica: Evolução e Paradigma

Nesta seção será feita uma breve revisão histórica da evolução das tecnologias de energia eólica no Brasil e no mundo.

#### 1.1.1 Desenvolvimento Histórico da Energia Eólica

A energia eólica é uma das mais importantes fontes de energias no atual contexto de intensificação do uso de energias renováveis. O seu emprego apresenta diversas vantagens tanto

em relação as formas tradicionais de energia quanto as demais formas de energia renováveis, sobretudo porque já apresentam um grande grau de desenvolvimento consolidado.

Essa modalidade de energia tem sido aproveitada pela humanidade por milênios. Seu uso inicial data da antiguidade, com o emprego dos primeiros veleiros pelos Fenícios, Gregos e Romanos, tendo se tornado a principal forma de energia para transporte intercontinental durante o período das Grandes Navegações. Em terra firme, o aproveitamento do vento como força motriz para auxílio no bombeamento de água e moagem de grãos tem origem com o emprego de cata-ventos pela China, Pérsia e Babilônia. Foi na Europa, no entanto, que essa ferramenta se desenvolveu e disseminou com construção de diversos moinhos de ventos de eixo horizontal. Esses moinhos eram instrumentos de poder e captação financeira durante o período medieval, quando os senhores feudais cobravam pelo uso de seus moinhos e criavam leis regulando a concessão de novos moinhos e proibindo plantação de árvores nas proximidades dos moinhos existentes, a fim de assegurar o "direito ao vento". Essas técnicas de aproveitamento de energia eólica entraram em decadência a partir da Revolução Industrial que trouxe o advento da máquina a vapor, apesar disso, até hoje a energia eólica é empregada dessas formas tradicionais.

Foi apenas no final do século XIX e no século XX, com o desenvolvimento e difusão da energia elétrica, que foram intensificadas pesquisas para o aproveitamento da energia eólica para geração de energia elétrica que culminaram na invenção dos aerogeradores, também conhecidos como turbinas eólicas. O primeiro aerogerador automático que se tem notícia, foi erguido por Charles F. Brush na cidade de Cleveland, Ohio, nos Estados Unidos em 1888. A ideia de Brush, um industriário que decidiu investir na eletrificação rural, consistia na utilização de um cata-ventos para a geração de energia elétrica, e trouxe importantes conceitos para geração eólica que são mantidos até hoje. O modelo de emprego de aerogeradores sugerido por Brush, foi o que predominou na difusão da tecnologia nos Estados Unidos, isto é, construção de aerogeradores para suprimento de localidades rurais de difícil acesso.

Paralelamente, na Rússia, foi inventada a Turbina Balaclava, que era um modelo de gerador de grande porte (100kW), o qual foi utilizado na primeira tentativa bem sucedida de conexão desses equipamentos a uma usina termelétrica por meio de linhas de transmissão. Na turbina Balaclava, iniciou-se o emprego de um sistema de controle para regular a velocidade de rotação, e conseqüentemente a potência gerada, por meio da inclinação das pás. O modelo Russo de utilização de turbinas eólicas de grande porte, ainda recebeu algum investimento, inclusive em outros países, surgindo inclusive projetos mais poderosos como o de geradores

de 1MW e 5MW. No entanto, a concorrência da tecnologia de combustíveis fósseis, que se tornaram abundantes e relativamente baratos no mercado, levaram ao abandono, por muitas décadas, de muitos dos projetos mais avançados para aerogeradores.

Um novo ciclo de forte interesse acadêmico e econômico na energia eólica foi iniciado na década de 70, com o choque do petróleo, que motivou a revisão internacional da matriz energética vigente, motivando o investimento em alternativas independentes de combustíveis fósseis. O interesse crescente pela energia eólica voltou a se intensificar com o acidente nuclear de Chernobyl, em 1986, que acabou por frear o desenvolvimento de uma das promissoras alternativas a matriz baseada em combustíveis fósseis. Desde então, o interesse científico e econômico em formas de energia limpas, seguras e de baixo custo ambiental, sobretudo com a difusão de termos como desenvolvimento sustentável e a preocupação recente com o aquecimento global.

Atualmente, existem dois modelos de exploração de energia eólica: a exploração *onshore*, com instalação das turbinas em terra firme; e a exploração *offshore*, com instalação das turbinas nos mares. As usinas eólicas *onshore* se desenvolveram primeiramente e apresentam um custo de instalação muito inferior, além de apresentarem fácil acesso para manutenção. As figuras 1.1 e 1.2 são fotografias de parques de geração de energia eólica *onshore* e *offshore* respectivamente.



Figura 1.1: Parque Eólico *onshore* em Palm Spring na Califórnia. Fonte: Acervo pessoal de Reinaldo Martinez Palhares.



Figura 1.2: Parque Eólico *offshore* de London Array no Reino Unido. Fonte: [www.londonarray.com](http://www.londonarray.com).

As usinas eólicas *offshore* tem atraído forte atenção e investimento mais recentemente e até bem pouco tempo era uma alternativa muito pouco considerada devido ao alto custo associado a instalação e manutenção dessas turbinas. Até o início de 2007 não havia nenhuma instalação de energia eólica *offshore* nos Estados Unidos [3], e até meados de 2012 todo potencial mundial instalado de energia eólica *offshore* era de apenas 4620 MW, o equivalente a cerca de 2% da capacidade total de energia eólica instalada no planeta, desses 4620 MW *offshore* cerca de 90% se concentravam nos mares do Norte, Báltico e da Irlanda [4]. Atualmente, diversos projetos de instalações de parques eólicos *offshore* estão em andamento, motivados principalmente pela maior performance e eficiência desses dispositivos e redução dos impactos ambientais, além do surgimento de diversas restrições em diversos países (como Reino Unido) á construção de turbinas *onshore* por questões habitacionais. Estimativas otimistas prevêm uma ampliação para 80 GW de potencial *offshore* instalado até 2020, dos quais 75% se situarão na Europa.

### 1.1.2 Energia Eólica no Brasil

A energia eólica também vem se desenvolvendo no Brasil, sobretudo desde os anos 2000. Em 2004, o Governo Federal, visando atender a crescente demanda de energia motivada pelo intenso crescimento econômico, estabeleceu o marco regulatório para energia renovável

criando o PROINFA através da Lei nº10438/2. O PROINFA apresentava como característica central a participação privada de produtores independentes autônomos em empreendimentos de energia elétrica relacionados a pequenas centrais hidrelétricas, biomassa e eólica, permitindo a compra dessa energia por parte da União. Ao todo, o PROINFA foi responsável pela instalação de 54 projetos eólicos que integralizaram uma capacidade eólica adicional instalada de 1422,92 MW. O desenvolvimento foi acentuado com a obtenção de espaço, por parte das fontes renováveis e especialmente a eólica, nos leilões de energia, além de outros incentivos governamentais a essa modalidade de energia. Segundo a Associação Brasileira de Energia Eólica (ABEEólica) a capacidade instalada de energia eólica no país passou de 22 MW em 2002 para 6790 MW atualmente. Todo o potencial instalado atualmente é *onshore*. A figura 1.3 mostra o Parque Eólico de Osório, no Rio Grande do Sul, maior parque eólico da América Latina.



Figura 1.3: Parque Eólico de Osório no Rio Grande do Sul. Fonte: [www.forumdaenergia.com.br](http://www.forumdaenergia.com.br).

Apesar do grande crescimento da energia eólica no Brasil, o potencial instalado ainda é muito pequeno se comparado com o potencial do país. Apenas o potencial *onshore* do país é estimado em 300 GW. O potencial *offshore* estimado em 2012 através de um estudo realizado pela PROVENTOS Consultoria foi de 102 GW somente em uma estreita faixa do litoral do estado do Rio Grande do Sul [5]. Apesar de não haver nenhum projeto eólico *offshore* em

andamento, o Ministro Eduardo Braga sinalizou pela primeira vez, em seu discurso de posse, que serão promovidos estudos a inserção dessa modalidade ao mix de energia nacional.

### 1.1.3 Vantagens e Desvantagens da Energia Eólica

A energia eólica apresenta diversas vantagens se comparadas a outras fontes de energia, entre as quais se destacam:

- é limpa, não emitindo gases poluentes nem produzindo qualquer natureza de resíduos;
- Depende de recurso inesgotável: vento;
- Dispensa manutenção frequente;
- Boa rentabilidade energética.

No entanto, é também importante indicar as devantagens do emprego de aerogeradores, entre as quais devem-se citar:

- Intermitência, dependendo do local de instalação, o vento pode não estar disponível a todo momento;
- Impactos ambientais com ruídos sonoros e eletromagnéticos, impossibilitando a sua instalação muito próxima a habitações, além do impacto visual das torres;
- Prejuízos ecológicos devido a acidentes com aves e morcegos;
- Alto investimento inicial devido ao alto preço dos componentes utilizados.

Os dois primeiros itens supracitados constituem os problemas mais relevantes e desafiantes para a comunidade de energia eólica, uma vez que os preços de peças para essas turbinas vem sendo reduzidos a medida que a tecnologia vem se disseminando. Nesse contexto, a energia eólica *offshore* se torna extremamente atrativa, uma vez que a disponibilidade de ventos oceânicos é praticamente constante e menos turbulento (o que possibilita a instalação de torres mais baixas e diminui o estresse mecânico) e essas instalações são distantes o suficiente de áreas habitacionais. Além disso, é possível a instalação de turbinas com alta eficiência, que extraiam o máximo da energia disponível. No entanto, os custos de instalação dessas turbinas é muito superior (de 2 a 3 vezes maiores) aos da instalação das *onshores*. Além disso o custo de uma

visita de manutenção para esses parques *offshore* é muito elevado, e a operação por si só já é desafiadora.

Por essa razão, o fator chave para a energia eólica *offshore* é a confiabilidade, que deve ser maximizada de forma a reduzir o número de manutenções e evitar situações que levem ao desligamento da turbina. O investimento em confiabilidade é o caminho efetivo para tornar as turbinas eólicas, sobretudo as *offshores*, mais lucrativas e aumentar a competitividade dessa tecnologia frente às demais alternativas. Nesse contexto, se fazem extremamente necessárias o desenvolvimento de sistemas de detecção e diagnóstico de falhas (FDI) e sistemas de controle tolerante a faltas (FTC), capazes de prevenir prejuízos materiais ou perda de produtividade.

Este trabalho aborda uma nova metodologia para FDI baseada em dados a qual será validada em um *benchmark* de turbina eólica. O contexto de turbinas eólicas apresenta um problema desafiador para a comunidade de FDI, pois este é um modelo complexo e movido por uma grandeza de comportamento imprevisível e capaz de afetar toda a dinâmica do sistema, isto é, o vento. O levantamento das técnicas de FDI existentes e uma fundamentação sobre supervisão de sistemas é realizado no Apêndice A e um levantamento das técnicas de FTC é feito no Apêndice B.

## 1.2 Objetivos e Escopo do trabalho

O objetivo principal desse trabalho é apresentar uma estratégia de FDI aplicável para um *benchmark* de turbina eólica que seja totalmente baseada em dados do processo, isto é, sem o uso de qualquer modelagem matemática da dinâmica do processo. A estratégia de FDI a ser apresentada se dividirá em dois módulos: o módulo de detecção de falhas e o módulo de isolamento de falhas. O módulo de diagnóstico de falhas deverá detectar novidades em séries temporais com a utilização de amostragem Gibbs, e o isolamento de falhas deverá ser feito com o uso de inferência *fuzzy*/Bayesiana.

Esse objetivo deverá ser alcançado a partir dos seguintes objetivos específicos:

- a) Simular e analisar exaustivamente o *benchmark* da turbina eólica no Simulink de forma a produzir um grande volume de dados, essencial para as técnicas baseadas em dados propostas;

- b) Inferir a relação entre as diferentes falhas presentes no modelo e seus efeitos nos sinais mensuráveis;
- c) Aplicar o amostrador de Gibbs como detector de novidades nos sinais do processos com a finalidade de produzir indicativos de falhas;
- d) Utilizar inferência *fuzzy*/Bayesiana, método capaz de realizar inferência em cenários de evidências incertas como no contexto de turbina eólica, para avaliar os indicadores de falhas e realizar a classificação adequada.

Não está no escopo desse trabalho a realização de medidas corretivas ou preventivas em relação as falhas, sendo assim, o problema de controle tolerante a falhas não será resolvido aqui. Não será apresentado neste trabalho também nenhum tipo de teste de campo, sendo os esforços concentrados no contexto do *benchmark*. A utilização do *benchmark* tem grande validade, pois este é composto por muitas características reais extraídas de testes de campo e foi proposto por uma fabricante de turbinas eólicas, a K. K. *electronics*. Além disso, o *benchmark* têm sido amplamente utilizado por pesquisadores de estratégias de FDI e FTC proporcionando uma fácil comparação das abordagens.

### 1.3 Metodologia

Nesse trabalho, é proposta uma metodologia alternativa de FDI baseada em dados. A metodologia proposta consiste em duas etapas básicas: a primeira é a detecção de novidades em sinais obtidos a partir de sensores, potencialmente associadas a falhas; e a segunda é a avaliação de sintomas e classificação de falhas.

No primeiro passo, o evento da falha é associado com novidades detectadas nos sinais a partir do uso de algoritmos de detecção de ponto de mudanças em séries temporais. A técnica de detecção de pontos de mudanças consiste, primeiramente, na transformação das séries temporais em processos de contagem de Poisson usando clusterização *fuzzy*, e posteriormente, a obtenção de um modelo para ponto de mudança na série temporal a partir do uso do amostrador Gibbs [6]. Esses pontos de mudanças detectadas podem ser como sintomas para o propósito de isolamento de falhas.

O isolamento é realizado no segundo passo. Onde as probabilidades de mudança são usadas com evidências, passam por processo de fuzzificação, e então, são processadas por uma

rede inferencial *fuzzy*/Bayesiana, através da qual se estima a probabilidade de ocorrência para cada tipo de falha.

A principal contribuição deste trabalho é estratégia ímpar de FDI proposta aplicada contexto de turbinas eólicas o qual oferece diversas dificuldades para FDI e FTC. A vantagem da metodologia proposta está no fato de ela dispensar totalmente o uso de modelos matemáticos para descrição da dinâmica dos processos. O desenvolvimento do sistema FDI aqui proposto levou em conta, em todas as etapas de sua implementação, aspectos relevantes para sua integração futura em sistemas FTC, buscando-se minimizar as FAR e FDR e maximizar o tempo gasto no diagnóstico. Além disso aqui é usado, de forma inédita no contexto de FDI, o amostrador de Gibbs para detecção de anomalias e a aplicação de inferência *fuzzy*/Bayesiana para isolamento de falhas nesse *benchmark* de turbina eólica, abordagem diferente das demais apresentadas para esse problema.

## 1.4 Organização do trabalho

O restante desse trabalho é organizado da seguinte forma:

- **Capítulo 2:** são abordados aspectos gerais sobre a tecnologia de turbinas eólicas e é feito um estudo sobre falhas e faltas que atingem esses sistemas. Nesse capítulo é feita a descrição do *benchmark* de turbina eólica que será utilizado ao longo desse trabalho;
- **Capítulo 3:** fornece a ideia básica a respeito de conceitos fundamentais para o desenvolvimento deste trabalho e para a compreensão da metodologia proposta. Serão revisadas a ideia de clusterização *fuzzy*, amostragem de Gibbs e de inferência *fuzzy*/Bayesiana;
- **Capítulo 4:** apresenta a metodologia proposta para o propósito de FDI e descreve o framework que será usado para isso. Além disso descreve as etapas *offline* do desenvolvimento do sistema em questão;
- **Capítulo 5:** retrata os resultados da aplicação da metodologia no *benchmark* de turbina eólica e avalia o seu desempenho;
- **Capítulo 6:** expressa as considerações finais sobre o trabalho e aponta caminhos para desenvolvimentos futuros da pesquisa.

# Capítulo 2

## Turbinas eólicas

Nessa seção serão abordados aspectos gerais dos sistemas de turbinas eólicos e questões relativas a sua confiabilidade e manutenção. Na Seção 2.1 serão revistos aspectos a aerodinâmica e funcionamento das turbinas eólicas. Na Seção 2.2 será descrito um *benchmark* de turbina eólica proposto para finalidade de FDI e FTC. Finalmente, na Seção 2.3 serão discutidos as faltas comuns que acometem esses sistemas, e será levantado o estado da arte de sistemas FDI para turbinas eólicas.

### 2.1 Visão geral sobre as Turbinas Eólicas

As turbinas eólicas basicamente são dispositivos projetados para transformar energia cinética presente nos ventos em algum tipo de energia mecânica. As turbinas eólicas podem ser classificadas de acordo com a orientação de seu rotor entre turbinas de eixo vertical ou de eixo horizontal. As turbinas eólicas de eixo horizontal prevaleceram sobre as demais devido ao seu maior aproveitamento da energia eólica, de forma que, atualmente, quase todas as turbinas eólicas comerciais são de eixo horizontal com duas ou três pás.

O rotor se localiza no topo da torre, onde os ventos carregam mais energia e menos turbulência, e é ligado através de um eixo a caixa de engrenagens e ao gerador que se encontram no interior da nacela. Sobre a nacela se encontra o anemômetro, que é o sensor de vento, responsável por capturar informações sobre a velocidade e direção do vento e enviá-las para os controladores do sistema. A caixa de engrenagem é o elemento mais pesado do sistema e é responsável por converter a baixa velocidade de rotação do eixo do rotor para a maior

velocidade do eixo acoplado ao gerador, responsável pela conversão de energia mecânica em elétrica. As turbinas elétricas são conectadas à rede através de um conversor e um transformador de potência. A figura 2.1 indica os principais componentes de uma turbina eólica.

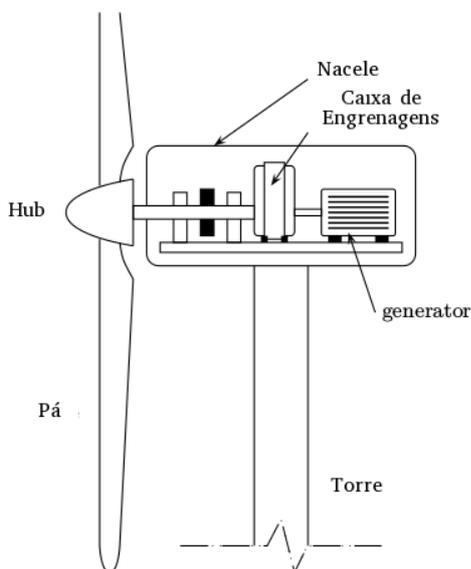


Figura 2.1: Principais componentes de uma turbina eólica [1].

### 2.1.1 Aerodinâmica das Turbinas Eólicas

A aerodinâmica das turbinas eólicas descrevem as forças exercidas na turbina pelo fluxo de ar. O modelo aerodinâmico das turbinas deriva principalmente de duas teorias: a teoria do disco atuador e a teoria de elemento de pá. Essas teorias permitem explicar de forma simplificada o processo de extração de energia [1].

O modelo do disco atuador considera o rotor como um disco que permite a passagem de ar. Uma vez que o rotor extrai energia do ar que passa, a velocidade do ar jusante é necessariamente menor do que a velocidade do ar montante e, conseqüentemente, a área da secção transversal do disco de ar jusante é maior que o montante (uma vez que a massa de ar é constante). Esse fenômeno causa uma queda de pressão que dá origem a força desenvolvida pelo disco atuador no fluxo de ar. A reação dessa força daria origem ao momento que produz a rotação das pás.

A teoria do disco atuador permite estimar a energia total extraída do fluxo de ar no caso ideal, considerando a existência de infinitas pás. Para explicar os efeitos do torque em cada

hélice e as forças que atuam nas mesmas, usa-se a teoria do elemento de pá. Os elementos de pás são faixas transversais de comprimento infinitesimal, onde as forças atuantes são analisadas a partir de determinadas hipóteses, e a força resultante sobre a pá pode ser calculada a partir da soma dos efeitos nos elementos infinitesimais.

Com o suporte das teorias supramencionadas, cujo detalhamento pode ser encontrado em [1], pode-se estimar a força de impulso ( $F_T$ ), o torque  $\tau_r$  e a potência mecânica  $P_r$  da turbina, respectivamente pelas equações (2.1), (2.2) e (2.3):

$$F_T(t) = \sum_{i=1}^3 \frac{1}{6} \rho \pi R^2 C_T(\lambda(t), \beta_i(t)) v_{w,i}(t)^2, \quad (2.1)$$

$$\tau_r(t) = \sum_{i=1}^3 \frac{1}{6} \rho \pi R^3 C_Q(\lambda(t), \beta_i(t)) v_{w,i}(t)^2, \quad (2.2)$$

$$P_r(t) = \sum_{i=1}^3 \frac{1}{6} \rho \pi R^3 C_P(\lambda(t), \beta_i(t)) v_{w,i}(t)^3, \quad (2.3)$$

$$\lambda = \frac{\omega_r R}{v_w}, \quad (2.4)$$

onde  $\rho$  é a densidade do ar,  $R$  é o raio do rotor,  $v_{w,i}(t)$  é a velocidade do vento na  $i$ -ésima pá, e  $C_T$ ,  $C_Q$  e  $C_P$ , são respectivamente coeficientes de impulso, torque e potência. Note que esses coeficientes são funções da relação  $\lambda$  de velocidade de extremidade das pás, dada pela equação 2.4, onde  $\omega_r$  é a velocidade angular do rotor, e mantida constante em seu valor ótimo, e do ângulo de arfagem da  $i$ -ésima pá  $\beta_i(t)$ , que é ajustado, por um atuador do ângulo de arfagem, de forma a atender os objetivos de controle.

### 2.1.2 Velocidade do Vento

O vento na superfície terrestre, que afeta as turbinas, é combinação do vento geostrófico e de ventos locais. O vento resultante que afeta as turbinas eólicas sofre ainda a ação diversos outros fenômenos como os relacionados ao terreno e aos obstáculos.

A análise espectral dos ventos que afetam a superfície terrestre (espectro de Hoven) apontam a presença de dois componentes principais de frequência na velocidade do vento, a velocidade média do vento, que é quase estacionária, e a turbulência, que é qualquer flutuação na velocidade do vento com posicionamento espectral diferente da velocidade média. As turbulências têm pouca influência no rendimento energético da turbina, mas tem um grande impacto nos esforços aerodinâmicos e na qualidade da energia.

As turbulências juntamente com a amostragem rotacional, efeito resultante do fato de as pás experimentarem diferentes velocidades de vento durante sua rotação, se propagam pela estrutura, reduzindo a vida útil da turbina, deteriorando a qualidade da energia e aumentando, conseqüentemente, o custo de operação. Apesar de muitas das flutuações da velocidade do vento terem caráter estocástico, alguns dos componentes principais desta são determinísticos. Esses componentes são resultados de dois efeitos: o *tower shadow* e o *wind shear*. O primeiro consiste na interferência, produzida pela torre de suporte do aerogerador, no fluxo de ar quando a pá passa pela estrutura. Este é o efeito determinístico mais importante, e produz harmônicos espalhados por uma longa faixa de frequência com maior energia associada ao terceiro harmônico. O segundo se refere a variação da velocidade do vento em função da altura, fazendo com que as pás experimentem diferentes velocidades e torques durante a sua trajetória, dando origem principalmente a harmônicos de terceira ordem.

Em estudos que devem ser feitos previamente a instalação de um aerogerador, devem ser obtidas previsões e modelos para a velocidade do vento que atinge a região onde se pretende fazer a instalação. A distribuição de ventos geralmente é aproximada de uma distribuição de Weibull, que indica que raramente a velocidade do vento mais comum é a média.

### 2.1.3 Controle da turbina eólica

O controle de turbinas eólicas é um problema que vêm sendo explorado há vários anos e que, no entanto, ainda necessita de grande evolução, sobretudo devido ao incremento dos objetivos de controle, que se tornaram bem mais sofisticados ao longo dos anos. A dinâmica dessas turbinas apresentam diversas não linearidades o que torna a tarefa do controle algo não trivial. Como em qualquer outra planta, o projeto de um sistema de controle para turbinas eólicas é composto por três etapas principais, a especificação dos objetivos de controle, a determinação da estratégia de controle e finalmente a realização da estratégia descrita.

Há algum tempo, o único objetivo de controle para as turbinas eólicas era a manutenção da mesma em condições seguras de operação, limitando a potência e a velocidade do sistema. Atualmente, os sistemas de controle desempenham papel fundamental na eficiência e qualidade energética, finalidades que muitas vezes conflitam. Pode-se, então, concentrar as metas de controle das turbinas eólicas em três conjuntos [1]:

- **Captação de Energia:** a energia gerada deve ser máxima dentro das restrições de ope-

ração da turbina como potência nominal e velocidade máxima do vento para operação (denominada velocidade de *cut-out*);

- **Esforços Mecânicos:** os esforços mecânicos desnecessários, geralmente relacionados a harmônicos de alta frequência e fenômenos transitórios, devem ser minimizados;
- **Qualidade de Energia:** a energia gerada deve ser adequada aos padrões do sistema elétrico conectado.

A complexidade e flexibilidade do controle depende da tecnologia da turbina eólica, e das formas através das quais é possível atuar na turbina que geralmente são: velocidade-fixa, velocidade-variável, arfagem-fixa, arfagem-variável [1]. Neste sentido, as turbinas eólicas podem ser classificadas em quatro categorias:

- Velocidade-fixa arfagem-fixa (FS-FP);
- Velocidade-variável arfagem-fixa (VS-FP);
- Velocidade-fixa arfagem-variável (FS-VP);
- Velocidade-variável arfagem-variável (VS-VP).

O problema do controle da turbina depende da zona de operação da turbina. O funcionamento de uma turbina eólica pode ser dividido em quatro zonas de operação em função da velocidade do vento. Na zona 1, a turbina eólica ainda está parada ou entrando em operação, quando a velocidade do vento é muito baixa. Na zona 2, o objetivo do controle da turbina é de maximizar a captação de energia, e ocorre quando a velocidade está entre a mínima para operação e a velocidade suficiente para que a referência de potência seja alcançada. Na zona 3, a turbina precisa limitar a captação de energia e deve objetivar a minimização dos esforços mecânicos e a manutenção da qualidade da energia. A zona 4 corresponde a velocidades de vento acima da velocidade de *cut-out*, circunstâncias em que a turbina deve deixar de operar por razões de segurança.

O sistema de controle das turbinas modernas está disposto em diversos níveis. No nível superior, existe um controle supervisor, que deve monitorar as condições da turbina e dos recursos eólicos, determinando o acionamento ou desligamento quando necessário, geralmente esse controle é do tipo se-então. Em um nível médio, se situa o controle dos mecanismos da

turbina propriamente ditos. Esse nível é composto fundamentalmente pelo controle do torque do gerador, controle do ângulo de arfagem das pás e controle do ângulo de guinada. O nível mais baixo de controle é composto pelos dispositivos de eletrônica de potência, gerador interno e pelo controlador do atuador do ângulo de arfagem.

## 2.2 Benchmark da Turbina Eólica

Neste trabalho será utilizado um benchmark de turbina eólica proposto por Odgaard et al. [7] e pela empresa tecnologia para turbinas eólicas K. K. Eletronics no SAFEPROCESS 2009 com uma chamada para a comunidade científica para que apresentassem soluções de FDI e FTC para o mesmo.

O *benchmark* da turbina, detalhadamente descrito em [2], simula no ambiente do Simulink uma turbina eólica de eixo horizontal com três pás, com controle PI VS-VP. Este modelo apresenta diversas características e detalhes que permitem a obtenção de resultados realísticos, dentre os quais pode-se citar: um modelo para a velocidade do vento que agrega os efeitos determinísticos, (*tower shadow* e *wind shear*), e estocásticos; incorporação de ruídos em todas as medidas obtidas por sensores; adoção de um modelo aerodinâmico com consideração do efeito dos diferentes ângulos de arfagem e guinada sobre o torque mecânico.

Simultaneamente ao realismo incorporado com fatores supracitados, algumas simplificações são feitas buscando favorecer os estudos de FDI e FTC, que é o foco do trabalho. A modelagem dos componentes aerodinâmicos é simplificada por modelos estáticos. Os controladores adotados são simples e básicos, atendendo os objetivos básicos diante das demais simplificações do modelo.

Essa composição balanceada entre realismo e simplicidade fazem deste *benchmark* um modelo apropriado para os propósitos de FDI e FTC, contendo a complexidade necessária para os estudos realísticos das falhas e dispensando a conhecimentos muito específicos sobre a tecnologia de turbinas eólicas favorecendo a usabilidade.

### 2.2.1 Subsistemas do *benchmark*

O modelo é composto por cinco subsistemas principais: o sistema de pás e arfagem, o sistema gerador e conversor, o sistema de *drive train*, o sistema de controle e o sistema de

sensores. A Figura 2.2 traz uma visão geral desses sistemas. A descrição detalhada das variáveis envolvidas nesse processo se dará ao logo desta seção

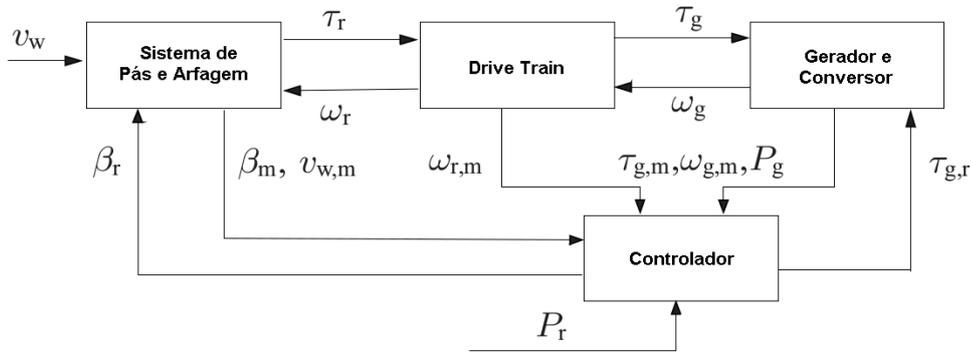


Figura 2.2: Visão geral do *benchmark* de Turbina Eólico [2].

### 2.2.1.1 Sistema de Pás e Arfagem

O modelo aerodinâmico de cada uma das pás de uma turbina é conhecido da literatura e pode ser representado por:

$$\tau_r(t) = \frac{\rho \pi R^3 C_q(\lambda(t), \beta_i(t)) v_w(t)^2}{6}, \quad (2.5)$$

Todos os parâmetros na equação (2.5) são características construtivas, exceto  $v_w(t)$  que é a velocidade do vento, e  $\beta_i$  que é o ângulo de arfagem da pá  $i$ . Percebe-se que o coeficiente de torque  $C_q$ , obtido através de uma *look-up table*, é função do ângulo  $\beta_i$ , o que torna esse ângulo um importante fator para que se obtenha o rendimento otimizado da turbina.

Existe um sistema hidráulico de arfagem, cujo objetivo é manter esse ângulo numa posição de referência, onde o rendimento é máximo. Esse sistema hidráulico pode ser descrito por um modelo de segunda ordem, cuja entrada é um ângulo de referência a ser seguido, e a saída é o ângulo real.

Esse ângulo é medido por sensores para cada pá. Nesse *benchmark* cada um dos sensores possuem redundância física, de forma que esse sistema é composto por 6 sensores ao todo cujas medidas são representadas por  $\beta_{i,mj}$ , onde  $i$ ,  $1 \leq i \leq 3$ , indica em qual das três pás o sensor está instalado, e  $j$  indica de qual dos dois sensores presentes se trata.

O *benchmark* permite a simulação de diversas faltas, em sensores ou atuadores, no sistema de pás e arfagem. Permite a simulação de faltas em cada um dos seis sensores, faltas que

podem resultar em um fator multiplicativo ou em um valor fixo nas medidas. Além disso considera a possibilidade de ocorrência de faltas no sistema hidráulico de arfagem para qualquer uma das três pás, essas faltas podem resultar numa queda de pressão hidráulica ou na presença de ar no óleos, em ambos os casos levando a mudança na dinâmica do sistema.

### 2.2.1.2 Sistema Gerador e Conversor

O conversor é usado para controlar o torque do gerador e do rotor, fazendo o gerador seguir uma referência de torque designada pelo sistema de controle, controlando também, dessa forma, a potência gerada. O dispositivo principal desse sistema é a caixa de engrenagens, que é o conversor de velocidades propriamente dito. O conversor pode ser modelado como um sistema de primeira ordem. E através da saída desse sistema  $\tau_g$ , o torque do gerador, pode-se calcular a potência gerada, que é o produto desse torque, pela velocidade angular do gerador e pelo rendimento da máquina. O *benchmark* considera que existem sensores capazes de medir o torque do gerador e de indicar a potência gerada.

Neste sistema, podem ocorrer falhas no atuador, gerando alterações na dinâmica do sistema, que pode ser percebida através do torque medido do gerador.

### 2.2.1.3 Sistema de *drive train*

O sistema de *drive train* tem como finalidade gerar um aumento da velocidade de rotação do rotor, ligado às pás, para o gerador elétrico. Esse sistema pode ser modelado no espaço de estados por:

$$\dot{x}(t) = \begin{bmatrix} -\frac{B_{dt}-B_r}{J_r} & \frac{B_{dt}}{N_g J_r} & -\frac{K_{dt}}{J_r} \\ \frac{\eta_{dt} B_{dt}}{N_g J_r} & -\frac{\eta_{dt} B_{dt} + B_g N_g^2}{N_g^2 J_r} & \frac{\eta_{dt} K_{dt}}{N_g J_r} \\ 1 & -\frac{1}{N_g} & 0 \end{bmatrix} x(t) + \begin{bmatrix} \frac{1}{J_r} & 0 \\ 0 & -\frac{1}{J_g} \end{bmatrix} u(t), \quad (2.6)$$

onde  $J_r$  é o momento de inércia da engrenagem de baixa velocidade (lado do rotor),  $J_g$  é o momento de inércia da engrenagem de alta velocidade (lado do gerador),  $B_{dt}$  é o coeficiente de amortecimento de torsão no *drive train*,  $B_g$  é o coeficiente de viscosidade da engrenagem de alta velocidade,  $\eta_{dt}$  é a eficiência do *drive train*,  $N_g$  é razão de transformação entre as engrenagens,

$K_{dt}$  é a rigidez do *drive train*, e o vetor de estados  $x(t)$  é:

$$x(t) = \begin{bmatrix} \omega_r \\ \omega_g \\ \theta_\Delta \end{bmatrix}, \quad (2.7)$$

onde  $\omega_r$  é a velocidade angular do rotor,  $\omega_g$  é a velocidade angular do gerador,  $\theta_\Delta$  é o ângulo de torção do *drive train*, e o vetor de entradas  $u(t)$  é:

$$u(t) = \begin{bmatrix} \tau_r \\ \tau_g \end{bmatrix}, \quad (2.8)$$

onde  $\tau_r$  é o torque do rotor e  $\tau_g$  é o torque do gerador.

Esse sistema possui dois pares de sensores em redundância para medir a velocidade de rotação do rotor  $\omega_r$  do gerador  $\omega_g$ . O *benchmark* permite a simulação de falhas nesses 4 sensores, que podem resultar em valores fixos ou em fatores multiplicativos. Além dessas, são consideradas ainda faltas na planta, no gerador ou rotor, que geram alterações na dinâmica do sistema.

#### 2.2.1.4 Sistema de Controle

O sistema de controle da turbina eólica consiste de dois controladores independentes. O primeiro é um controlador PI para o sistema de pás e arfagem, e tem como objetivo manter as pás com um ângulo de arfagem ótimo. O outro controla de fato potência gerada, fazendo ela seguir a uma referência de potência, este controlador pode operar em diferentes modos de acordo com a intensidade dos ventos.

O controle adotado no *benchmark* atua apenas nas zonas de operação 2 e 3. Na zona 2, quando a turbina trabalha com carga parcial e velocidades entre  $3m/s$  e  $12.5m/s$ , o controle deve otimizar a potência gerada atuando no sistema de arfagem (a potência ótima é obtida com o ângulo de arfagem de 0 graus para todas as pás). Na zona 3, a potência de referência é alcançada, e o controlador deve atuar no sistema de arfagem de forma a manter a potência gerada constante. A figura 2.3 mostra as zonas de operação do modelo.

#### 2.2.1.5 Sistema de Sensores

Este sistema fornece as medidas de diversos sensores instalados na turbina eólica. As medidas são compostas pelo valor da variável correspondente no modelo adicionado a ruídos

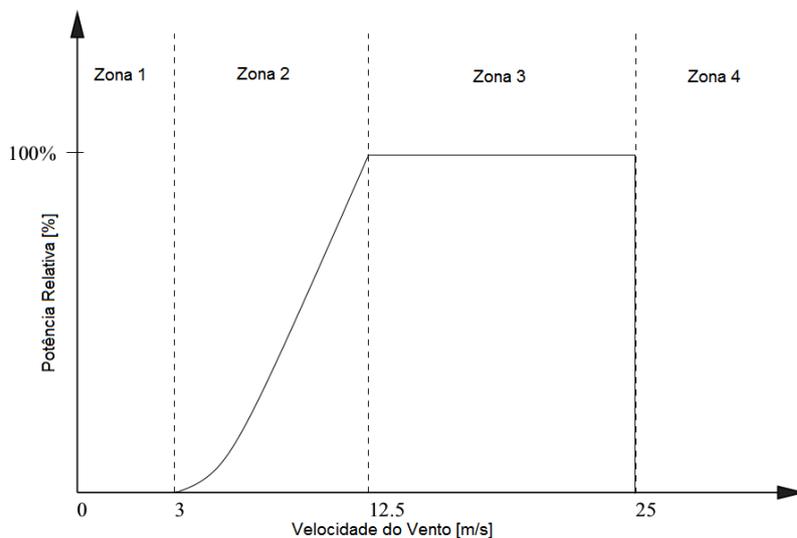


Figura 2.3: Zonas de operação da turbina eólica [2].

estocásticos. Os principais sensores fornecidos pelo *benchmark* são:

- seis sensores para os ângulos de arfagem, dois para cada pá, e os sinais fornecidos por cada um desses é representado por variáveis nomeadas por  $\beta_{i,m}$ , onde  $i$  representa o número da pá,  $i = 1, 2, 3$ , e  $m$  é o número do sensor, podendo ser  $m_1$  ou  $m_2$  (se referindo a um dos dois sensores redundantes);
- dois sensores de velocidade do rotor, cujos sinais de medida são  $\omega_{r,m_1}$  e  $\omega_{r,m_2}$ ;
- dois sensores de velocidade no gerador, cujos sinais de medida são  $\omega_{g,m_1}$  e  $\omega_{g,m_2}$ ;
- sensor para medição da potência gerada, cujo sinal de medida é  $P_{g,m}$ ;
- sensor para medição do torque mecânico gerado gerado, cujo sinal de medida é  $\tau_{g,m}$ ;
- anemômetro, que fornece a velocidade do vento na altura do *hub*. O sinal de medida do anemômetro é representado por  $v_{hub}$ .

A Tabela 2.1 resume as informações de todos sensores do *benchmark*.

## 2.2.2 Perfil do vento e falhas

Esse *benchmark* oferece um modelo de vento que inclui componentes de flutuação estocásticos e determinísticos. Devido a isso o modelo de vento desse *benchmark* é a adição de

<sup>1</sup>Medido na  $i$ -ésima pá.

Sensor	Símbolo	Unidade	Nível de Ruído
Anemômetro	$v_{hub}$	$m/s$	0.0071
Velocidade do Rotor	$\omega_{r,m}$	$rad/s$	$10^{-4}$
Velocidade do Gerador	$\omega_{g,m}$	$rad/s$	$2 \cdot 10^{-4}$
Torque Mecânico Gerado	$\tau_{g,m}$	$Nm$	0.9
Potência Elétrica Gerada	$P_{g,m}$	$W$	10
Ângulo de Arfagem <sup>1</sup>	$\beta_{i,m}$	$graus$	$1.5 \cdot 10^{-3}$
Ângulo Azimutal	$\phi_m$	$graus$	$10^{-3}$
Momento na Base da Pá <sup>1</sup>	$M_{B,i,m}$	$Nm$	$10^3$
Aceleração no Topo da Torre (eixo x)	$\ddot{x}_{x,m}$	$m/s^2$	$5 \cdot 10^{-4}$
Aceleração no Topo da Torre (eixo y)	$\ddot{x}_{y,m}$	$m/s^2$	$5 \cdot 10^{-4}$
Erro de Guinada	$\Xi_{e,m}$	$graus$	$5 \cdot 10^{-2}$

Tabela 2.1: Sensores disponíveis no *benchmark* de turbina eólica.

quatro componentes:

$$v_w(t) = v_m(t) + v_s(t) + v_{ws}(t) + v_{ts}(t), \quad (2.9)$$

onde  $v_m$  é a velocidade média,  $v_s$  é o componente estocástico da flutuação,  $v_{ws}$  é o componente referente ao efeito *wind shear* e  $v_{ts}$  é o componente referente ao efeito *tower shadow*. Além da velocidade do vento medida pelo anemômetro, que só leva em consideração os dois primeiros componentes da equação (2.9), existem variáveis representando a velocidade do vento na extremidade de cada uma das pás ( $v_{w_1}$ ,  $v_{w_2}$  e  $v_{w_3}$ ) que consideram o efeito de todos os componentes.

O componente estocástico é modelado através de filtros de Kaimal [1]. Detalhes sobre o modelo de cada um dos componentes presentes na equação (2.9) estão presentes em [2] e em suas referências.

O *benchmark* permite a simulação de diversas falhas em sensores, atuadores ou nas plantas, com diferentes níveis de gravidade e consequências.

Os sensores podem falhar devido a um problema elétrico ou mecânico que pode resultar em um valor de medida fixo ou variável multiplicado por um fator de ganho. As falhas podem afetar os sensores dos ângulos de arfagem (denotadas por  $\Delta\beta_{1,m1}$ ,  $\Delta\beta_{1,m2}$ ,  $\Delta\beta_{2,m1}$ ,  $\Delta\beta_{2,m2}$ ,  $\Delta\beta_{3,m1}$ , e  $\Delta\beta_{3,m2}$ ), os sensores do gerador (denotadas por  $\Delta\omega_{g,m1}$  e  $\Delta\omega_{g,m2}$ ), ou os sensores do rotor (denotadas por  $\Delta\omega_{r,m1}$  e  $\Delta\omega_{r,m2}$ ).

O conversor e o atuador de arfagem também podem falhar. A falha no conversor é denotada por  $\Delta\tau_g$  e pode ser causada por problemas eletrônicos ou por *offset* na estimativa. As consequências dessa falha pode ser um simples *offset* ou mudanças na dinâmica do conversor. O atuador de arfagem é um sistema hidráulico que pode falhar em qualquer das três pás e são

representadas por  $\Delta\beta_1$ ,  $\Delta\beta_2$  e  $\Delta\beta_3$ . As falhas nesse sistema podem ocorrer devido á queda de pressão no sistema hidráulico ou devido á presença de ar no óleo.

O modelo permite ainda a simulação de uma falha na planta que pode ocorrer no *drive train* devido a mudanças no coeficiente de fricção gerando dois sinais de falha representados por  $\Delta\omega_g$  e  $\Delta\omega_r$ .

Em [2] são apresentados alguns padrões de falhas e bancos de testes para o propósito de FDI e FTC. O usuário do modelo, no entanto, não é preso a esses bancos, podendo realizar testes em diferentes configurações de falhas. Nesse trabalho, foram usados diferentes configurações para se produzir dados suficientes para a abordagem baseada em dados, no entanto, o processo de teste e validação foi feito sobretudo com a sequência padrão que é descrita na Tabela 2.2.

Falha #	Descrição	Tipo	Símbolo	Gravidade	Início (s)	Fim (s)
$F_1$	Valor fixo na medida de $\beta_{1,m1}$	Valor Fixo	$\Delta\beta_{1,m1}$	Baixa	2000	2100
$F_2$	Ganho na medida de $\beta_{2,m2}$	Fator de Ganho	$\Delta\beta_{2,m2}$	Baixa	2300	2400
$F_3$	Valor fixo na medida de $\beta_{3,m1}$	Valor Fixo	$\Delta\beta_{3,m1}$	Baixa	2600	2700
$F_4$	Valor fixo na medida de $\omega_{r,m1}$	Valor Fixo	$\Delta\omega_{r,m1}$	Baixa	1500	1600
$F_5$	Ganho nas medidas de $\omega_{r,m2}$ e $\omega_{g,m1}$	Fator de Ganho	$\Delta\omega_{g,m1}$ , $\Delta\omega_{r,m2}$	Baixa	1000	1100
$F_6$	Mudança na dinâmica do atuador de arfagem 2 devido a queda de pressão	Mudança na dinâmica	$\Delta\beta_2$	Alta	2900	3000
$F_7$	Mudança lenta da dinâmica do atuador de arfagem 3 devido a presença de ar no óleo	Mudança na dinâmica	$\Delta\beta_3$	Média	3500	3600
$F_8$	<i>Offset</i> em $\tau_g$	<i>Offset</i>	$\Delta\tau_g$	Média	3800	3900
$F_9$	Mudança na dinâmica do <i>drive train</i>	Mudança na dinâmica	$\Delta\omega_r$ , $\Delta\omega_g$	Média	4100	4400

Tabela 2.2: Configuração padrão de falhas.

## 2.3 Falhas em Turbinas Eólicas

Nesta seção serão estudadas algumas das falhas e faltas comuns que atingem turbinas eólicas. Além disso será levantado o estado da arte da supervisão e FDI nesses sistemas.

### 2.3.1 Faltas comuns em Turbinas Eólicas

A predição, previsão e correção de falhas são os fatores chaves para a melhora do custo de energia nos sistemas de energia eólica, evitando a ocorrência de faltas. Diferentes faltas podem afetar uma turbina eólica, com diferente grau de severidade e com diferentes impactos financeiros (geralmente associados ao tempo de desligamento causado pela falha). Os componentes que concentram o maior número de falhas são a caixa de engrenagens, o gerador, os sensores e o conversor eletrônico.

Ribrant e Bertling [8] realiza um estudo sobre as principais faltas que acometem as turbinas eólicas baseado em dados estatísticos de manutenção de turbinas da Suécia, Finlândia e Alemanha. Estes estudos indicam que, de forma geral, os componentes que apresentam maior número de faltas são o sistema elétrico, o sistema de pá e arfagem, sensores e o sistema hidráulico. No entanto, as faltas mais graves ocorrem na caixa de engrenagens, pois leva a um maior tempo de desligamento e tem um maior custo de reparo.

Sinha e Steel [9] comprovam a gravidade das faltas nas caixas de engrenagem em seus estudos que investigam as causas e os efeitos das faltas em turbinas eólicas. Em [9], é mostrado que as falhas com maiores custos são as falhas nas caixas de engrenagem e nos geradores, sendo que esta última ocorre com frequência maior. Ainda nesse trabalho, um estudo mais profundo das faltas nas caixas de engrenagem permitiu identificar as principais causas, entre as quais se destacam os problemas no rolamento e nos sensores.

Outros estudos também confirmam os problemas recorrentes apontados em [8], como o de Hahn et al. [10], que investiga as faltas em turbinas elétricas da Alemanha, e o de Pinar Pérez et al. [11], que compila a investigação de diversos outros estudos sobre a confiabilidade de turbinas eólicas. Esses trabalhos indicam que as falhas mais frequentes ocorrem no sistema elétrico, sistemas de pá e arfagem, sensores e caixa de engrenagens e sistema hidráulico. Esse trabalho também indica que as peças mais caras nas turbinas eólica são os geradores, os conversores e as caixas de engrenagens, todos componentes que apresentam faltas com frequência. Além disso esses trabalhos indicam que o problema que tem maior impacto na disponibilidade,

isto é mantê-las as turbinas desligadas por maior tempo, são problemas nas pás, cuja substituição apresenta grande dificuldade. Problemas nas pás geralmente são causados pelos severos esforços mecânicos aos quais elas são submetidas, de forma que é inevitável que elas venham faltar um dia. A ocorrência de faltas em qualquer outro subsistema é um fator amplificador desses esforços e portanto redutor da vida útil dessas peças.

Os efeitos dos problemas nas caixas de engrenagens sobre outros componentes da turbina são apontados por Qiu et al. em [12]. Esse trabalho indica que os efeitos deste tipo de falha afetam severamente: o torque no gerador produzido, diminuindo seu valor para menores velocidades de vento, reduzindo também a potência gerada e afetando o rendimento do processo; o torque no rotor, aumentando seu valor para altas velocidades de vento, desgastando os demais componentes mecânicos; e o ângulo de arfagem, que se distânciam do seu valor ótimo.

Assim como no estudo de Qiu et al [12], as diversas falhas que ocorrem nas turbinas eólicas podem se propagar quando prolongadas, afetando diferentes subsistemas. Uma falha no sensor de arfagem, por exemplo, poderia levar com o tempo a uma sobrecarga de partes mecânicas desnecessária, além de afetar a qualidade de energia. Desta forma, um sistema de FDI adequado afeta positivamente a vida útil dos componentes da turbina eólica e a qualidade da energia gerada.

Mais informações sobre faltas e confiabilidade das turbinas eólicas podem ser encontradas em [13] e nas referências do mesmo. Nesse trabalho, Tchakou et al. [13] fazem uma revisão completa dos fundamentos do monitoramento de turbinas eólicas e discutem sobre as principais faltas e suas possíveis causas e consequências.

### **2.3.2 Sistemas de FDI para Turbinas Eólicas**

Os altos custos das falhas, as dificuldades na manutenção, e a exposição diária a todo tipo de esforço incentivam o desenvolvimento de diversas técnicas de FDI e FTC com aplicações diretas em turbinas eólicas.

Os sistemas de FDI em turbinas eólicas têm como objetivo principal identificar falhas antes que elas se propaguem, deterioresem os demais componentes e causem uma falta no sistema. No entanto, turbinas eólicas são sistemas complexos e com diversas não linearidades o que torna difícil e desafiadora a tarefa de desenvolvimento de soluções FDI com essa aplicação e incentiva o emprego de técnicas baseadas em dados, que dispensam a complexidade do modelo

matemático desses sistemas.

Pelas razões já mencionadas na seção anterior, o componente que mais tem atraído a atenção dos pesquisadores é a caixa de engrenagens, mas também existem trabalhos que se dedicam especificamente a outros problemas, como por exemplo os trabalhos de: Yafeng et al. [14], que emprega lógica fuzzy para encontrar sintomas de falhas em pás de turbina eólica; Wei et al. [15] que utiliza estimadores baseados em filtros de Kalman para detectar falhas em sensores de torque nas pás; Rothenhagen e Fuchs [16, 17] que propuseram sistemas FDI baseados em observadores de estados para identificar falhas em sensores de corrente e tensão presentes em geradores de indução duplamente alimentados (DFIG) empregados em turbinas eólicas. No entanto, ainda prevalecem os sistemas de FDI focados nas caixas de engrenagens.

Hilbert et al. [18] aplicaram o método clássico de FDI baseado em observadores de Luenberg, com testes para diferentes níveis de *thresholds*, para detectar falhas na caixa de engrenagem de um modelo de turbina eólica. Zhou et al. [19] propõe um sistema de diagnóstico de falhas na caixa de engrenagem baseado em FMECA, técnica para identificar e classificar falhas, baseada nas suas causas e efeitos. Neste trabalho, o FMECA é usado para extrair o conhecimento a respeito das falhas bem como as relações entre os cenários de faltas e diversos hardwares envolvidos, essa base de conhecimento é utilizada para elaborar um sistema especialista de inferência, com o suporte de *framework* composto por diversos *softwares*, para localizar as causas das falhas em caixas de engrenagem.

Como as turbinas eólicas são sistemas geralmente compostos por uma grande quantidade de sensores, diversas técnicas baseadas em dados que focam no processamento e extração de características diretamente de sinais vêm sendo empregadas. Attoui e Omeiri [20] empregaram um algoritmo de FFT adaptativa para detectar e diagnosticar falhas em DFIG para turbinas eólicas, realizando análise espectral da corrente de estator do gerador. Tang et al. [21] propõem um *framework* que combina transformada *wavelet* de Morlet e WVD para detectar falhas que ocorrem no período transitório do funcionamento da caixa de engrenagens a partir da análise espectral dos sinais obtidos através dos sensores de vibração. Wenyi et al. [22] propõem um sistema de FDI para caixa de engrenagens que utiliza detecção de falhas baseada na análise espectral diagonal (uma derivada da transformada de Fourier discreta) com o isolamento baseado em SVM, os sinais utilizados aqui também são os de vibração. Para o mesmo problema dos sensores de vibração, Hang et al. [23] formularam um engenhoso algoritmo de FDI descrito em cinco passos: obtenção de diversos sinais de vibração fornecidos por sensores; extração

de característica de cada um desses sinais a partir de análise espectral baseada em HHT; classificação probabilística das características extraídas de cada sinal por meio de classificadores SVM multi-classe; fusão das classificações para obtenção de uma distribuição de probabilidade global para falhas; finalmente o diagnóstico de falhas a partir de regras de decisão. Neste trabalho, os autores comparam o emprego de três abordagens de análise de fusão das classificações - a Média Ponderada Ordenada (OWP), o raciocínio evidencial D-S (DSER) e a integral fuzzy (FI) - e comparam o desempenho de sua formulação com uma semelhante usando classificador neural ao invés de SVM.

Também com análises baseadas em extração de característica de sinais, Nejad et al. [24] aplicam análise espectral dos sinais de erro entre medidas de velocidades nas extremidades dos eixos do *drive train* para antecipar a ocorrência de falhas. Com o uso de um modelo clássico para sistemas elétricos de potência, a modelagem por componentes simétricos, Hocine et al. [25] detectou falhas na caixa de engrenagem com a análise espectral da potência gerada. Recentemente, Hu et al. [26] formularam um sistema de detecção de falhas a partir dos sinais de vibração de caixa de engrenagens de turbinas eólicas que combina transformada de *wavelet* com decomposição EITD (*ensemble intrinsic timescale decomposition*), e realiza o isolamento através de um cálculo de correlação entre as componentes obtidas.

Chen et al. [27] propuseram um sistema de monitoramento baseado em SCADA com diagnóstico de falhas realizado por meio de redes Bayesianas para detecção das causas raízes de faltas nas pás de turbina eólica, prevenindo essas faltas. Uma estratégia muito similar também foi aplicada por Chen e Hao [28] para detecção de problemas em caixa de engrenagem.

Alguns outros trabalhos se dedicaram ao problema de FDI para turbinas eólicas de forma mais genérica, ao invés de se concentrarem em falhas de componentes específicos, entre os quais pode-se citar Negre et al. [29] que propõe um sistema FDI com detecção baseada em observadores de estados e geradores de resíduos que são avaliados por sistema de avaliação de resíduos robusto, que leva em conta os erros possíveis devido às incertezas.

O *benchmark* de Turbina Eólica descrito na seção 2.2 foi objeto de diversos estudos e propostas de sistemas FDI e FTC ao longo dos últimos anos. O modelo foi lançado como um desafio a comunidade científica para que apresentassem soluções para o problema de FDI em turbinas eólicas. As propostas apresentadas foram publicadas no IFAC World Congress 2011. As estratégias de FDI com melhor desempenho foram descritas e comparadas em [2].

As propostas apresentadas foram submetidas a testes e propostos pela K. K. *electronics*.

Odgaard et al. [2] indicou que [30–34] foram as propostas que apresentaram melhor desempenho diante da bateria de testes. Os resultados apresentados por todas essas propostas têm em comum as grandes dificuldades encontradas na detecção das falhas 2 e 8, e nenhuma obteve êxito na tarefa de detecção da falha 9. A maioria das propostas apresentadas eram de abordagens baseadas em modelo, as quais, de forma geral, apresentaram elevadas taxas de falsos positivos.

O sistema de FDI apresentado por Chen et al. in [31] se baseia em estimadores de estado, alguns observadores de Luenberger e alguns filtros de Kalman. Nessa abordagem, um estimador foi construído para cada subsistema, e sinais de resíduos foram gerados através da comparação das variáveis estimadas com as medidas fornecidas pelos sensores. Posteriormente esses resíduos foram avaliados usando-se razão de verossimilhança generalizada (GLR) e *thresholds* estáticos. O ponto fraco desta proposta é o grande número de falsos positivos. Zhang et al. [32] também propuseram um sistema FDI baseado em bancos de estimadores de estados feitos de forma particular para cada sistema e empregados para isolamento de falhas também. Esse trabalho também apresentou muitas detecções incorretas.

Ozdemir et al. [34] usaram contadores crescentes-decrescentes (*up-down counters*) ao invés dos ajustes tradicionais de *thresholds*. Nesse trabalho é usado uma mistura de técnicas de detecção de falhas com geração de resíduos para os diferentes subsistemas do modelo: redundância física para o sistema de sensores e atuadores de arfagem, filtros de Kalman para os sensores de velocidade do rotor e gerador, equações de paridade para o sistema gerador e conversor. O grande diferencial está no sistema de ajuste incremental dos *thresholds*. A proposta foi capaz de detectar a maioria das falhas, no entanto apresentou reação muito lenta.

Svärd e Nyberg [33] propuseram um sistema baseado em geração sequencial de resíduos. Na abordagem proposta diversos candidatos a geradores de resíduos são gerados, mas apenas alguns são selecionados por meio de um algoritmo guloso de seleção. O isolamento das falhas é feito através de comparação entre a distribuição de probabilidade estimada em cenários com e sem falhas. Essa abordagem apresentou bons resultados, detectando todas as falhas de 1 a 7, com baixo nível de falsos positivos se comparados com os citados anteriormente.

Todas essas propostas de sistemas FDI para o *benchmark*, citadas acima, eram baseadas em modelo, como a maioria das abordagens que apareceram para o problema desde então. Contudo, o trabalho com os melhores resultados, segundo [2], foi o de Laouti et al. [30], cuja proposta era baseada em dados. O sistema de FDI proposto utiliza SVM, adotando funções de

base radial como kernel. O ponto forte da avaliação do trabalho é o baixo número de detecções incorretas nas falhas de sensores. Em contra partida, o método apresentou grandes problemas nas demais falhas, e não conseguiu detectar as falhas de 6 a 8. Posteriormente em [35], os autores propuseram uma abordagem híbrida, que é parcialmente baseada em modelo, e conseguiram melhores resultados com as falhas 6 a 8.

Tabatabaeipour et al. [36] propuseram uma metodologia de detecção de falhas *set-membership* robusta para o *benchmark* de turbina eólica. Nessa abordagem, os ruídos e incertezas são considerados desconhecidos, no entanto, com limites bem definidos. O sistema foi capaz de detectar todas as falhas em cenários sem incertezas, e mais da metade em cenários incertos.

Othman et al. [37] propuseram uma estratégia de FDI baseada em SVM e estimadores de Kalman, em paralelo, para o *benchmark* de turbina eólica com pequenas alterações, as falhas testadas são diferentes das indicadas em [2] e nenhum dos sensores foram considerados redundantes. As falhas que não foram bem isoladas pelo SVM, foram isoladas com êxito pelos filtros de Kalman, indicando a possibilidade de combinação das técnicas.

Também para o *benchmark* com modificações nas falhas abordadas, Yin et al. [38] apresentaram uma abordagem baseada em dados para FDI. O método se baseia na constituição de um espaço de paridades a partir de dados de medidas para geração de resíduos avaliados com GLR. A estratégia apresentou bons resultados para falhas em sensores, no entanto não obteve bons resultados com falhas em atuadores.

Em outro trabalho envolvendo FDI para o *benchmark* de turbina eólica com falhas modificadas, Sanchez et al. [39] propõem uma metodologia baseada em relações de redundância analítica (ARR's), que são relações análogas às equações de paridade, e observadores de intervalos, para comportar as não linearidades do modelo. As diversas falhas simuladas, de sensores e atuadores, puderam ser detectadas com a estratégia proposta. Os observadores de intervalos também foram adotados para FDI para esse *benchmark* por Blesa et al. [40], almejando a aplicação para FTC.

Mais recentemente, Simani et al. [41] propuseram uma estratégia de FDI baseada em identificação de modelos usando estimadores fuzzy para o *benchmark*. A avaliação de resíduos e o isolamento de falhas se baseava nas assinaturas de falhas em determinados sinais de interesse identificados através de FMEA. Os resultados do sistema de FDI proposto foram muito bons, ele conseguiu detectar e isolar todas as falhas com baixas taxas de falsos alarmes e não detecções

(FAR e MFR). Os comparativos apresentados pelos autores indicam melhor desempenho em relação as estratégias comparadas em [2] e citadas acima [30–34], além de também apresentar superioridade em relação a técnicas de FDI ativo. Uma técnica, também baseada em identificação fuzzy de modelos, foi usada mais recentemente por Badihi et al. [42], com objetivo de alimentar um sistema de FTC.

Dey et al. [43] apresenta três diferentes estratégias FDI baseadas em modelo para o *benchmark*, focando em problemas que acometem o sistema de *drive train*, gerador e conversor. São estudadas apenas 4 falhas, as falhas 4, 5, 8 e uma versão modificada da falha 9. Na primeira estratégia, são projetados 7 geradores de resíduos baseados em filtros de Kalman. As falhas 4, 8 e 9 foram detectadas e isoladas com sucesso, mas falha 5 não foi detectada completamente. A segunda estratégia é semelhante a anterior, mas baseada em observadores. Neste caso, todas as falhas foram detectadas com tempo bem maior que na abordagem anterior. A última estratégia consiste em uma abordagem baseada em equações de paridade, para geração de resíduos e filtragem  $H_\infty$  para remoção de ruídos e interferências. Nessa abordagem, todas as falhas foram detectadas e isoladas, num tempo menor que a segunda.

## 2.4 Conclusão

Para a compreensão da metodologia de FDI proposta no trabalho se faz necessário o conhecimento básico sobre a planta em que a mesma será aplicada. Por essa razão, este capítulo forneceu uma ideia geral sobre os sistemas de turbinas eólicas e descreveu os seus principais componentes, com foco no *benchmark* que foi empregado. Foram ainda estudadas algumas das principais falhas e faltas que acometem os sistemas de turbinas eólicas buscando realizar o levantamento do estado da arte da supervisão, detecção e diagnóstico de falhas nesses sistemas. Neste trabalho não foram fornecidos grandes detalhes construtivos das turbinas eólicas, uma vez que o foco é no sistema de FDI e não na planta, para mais detalhes o leitor poderá consultar a literatura especializada como [1]. Neste capítulo constam apenas as informações relevantes para compreensão da dificuldade do problema no contexto de energia eólica e compreensão dos resultados que serão apresentados nos capítulos posteriores.

# Capítulo 3

## Fundamentação Teórica

Nessa seção serão apresentados alguns conceitos fundamentais para a metodologia FDI a ser implementada. A ideia central da metodologia proposta é o diagnóstico em duas etapas: geração de evidências de falhas por meio de um modelo de ponto de mudança obtido através de amostragem de Gibbs aplicada a janelas de sinais adquiridos em medidas de sensores; e o posterior processamento dessas evidências de falhas, com a finalidade de isolamento das mesmas, com o uso de redes *fuzzy*/Bayesianas. Na Seção 3.1 será explicada a estratégia de transformação de séries temporais em processos de contagem Poisson com a utilização de clusterização *fuzzy*. A Seção 3.2 descreve o algoritmo do amostrador de Gibbs e como ele pode ser empregado para obtenção de um modelo de ponto de mudança. Finalmente, na Seção 3.3 será construída a ideia básica da inferência *fuzzy*/Bayesiana.

### 3.1 Transformação de séries temporais em processos de contagem Poisson via conjuntos *fuzzy*

A primeira etapa da metodologia proposta consiste em um sistema de FD. O mecanismo de detecção proposto consiste em dois passos. Nessa seção será descrito o primeiro deles: a transformação de séries temporais em processos de contagem Poisson.

A estratégia segue passos semelhante aos propostos em [44], na qual uma determinada série temporal é transformada em distribuição beta através de clusterização *fuzzy*. Entretanto, neste trabalho, a transformação da série temporal é para processos de contagem Poisson, em vez de distribuição beta. Essa modificação se fez necessária para simplificar o processo de

modelagem, uma vez que a distribuição escolhida será a base do processo de detecção de pontos de mudança, isto é na amostragem de Gibbs. Note que se optasse por escolher a distribuição beta, seria necessário o cômputo de cinco distribuições conjuntas completas, o que é uma tarefa computacional dispendiosa. Por outro lado com a opção pelo processo de Poisson, o número de distribuições conjuntas a serem calculadas é reduzido para apenas três.

A fim de ilustrar a mecânica desta transformação, considere série temporal hipotética abaixo:

$$y(t) = \begin{cases} p_1 + 0.1 * \varepsilon(t) - 0.1 * \varepsilon(t - 1), & \text{if } t \leq m, \\ p_2 + 0.1 * \varepsilon(t) - 0.1 * \varepsilon(t - 1), & \text{if } t > m \end{cases} \quad (3.1)$$

na qual  $p_1$  é o primeiro ponto de operação,  $p_2$  é o segundo ponto de operação,  $\varepsilon(t)$  é um sinal de ruído com distribuição  $\pi(\cdot)$ ,  $m$  é um ponto de mudança para (3.1). As Figuras 3.1(a) e 3.1(b) ilustram esta série temporal  $y(t)$  em (3.1) considerando  $p_1 = 1$ ,  $p_2 = 2$  fixos,  $\varepsilon(t) \sim U(0, 1)$ ,  $m = 30$ , e 60 amostras.

A ideia da transformação da série temporal passa por um problema de clusterização dos pontos da série temporal, isto é, agrupamento dos valores  $y(t)$  semelhantes. A clusterização pode realizar agrupamentos de tipo *crisp* ou *fuzzy*. No agrupamento *crisp* um padrão pertence ou não pertence a um determinado grupo, enquanto no *fuzzy* o padrão pode apresentar diferentes graus de pertinência em relação as classes. Neste trabalho será utilizada clusterização *fuzzy*. Existem diversos algoritmos de clusterização entre as quais pode-se citar as redes de Kohonen [45] e o C-means. O C-means [46] será o algoritmo utilizado nesse trabalho.

**Definição (Centro de Cluster fuzzy)** [44] *Seja  $y(t)$  uma série temporal, e considere um  $k$  inteiro positivo. Definindo-se o conjunto*

$$C = \{C_i \mid \min\{y(t)\} \leq C_i \leq \max\{y(t)\}, i = 1, 2, \dots, k\}$$

*tal que resolva o seguinte problema de minimização:*

$$\min \sum_{i=1}^k \sum_{y(t) \in C_i} |y(t) - C_i|^2. \quad (3.2)$$

*O conjunto  $C = \{C_i, i = 1, 2, \dots, k\}$  que minimiza (3.2) é chamada conjunto de centros de cluster para a série temporal  $y(t)$ . O grau de pertinência fuzzy, ou o valor da função de*

*pertinência fuzzy, da relação fuzzy  $y(t) \in C_i$  (que significa  $y(t)$  pertence a cada cluster  $C_i$ ) é expressa por:*

$$\mu_i(t) \triangleq \left[ \sum_{j=1}^k \frac{|y(t) - C_i|^2}{|y(t) - C_j|^2} \right]^{-1} \quad (3.3)$$

■

A ideia central é medir a distância de cada ponto na série temporal  $y(t)$  para cada centro de cluster  $C_i$  para cada conjunto de centros de clusters. Os procedimentos da transformação da série temporal em um processo de contagem de Poisson estão resumidos no Algoritmo 1.

---

**Algoritmo 1:** Algoritmo para a obtenção de um processo de contagem Poisson através de clusterização *fuzzy* C-means

---

**Dados:** Série temporal  $y(t)$ .

**Resultado:** Processo de contagem Poisson.

**início**

Encontre os centros  $C_1$  e  $C_2$  resolvendo (3.2)

Construa as funções de pertinência fuzzy usando (3.3)

Aproxime a função de pertinência por um processo de contagem Poisson

**retorna** A série do processo de contagem Poisson.

---

Um exemplo da transformação é ilustrado abaixo:

- Tendo como entrada a série temporal  $y(t)$  (dada por (3.1));
- Encontram-se  $C_i, i = 1, 2$ , os elementos do conjunto de centros de cluster para  $y(t)$  usando C-means (os centros são denotados por  $C_1$  e  $C_2$  na Figura 3.1(a) com  $p_1 = 1, p_2 = 2$  fixos,  $\varepsilon(t) \sim U(0, 1)$ ,  $m = 30$ , e 60 amostras).
- Calcula-se o grau de pertinência *fuzzy* dados em (3.3), para cada amostra da série temporal,  $y(t)$ , com respeito a cada centro  $C_i$  (as funções de pertinência estão ilustradas na Figura 3.1(b)).

Como se deseja encontrar apenas um ponto de mudança na série, então é necessária a obtenção de apenas dois centros.

O passo final do processo de transformação é o arredondamento de uma das funções de pertinência, por exemplo,  $\mu_1(t)$ , para um processo de contagem Poisson aproximado (zeros e uns), no qual será encontrado o ponto de mudança com o aparato da Amostragem de Gibbs.

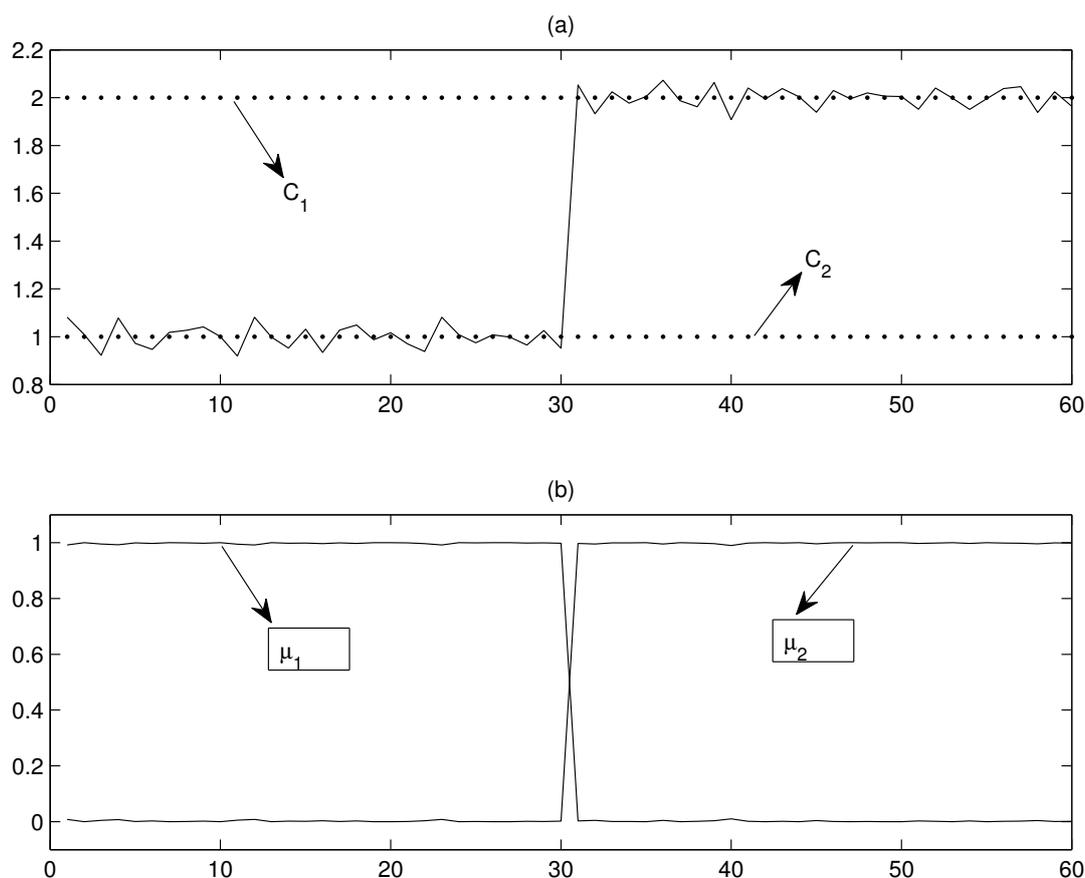


Figura 3.1: Funções de pertinência .

## 3.2 Amostragem de Gibbs para detecção de pontos de mudança

A amostragem de Gibbs é uma técnica para obtenção de um modelo para variáveis aleatórias a partir de uma distribuição marginal sem o cálculo da função de densidade, mas por meio de uma simulação de Monte Carlo via Cadeias de Markov (MCMC). Detalhes adicionais sobre a amostragem de Gibbs podem ser encontrados [47]. Aqui, nós estamos interessados em obter um modelo de ponto de mudança de uma série de observações de um processo Poisson obtido com o uso de clusterização *fuzzy*, descrita na seção anterior.

Antes de apresentar o algoritmo da amostragem de Gibbs [48], [6], considere as seguintes distribuições condicionais completas:

$$\begin{aligned} &\pi(\psi_1|\psi_2, \dots, \psi_p) \\ &\pi(\psi_2|\psi_1, \psi_3, \dots, \psi_p) \\ &\vdots \\ &\pi(\psi_p|\psi_1, \psi_2, \dots, \psi_{p-1}) \end{aligned}$$

O algoritmo da amostragem de Gibbs é descrito no Algoritmo 2.

---

**Algoritmo 2:** Algoritmo da Amostragem de Gibbs
 

---

**Dados:** Sequência de distribuição conjunta.

**Resultado:** Sequência de valores simulados  $\{\psi^{(1)}, \psi^{(2)}, \dots, \psi^{(M)}\}$ .

**início**

Especifique um valor inicial  $\psi^{(0)} = (\psi_1^{(0)}, \dots, \psi_p^{(0)})$

**para**  $j = 1, 2, \dots, M$  **faça**

Gere  $\psi_1^{(j+1)}$  a partir de  $\pi(\psi_1|\psi_2^{(j)}, \psi_3^{(j)}, \psi_4^{(j)}, \dots, \psi_p^{(j)})$

Gere  $\psi_2^{(j+1)}$  a partir de  $\pi(\psi_2|\psi_1^{(j+1)}, \psi_3^{(j)}, \psi_4^{(j)}, \dots, \psi_p^{(j)})$

Gere  $\psi_3^{(j+1)}$  a partir de  $\pi(\psi_3|\psi_1^{(j+1)}, \psi_2^{(j+1)}, \psi_4^{(j)}, \dots, \psi_p^{(j)})$

$\vdots$

Gere  $\psi_p^{(j+1)}$  a partir de  $\pi(\psi_p|\psi_1^{(j+1)}, \dots, \psi_{p-1}^{(j+1)})$

**retorna** os valores  $\{\psi^{(1)}, \psi^{(2)}, \dots, \psi^{(M)}\}$ .

---

No algoritmo 2, a amostragem não se dá diretamente a partir da distribuição posterior propriamente dita. Ao invés disso, simulam-se amostras realizando a varredura através de todas as probabilidades condicionais, uma variável aleatória de cada vez. Uma vez que o algoritmo é iniciado com variáveis aleatórias que não correspondem a valores apropriados, é necessário descartar essas amostras periodicamente, definindo o tempo de *burn-in*, isto é, o período com que as amostras são descartadas.

### 3.2.1 Um modelo de ponto de mudança

Considere que a sequência  $x = x_1; x_2; \dots; x_N$  é observada e a média das observações tem o mesmo valor para todas as amostras  $i = 1, \dots, n$ , isto é 0 ou 1, e apresenta um valor diferente para as amostras  $i = n + 1, \dots, N$ . A contagem, em cada amostra  $i$  é modelada como uma variável de Poisson com função de densidade dada por:

$$Poisson(x_i; \lambda) = e^{-\lambda} \frac{\lambda^{x_i}}{x_i!} \quad (3.4)$$

onde  $\lambda$  é a média da distribuição modelada como uma distribuição gamma com função de densidade:

$$gamma(\lambda; a, b) = \frac{1}{\Gamma(a)} b^a \lambda^{a-1} e^{-b\lambda} \quad (3.5)$$

A média inicial  $\lambda_1$  salta para um novo valor  $\lambda_2$  a partir de uma amostra aleatória  $n$ . Então o modelo para detectar apenas um ponto de mudança é:

$$\begin{aligned} n &\sim U\{1, 2, \dots, N\} \\ \lambda_1 &\sim gamma(\lambda_1; a, b) \\ \lambda_2 &\sim gamma(\lambda_2; a, b) \\ x_i &\sim \begin{cases} Poisson(x_i; \lambda_1), & 1 \leq i \leq n \\ Poisson(x_i; \lambda_2), & n < i \leq N. \end{cases} \end{aligned}$$

O problema de inferir a distribuição posterior sobre as variáveis latentes  $n$ ,  $\lambda_1$  e  $\lambda_2$  pode ser solucionado por meio do teorema de Bayes:

$$p(\lambda_1, \lambda_2, n | x_{1:N}) \sim p(x_{1:n} | \lambda_1) p(x_{n+1:N} | \lambda_2) p(\lambda_1) p(\lambda_2) p(n) \quad (3.6)$$

### 3.2.2 Distribuições Condicionais Completas

Como apresentado no Algoritmo 2, é necessário obter a probabilidade posterior condicional para cada uma das variáveis para realizar a amostragem de Gibbs. Dessa forma, o ponto de partida é obter a distribuição conjunta completa para cada variável aleatória do modelo,  $\lambda_1$ ,  $\lambda_2$  e  $n$ , para em sequência, estimar a distribuição condicional posterior. Uma distribuição conjunta completa é dada em (3.6). Então:

$$\begin{aligned} p(x_{1:n} | \lambda_1) p(x_{n+1:N} | \lambda_2) p(\lambda_1) p(\lambda_2) p(n) &= \left( \prod_{i=1}^n p(x_i | \lambda_1) \right) \times \\ &\quad \left( \prod_{i=n+1}^N p(x_i | \lambda_2) \right) p(\lambda_1) p(\lambda_2) p(n) \end{aligned} \quad (3.7)$$

Definindo  $t_1 = \sum_{i=1}^n x_i$  e  $t_2 = \sum_{i=n+1}^N x_i$ , as distribuições conjuntas completas para cada uma das variáveis é dada por:

$$\begin{aligned} p(\lambda_1 | \lambda_2, n, x_i) &\sim \lambda_1^{(a+t_1-1)} e^{-(b+n)\lambda_1} \\ p(\lambda_2 | \lambda_1, n, x_i) &\sim \lambda_2^{(a+t_2-1)} e^{-(b+N-n)\lambda_2} \\ p(n | \lambda_1, \lambda_2, x_i) &\sim \lambda_1^{t_1} e^{-n\lambda_1} \lambda_2^{t_2} e^{-(N-n)\lambda_2} \end{aligned}$$

### 3.2.3 Um exemplo ilustrativo

Considere a série temporal em (3.1) (veja a ilustração superior na Figura 3.2). A simulação é realizada para  $N = 60$  (amostras). As variáveis  $\lambda_1$  e  $\lambda_2$  são inicializadas por dois valores independentes a partir de  $gamma(a; b)$  com, por exemplo,  $a = 2$  e  $b = 1$ . O número de iterações é  $M = 1200$ . O número de iterações descartadas, como período de *burn-in*, é 200. O resultado é ilustrado na gravura inferior da Figura 3.2. Deste modo, é fácil concluir que o algoritmo detectou corretamente o ponto de mudança.

## 3.3 Redes *fuzzy*/Bayesianas

A rede Bayesiana é um método de inferência baseada no teorema de Bayes para probabilidade condicional, e seu emprego é conveniente em cenários incertos com evidências sólidas, isto é, evidências que podem apenas ser classificadas entre verdadeiras ou falsas. O Teorema de Bayes permite o cálculo de  $P(H_i | \varepsilon_j)$ , ou seja, a probabilidade de a hipótese  $H_i$  ser verdadeira dado que a evidência  $\varepsilon_j$  é certamente verdadeira.

As redes Bayesianas são frequentemente empregadas em sistemas de FDI com diferentes funções, entre as quais pode-se citar: ferramenta de monitoramento estatístico baseado em dados de processos multivariados [49], filtros de partículas [50], e sistema de estimativa paramétrica [51]. Existem também diversas outras aplicações de redes Bayesianas em sistemas de geração de energia eólica, por exemplo, previsão de recursos elétricos, previsão de geração de energia eólica, e ainda em sistemas de FDI e FTC para turbinas eólicas.

Entretanto, a inferência apresenta uma importante desvantagem. Ela não pode ser aplicada diretamente para modelos com evidências incertas. Uma solução eficiente para este problema foi proposta pioneiramente em [52], que formula o conceito de inferência *fuzzy* Bayesiana, cuja ideia central é a aplicação da inferência Bayesiana para dados *fuzzy*, isto é, em circuns-

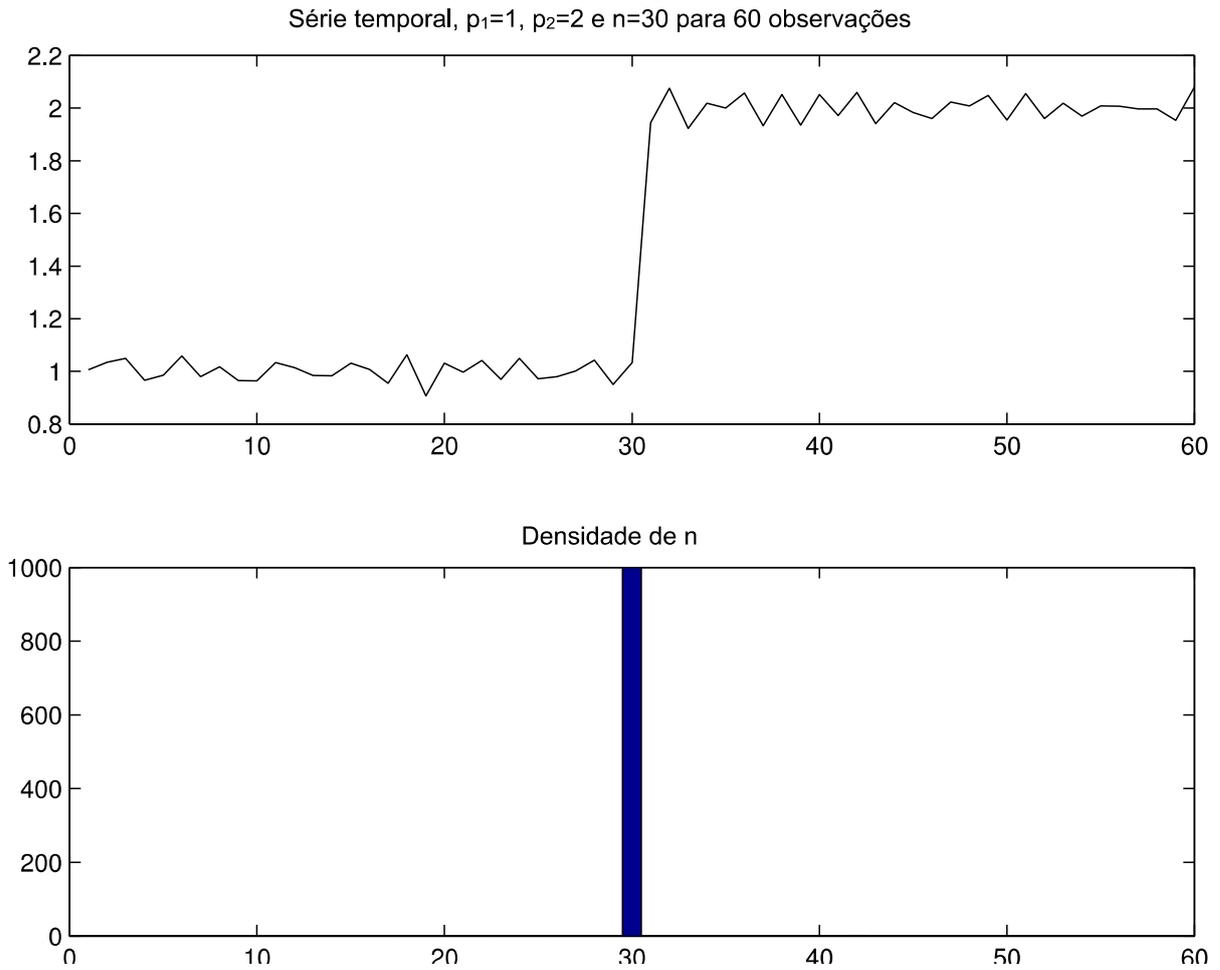


Figura 3.2: Resultados da aplicação da amostragem de Gibbs.

tâncias em que não é possível uma formulação clara das evidências, que portanto são associadas a um grau de pertinência.

Esse conceito foi aplicado para o propósito de FDI por D'Angelo et al. em [53] usando a inferência *fuzzy*/Bayesiana para determinar a confiança  $P(H_i|\tilde{\epsilon}_1, \tilde{\epsilon}_2, \dots, \tilde{\epsilon}_k)$  na hipótese  $H_i$ , dado um conjunto de evidências incertas  $\tilde{\epsilon}_1, \tilde{\epsilon}_2, \dots, \tilde{\epsilon}_k$ , de cujas incertezas são descritas por um par de funções de pertinência  $\mu_{\tilde{\epsilon}}$ . Nessa abordagem, o cálculo de  $P(H_i|\tilde{\epsilon}_1, \tilde{\epsilon}_2, \dots, \tilde{\epsilon}_k)$  depende apenas da tabela de probabilidades conjuntas  $P(H_i|\epsilon_1, \epsilon_2, \dots, \epsilon_k)$  que é obtida por meio do teorema de Bayes. A probabilidade  $P(H_i|\tilde{\epsilon}_1, \tilde{\epsilon}_2, \dots, \tilde{\epsilon}_k)$  é dada por [53]:

$$P(H_i|\tilde{\epsilon}_1, \tilde{\epsilon}_2, \dots, \tilde{\epsilon}_k) = \frac{\sum_{j=1}^{2^k} P(H_i|\epsilon_{j1}, \epsilon_{j2}, \dots, \epsilon_{jk}) (\prod_{m=1}^k \mu_{\tilde{\epsilon}_{jm}})}{\sum_{j=1}^{2^k} \prod_{m=1}^k \mu_{\tilde{\epsilon}_{jm}}}. \quad (3.8)$$

**Teorema 3.1** A soma das probabilidades conjuntas das hipóteses relativas a um conjunto de

evidências fuzzy é

$$\sum_{i=1}^n P(H_i | \tilde{\epsilon}_1, \tilde{\epsilon}_2, \dots, \tilde{\epsilon}_k) = 1, \quad (3.9)$$

onde  $n$  é o número total de hipóteses.

O Teorema 3.1 implica na conclusão que a soma das probabilidades condicionais relativas a evidências fuzzy são também unitárias, demonstrando que técnica é consistente e pode ser utilizada para a inferência neste problema de FDI.

### 3.4 Conclusão

Neste capítulo foram apresentados os fundamentos teóricos em que se baseia o sistema de FDI proposto. Foram explanados brevemente os recursos utilizados nos processos de detecção de falhas (clusterização *fuzzy* e amostragem de Gibbs) e diagnóstico de falhas (redes *fuzzy*/Bayesianas). No capítulo seguinte, o *framework* empregado para FDI será estudado e será descrito como cada um dos componentes abordados neste capítulo se relacionam.

## Capítulo 4

# Arquitetura e Metodologia de FDI

Nesse capítulo as principais contribuições deste trabalho são estudadas com maior profundidade. Aqui será apresentada a metodologia proposta para FDI no *benchmark* de turbina eólica e a estrutura geral empregada para esse propósito. A Seção 4.1 fornece uma visão geral do *framework* de FDI e a Seção 4.2 descreve o algoritmo de FDI empregado. Finalmente, a Seção 4.3 discute aspectos relativos a implementação do sistema proposto, descrevendo as etapas *offline* relacionadas ao sistema FDI.

### 4.1 Arquitetura do Sistema de FDI

O sistema de FDI consiste em dois principais componentes: o módulo de detecção de ponto de mudança e módulo de isolamento de falhas fuzzy/Bayesiano. Uma visão geral do *framework* de FDI empregado é retratada na Figura 4.1.

O primeiro módulo lê os sensores disponíveis no *benchmark* da turbina eólicas, janelando os sinais de medida. Cada janela extraída consiste em uma série temporal que é, em seguida, transformada em um processo de contagem Poisson via clusterização fuzzy, utilizando os procedimentos descritos na Seção 3.1. Em sequência, a janela é processada pelo amostrador de Gibbs, que indica a distribuição da probabilidade de ponto de mudança para os pontos da janela. Cada sinal representativo deve passar por esse processamento separadamente, no entanto nem todas as medidas de sensores foram selecionadas como sinais representativos, assim como, para a metodologia proposta, nem todos os sinais representativos precisam ser medidas diretas de sensores, mas podem ser sinais resultantes de pré-processamento.

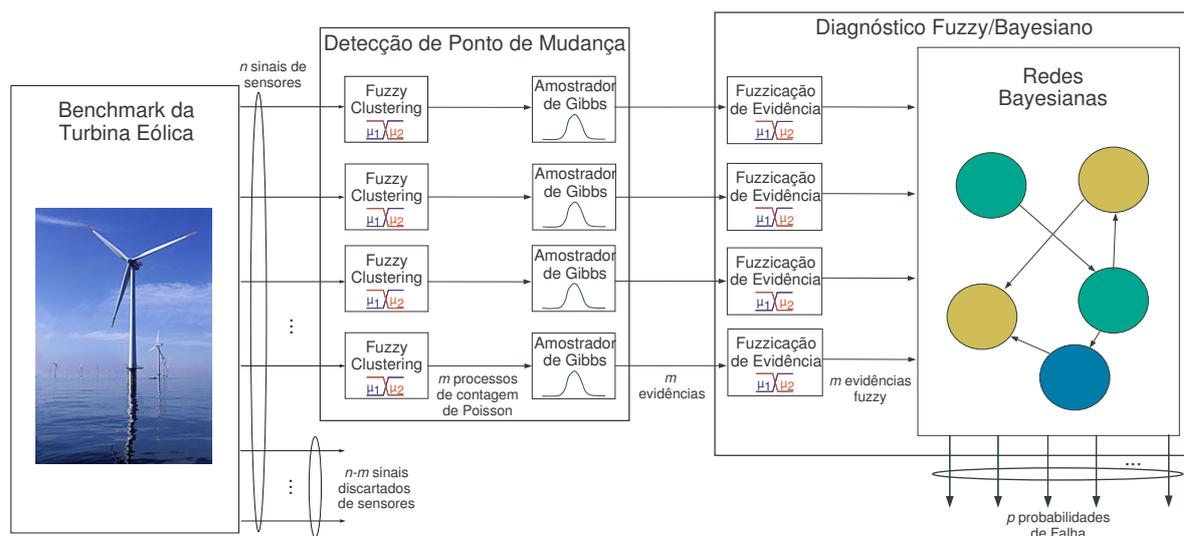


Figura 4.1: Implementação do Sistema de FDI.

O segundo módulo consiste na rede fuzzy/Bayesiana na qual a probabilidade de ocorrência de ponto de mudança é fuzzificada e avaliada. As evidências fuzzy e tabela de probabilidade condicional, esta última obtida por redes Bayesianas tradicionais, são empregadas pela inferência fuzzy/Bayesiana, descrito na Seção 3.3, para classificar a falha. Para cada falha a ser considerada é empregada uma rede Bayesiana diferente.

## 4.2 Algoritmo de FDI proposto

O processo de detecção e geração de evidências é aplicado em  $m$  janelas deslizantes e cada janela é associada a um sinal representativo. Cada janela tem o comprimento de  $T_w$  segundos e o tempo de deslizamento de  $T_{slide}$  segundos, isto é, a cada  $T_{slide}$  segundos o algoritmo é repetido sobre uma nova janela de  $T_w$  segundos, dos quais  $T_w - T_{slide}$  são os últimos dados da janela anterior e  $T_{slide}$  são dados novos.

Para cada janela são obtidos dois centros de cluster fuzzy, e uma função de pertinência que é obtida por meio da equação (3.3) e aproximada para um processo de contagem Poisson. Então, um modelo para ponto de mudança é obtido através de amostragem de Gibbs para cada um dos processos Poisson gerados, ou seja, para cada amostra das janela de cada sinal representativo é associada uma probabilidade daquela amostra conter uma novidade (ser um ponto de mudança). A maior probabilidade da janela é tomada como evidência para a inferência

fuzzy/Bayesiana.

As evidências  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_m$  originadas no amostrador de Gibbs são fuzzificadas para que incorporem incertezas, resultando em evidências fuzzy  $\tilde{\varepsilon}_1, \tilde{\varepsilon}_2, \dots, \tilde{\varepsilon}_k$ . Durante a classificação fuzzy/Bayesiana, é calculada, para cada uma das  $p$  falhas de interesse, a probabilidade de a falha estar ocorrendo usando a equação (3.8), as evidências fuzzy e as probabilidades Bayesianas, obtidas por meio de uma tabela de probabilidade condicional construída em etapa *offline* com o uso de redes Bayesianas também treinadas *offline*.

Em resumo, a estratégia de FDI, para cada janela amostrada, consiste nos procedimentos descritos no Algoritmo 3.

---

#### **Algoritmo 3:** Algoritmo de FDI

---

**Dados:**  $m$  séries temporais de medidas de sensores  $y_1(t), y_2(t), \dots, y_m(t)$  e  $p$  redes Bayesianas.

**Resultado:** Classificação de Falhas:  $F_1$  ou  $F_2 \dots$  ou  $F_p$

**início**

**para**  $i = 1, 2, \dots, m$  **faça**

    Transforme  $y_i(t)$  em um processo de contagem Poisson por meio de clusterização fuzzy;

    Obtenha o modelo de ponto de mudança usando amostragem de Gibbs;

    Obtenha as evidências de falhas para cada sinal, isto é as probabilidades de mudança máximas nas séries;

    Calcule as evidências fuzzy;

**para**  $j = 1, 2, \dots, p$  **faça**

    Obter a tabela de probabilidade condicional através da  $j$ -ésima rede Bayesiana;

    Calcule a probabilidade de ocorrência  $P_{F_j}$  da  $j$ -ésima falha usando (3.8);

**retorna** Classificação de falhas:  $F_1$  ou  $F_2 \dots$  ou  $F_p$

---

### 4.3 Implementação do sistema de FDI proposto

Nesta seção serão descritas as etapas necessárias para implementação do sistema de FDI descrito nas seções anteriores. As seções anteriores discutiram aspectos relativos ao funcionamento online do sistema, aqui serão discutidos os fatores que devem ser considerados na fase *offline* do projeto.

O processo de implementação e ajuste do sistema de FDI proposto consiste em quatro etapas principais e consecutivas:

- Geração do banco de sinais;

- Ajuste dos amostradores de Gibbs;
- Seleção de sinais representativos;
- Treinamento das redes fuzzy-Bayesianas.

O diagrama da Figura 4.2 resume as etapas supramencionadas a serem seguidas de forma a obter o sistema de FDI ajustado.

### 4.3.1 Geração do banco de sinais

Na primeira etapa, um banco de dados é formado por sinais obtidos a partir de medidas de sensores do *benchmark* da turbina eólica, e é representada pela cor amarela no diagrama da Figura 4.2, simulado em diferentes circunstâncias, isto é, para diferentes configurações de falhas e perfis de vento. A produção desse volume de dados é essencial para abordagens baseadas em dados como a proposta aqui.

Primeiramente deve-se gerar (ou obter experimentalmente) diferentes padrões de vento e de falhas. A combinação desses padrões devem produzir diferentes cenários de teste para a simulação do *benchmark*.

Em seguida, o modelo da turbina deve ser simulado para cada um dos cenários gerados. Os sinais obtidos com a medição dos diferentes sensores existentes no modelo devem ser armazenados.

Com isso, ao final dessa etapa se alcançará um banco de sinais, que ilustra o comportamento da turbina para diferentes cenários de falha e vento. Quanto maior o número de cenários, maior a quantidade de informações sobre o sistema, e mais preciso será o sistema de FDI.

### 4.3.2 Ajuste do amostrador de Gibbs

A etapa seguinte é o ajuste do amostrador de Gibbs, representada pela cor azul no diagrama da Figura 4.2. Na Seção 4.2 são descritos os parâmetros do amostrador de Gibbs, que são fundamentalmente  $T_w$  e  $T_{slide}$ . A combinação desses valores deve determinar a sensibilidade da detecção de novidades e o tempo de execução do algoritmo. A largura da janela é controlada por  $T_w$ . Janelas muito longas levam a execução de mais simulações MCMC e portanto um maior tempo de execução do algoritmo do detector de Gibbs. No entanto, janelas muito curtas tendem a levar a um maior número de falsas detecções. Deve-se manter uma quantidade

razoável de dados passados, controlado pelo  $T_{slide}$ , encontrando um compromisso entre tempo de execução e FDR.

Por isso é importante a etapa de ajustes no amostrador de Gibbs. Nessa etapa, algumas amostras de sinais do banco de sinais são usadas para que se verifique o desempenho do Amostrador. Caso o desempenho seja fraco, ou seja, apresente muitos falso alarmes ou detecções perdidas, deve-se alterar o valor de  $T_w$  e  $T_{slide}$ , prezando pelo menor tempo de execução do algoritmo. Uma vez que a configuração adequada é obtida, o algoritmo do amostrador de Gibbs estará pronto para ser usado para o propósito de modelagem de novidades, que será equivalente a indicação de falhas.

### 4.3.3 Seleção de sinais representativos

A terceira etapa consiste na seleção dos sinais que serão usados para o propósito de detecção de falhas, representada pela cor vermelha 4.2. O banco de sinais é composto por um grande número de sinais de sensores por cenário, que no entanto podem não ser suficientes para detectar algumas falhas, ao mesmo tempo que muitos deles podem representar a mesma informação. Por isso deve-se encontrar o menor conjunto de sinais que sejam capazes de fornecer informações sobre todos os cenários de falhas.

Primeiramente, deve-se expandir o conjunto de sinais inicialmente formado por sinais de sensores do *benchmark*, podem ser adicionados novos sinais derivados dos primeiros. Esse processo dará origem a novos sinais aumentando o volume de informação a ser processada, o que aumentaria o custo computacional do algoritmo de FDI.

Visando reduzir esse custo computacional, deve-se eliminar o maior número de sinais possíveis desse conjunto, num processo de compressão que deve prezar pela quantidade de informações sobre falhas. Para isso deve-se utilizar a amostragem de Gibbs para todo o banco de sinais, e registrar as detecções de novidades produzidas por esse. Desse registro, derivam-se duas matrizes, a matriz de assinatura de falhas, que associa a detecção de cada falhas aos sinais do conjunto, e a matriz de detecções incorretas, que de forma semelhante, indica quais sinais indicam detecções na ausência de falhas. A concatenação dessas matrizes produz a matriz de falhas e detecções bruta. Dessa matriz pode-se determinar o grau de correlação entre os sinais, e excluir alguns dos sinais extremamente correlacionados, isto é que indicam informações redundantes. Desse processo de filtragem de sinais correlacionados obtêm-se a matriz de falhas e

detecções reduzida.

#### 4.3.4 Treinamento das redes fuzzy-Bayesianas

Na etapa final, representada pela cor verde no diagrama da Figura 4.2, com a matriz de falhas e detecções reduzida, pode-se treinar as redes fuzzy/Bayesianas para o propósito de classificação de falhas. Para isso deve-se realizar duas tarefas, construir os fuzzificadores que serão usados para transformar os sintomas fornecidos pelo amostrador de Gibbs em evidências fuzzy, e treinar redes Bayesianas.

A construção de fuzzificadores consiste em ajustar as funções de pertinência para cada sinal, tendo em vista o perfil da distribuição de probabilidade de mudança modelada por amostragem Gibbs. Deve-se definir os níveis de probabilidade a partir da qual a pertinência é unitária e abaixo da qual é nula, para então formular as funções de pertinência.

O treinamento das redes Bayesianas é feito a partir dos padrões armazenados na matriz de falhas e detecções reduzida. Para cada falha a ser identificada uma rede diferente deve ser treinada. Depois de treinada ela deve ser validada a partir de dados de falhas, caso a inferência não esteja distinguindo bem as falhas, deve-se retornar ao processo de filtragem de sinais correlacionados, acrescentando (ou alterando) sinais representativos. Esse processo é repetido até que se obtenha um desempenho satisfatório das redes Bayesianas.

Com as redes Bayesianas treinadas, pode-se obter as tabelas de probabilidade condicionais que serão utilizadas no algoritmo de FDI proposto.

## 4.4 Conclusão

Este capítulo descreveu o *framework* e o algoritmo propostos para FDI, além das etapas empregadas na sua implementação. Foram apresentadas aqui as principais contribuições do trabalho: a estrutura de FDI a ser empregada *online* com detecção baseada em amostragem de Gibbs e isolamento baseado em inferência *fuzzy*/Bayesiana; o procedimento de implementação desse sistema; e a metodologia de seleção de sinais representativos para detecção e isolamento de falhas. O próximo capítulo apresentará e avaliará os resultados da proposta aqui apresentada.

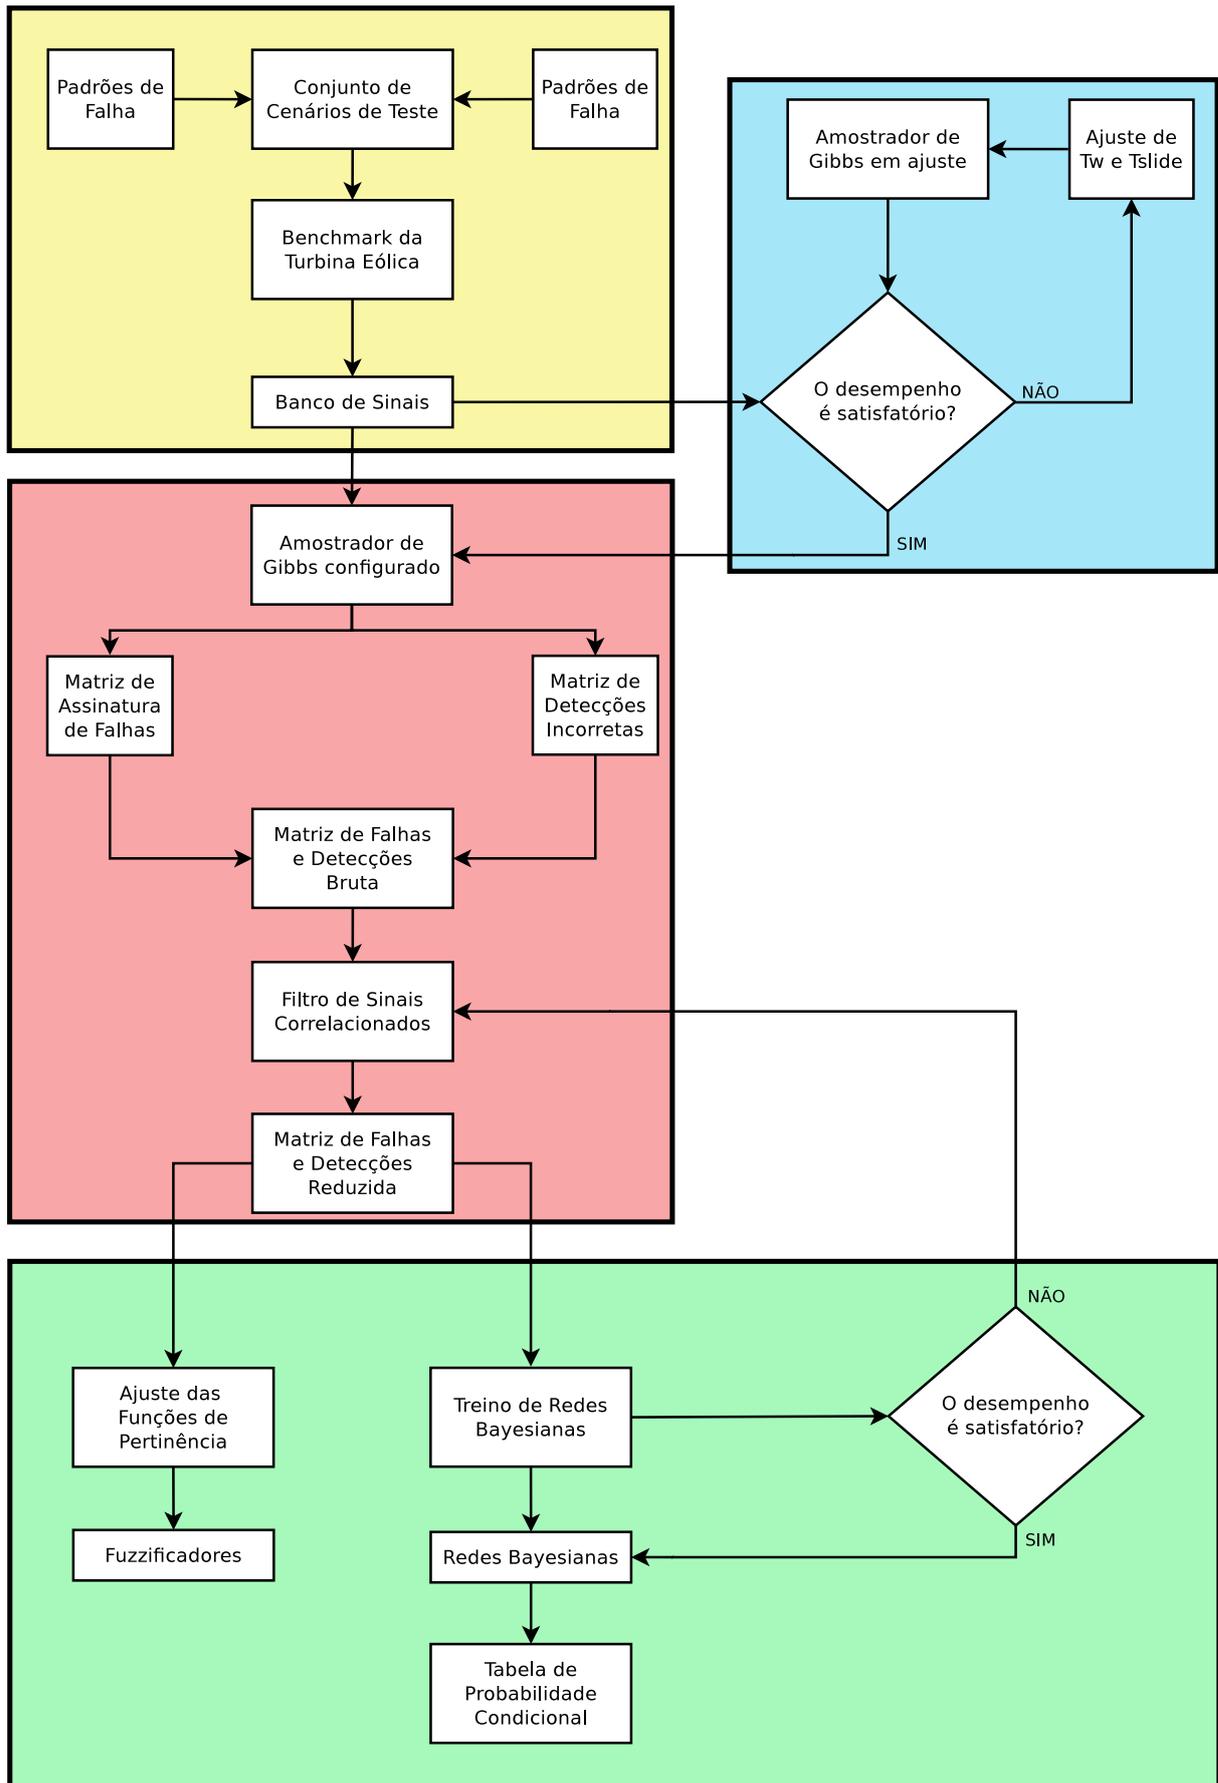


Figura 4.2: *framework* para FDI.

## Capítulo 5

# Aplicação da metodologia de FDI para o *benchmark* de turbina eólica

Nesse capítulo serão apresentados os resultados obtidos com a aplicação da metodologia FDI proposta no *benchmark* de turbina eólica. A Seção 5.1 são apresentados o perfil de velocidade de vento empregado e o comportamento potência gerada para a simulação com o mesmo. Na Seção 5.2 serão discutidos alguns fatores importantes a respeito da implementação da metodologia proposta. Finalmente, na Seção 5.3 serão apresentados os resultados do sistema FDI aplicado ao perfil de falhas padrão e para falhas simultâneas.

### 5.1 Perfil de vento e potência gerada

Na fase de testes, a estratégia de FDI foi aplicada para o *benchmark* de turbina eólica usando o perfil de vento ilustrado Figura 5.1 e a sequência de falhas apresentada na Tabela 2.3, ambos os modelos padrões sugeridos por [2]. Note que a simulação tem uma duração de 4400 segundos. O modelo de vento é extraído de medições reais de turbinas eólicas *offshore* no mar do Norte.

A potência gerada e o torque do gerador, resultante da aplicação desse modelo de vento no *benchmark* e com o funcionamento afetado pela sequência padrão de falhas, são ilustrados respectivamente nas Figuras 5.2 e 5.3. As áreas sombreadas, nos três gráficos, representam os intervalos de tempo em que está ocorrendo algum tipo de falha.

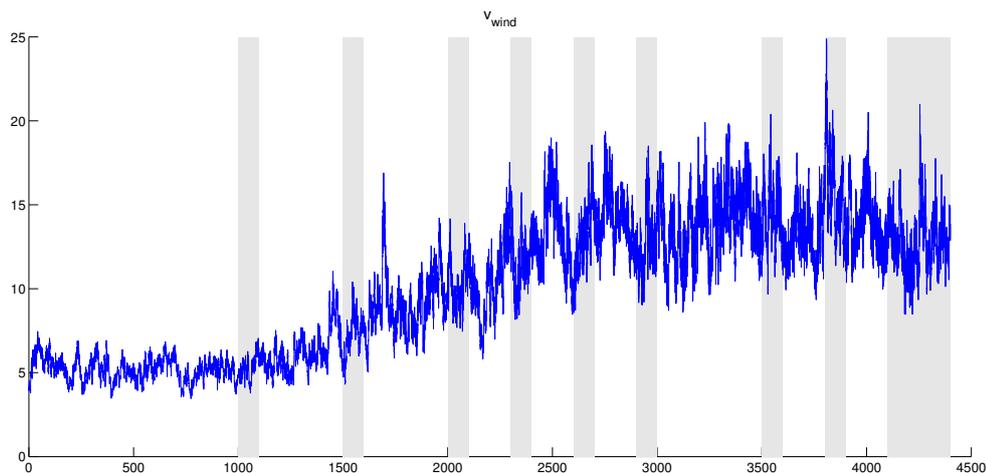


Figura 5.1: Perfil da velocidade de vento utilizada para o teste do esquema de FDI.

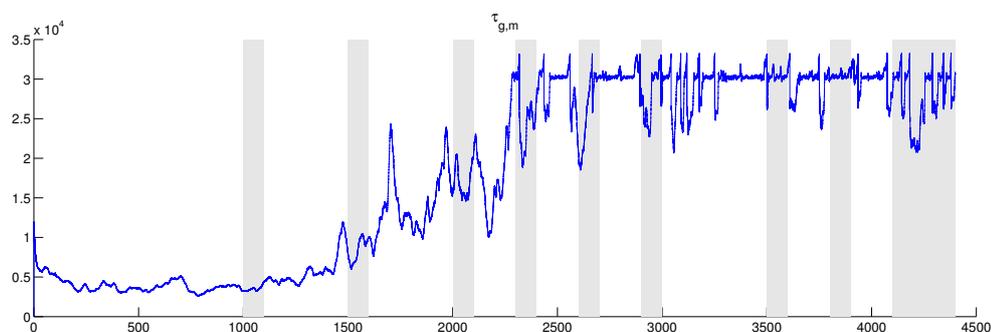


Figura 5.2: Torque no gerador na simulação do *benchmark* com o perfil de velocidade da Figura 5.1.

## 5.2 Aspectos críticos da implementação

O sistema de FDI baseado em dados proposto para o *benchmark* da turbina eólica demanda análise exhaustiva de resultados de simulações em diferentes cenários. Existem duas dificuldades principais encontradas nessa tarefa:

- A fonte principal de problemas no processo de FDI é a fonte de energia, nesse caso o vento, o comportamento de difícil previsão e a sua capacidade de afetar todos os módulos da turbina podem levar a confusões na detecção. O tratamento inadequado dessa variável pode aumentar significativamente o número de detecções falsas ou incorretas;
- O tamanho do banco de dados a ser processado para que a detecção e o diagnóstico se tornem eficientes. Técnicas baseadas em dados, como a proposta aqui, demandam um

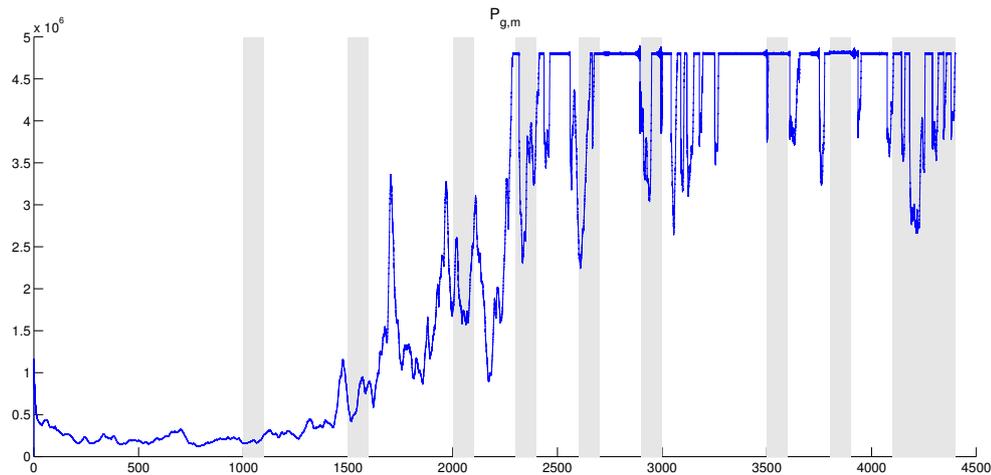


Figura 5.3: Potência gerada pelo modelo de turbina eólica diante do perfil de velocidade da Figura 5.1.

volume muito grande de dados, o que demanda muito recurso computacional e tempo para aperfeiçoamento do sistema.

Existe um claro *trade-off* entre essas duas questões que deve ser ponderado em cada etapa do projeto do sistema. A performance do sistema de FDI pode ser melhorada com o uso de mais sinais para serem analisados e mais cenários de simulação, dessa forma o sistema conseguirá fazer a distinção entre efeitos de variações na velocidade do vento e efeitos da presença de falhas com mais precisão, no entanto esse avanço se dará com altos custos computacionais.

Nesse trabalho, algumas ações foram tomadas com o objetivo de encontrar o ponto ótimo entre precisão e custos computacionais. A primeira ação recomendada para reduzir os efeitos do vento no sistema de FDI é utilizar, além dos sinais obtidos diretamente dos sensores, sinais obtidos através da comparação entre diferentes sinais, isto é, sinais resultantes da diferença entre medidas. Por exemplo, além do emprego do sinal do sensor 1 de ângulo de arfagem da pá 1,  $\beta_{1,m1}$ , e do sinal do sensor do ângulo de arfagem da pá 3,  $\beta_{3,m2}$ , também pode ser analisado o sinal resultante da diferença entre os dois, aqui denominado  $D_{\beta_{1,m1},\beta_{3,m2}}$ . Essa estratégia é uma alternativa útil para atenuar os efeitos da variação na velocidade do vento (que afeta todos os sensores).

As diferentes combinações possíveis de sinais de diferença podem expandir muito o número de sinais, o que pode tornar o problema computacionalmente intratável, principalmente devido ao consumo de memória e tempo de processamento para treinamento das redes Baye-

sianas, que aumenta exponencialmente com o número de variáveis, número que é limitado a 32 variáveis na toolbox de Redes Bayesianas do MATLAB, que foi utilizada nesse trabalho. Para superar esse efeito, deve-se analisar a correlação entre os sinais para reduzir o número de sinais a serem empregados, e conseqüentemente o número de variáveis de entrada da rede fuzzy/Bayesiana.

Para exemplificar esse processo de redução por correlação, considere cinco sinais  $s_1, s_2, s_3, s_4,$  e  $s_5$ , que são utilizados com a finalidade de detectar e isolar duas possíveis falhas  $F_1$  e  $F_2$ . Suponha que a aplicação exaustiva do amostrador de Gibbs e a análise de seus resultados permitam construir a matriz  $D$  de falhas e detecções brutas dada por (5.1). Cada coluna corresponde a uma amostra diferente de padrões de detecção, as cinco primeiras linhas correspondem a detecção de ponto de mudança para cada sinal, e as duas últimas linhas correspondem a ocorrência real das duas falhas (conhecida previamente). Os padrões 1's indicam a detecção ou ocorrência positiva, de modo contrário os padrões 0's indicam a não-deteção ou não-ocorrência de falhas.

$$D = \begin{bmatrix} 0 & 1 & 1 & 0 & 1 & 1 & 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 1 & 1 \\ 0 & 0 & 0 & 1 & 0 & 0 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 0 & 1 & 1 & 1 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 1 & 1 & 1 & 0 & 0 \\ 1 & 1 & 1 & 0 & 0 & 0 & 1 & 1 & 0 & 1 \\ 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 & 1 \end{bmatrix} \quad (5.1)$$

A correlação entre duas populações  $A$  e  $B$ , com  $n$  amostras, onde  $\bar{a}$  e  $\bar{b}$  são as médias das medidas de  $A$  e  $B$ , e  $\sigma_A$  e  $\sigma_B$  são os desvios padrões de  $A$  e  $B$ , pode ser calculada por:

$$\text{corr}(A, B) = \frac{\sum_{i=1}^n a_i b_i - n\bar{a}\bar{b}}{(n-1)\sigma_A\sigma_B} \quad (5.2)$$

Para esse exemplo, uma matriz simétrica de correlação pode ser construída, onde cada elemento  $c_{ij}$  é o coeficiente de correlação entre o  $i$ -ésimo sinal e o  $j$ -ésimo sinal. Para a matriz  $D$ , a matriz de correlação associada  $C$  é dada por:

$$C = \begin{bmatrix} 1.00 & -0.36 & -0.41 & 0.80 & 0.67 & 0.17 & 0.17 \\ * & 1.00 & 0.65 & -0.52 & -0.09 & 0.09 & 0.53 \\ * & * & 1.00 & -0.65 & 0.00 & 0.00 & -0.41 \\ * & * & * & 1.00 & 0.53 & 0.36 & -0.09 \\ * & * & * & * & 1.00 & 0.25 & 0.25 \\ * & * & * & * & * & 1.00 & -0.25 \\ * & * & * & * & * & * & 1.00 \end{bmatrix} \quad (5.3)$$

Considerando, que 0.6 é um grau de correlação suficientemente alto, pode-se excluir alguns sinais fortemente correlacionados e que representam as mesmas informações. Nesse exemplo, note que  $c_{14} = 0.8$ ,  $c_{15} = 0.67$ , e  $c_{23} = 0.65$ , o que indica que os sinais  $s_4$  e  $s_5$  apresentam grande correlação com o sinal  $s_1$ , assim como o sinal  $s_3$  tem grande correlação com o sinal  $s_2$ . Esses resultados permitem a eliminação dos sinais  $s_3$ ,  $s_4$  e  $s_5$ .

Note que o procedimento descrito acima corresponde ao processo de seleção de sinais representativos, na fase de projeto, o qual foi mencionado na Seção 4.3.3 do capítulo anterior. A inclusão de sinais de diferença equivale a fase de expansão do banco de sinais, e a filtragem por correlação corresponde a fase de filtro de sinais correlacionados.

## 5.3 Resultados

Para validar a metodologia, foram feitas 12 simulações no *benchmark* de turbina eólica usando o mesmo perfil de velocidade de vento que está ilustrado na Figura 5.1 e a sequência de falhas padrão apresentada na Tabela 2.2. Além disso foram feitas simulações com uma sequência de falhas diferente, onde existe a ocorrência simultânea de falhas.

### 5.3.1 Sequência de padrão de falhas

A abordagem proposta detectou e isolou com sucesso as falhas  $F_1$ ,  $F_3$ ,  $F_4$ ,  $F_5$  e  $F_9$  em todas as simulações, sem qualquer falso alarme ou detecção perdida. As Figuras 5.4- 5.7 descrevem uma dessas simulações com a sequência padrão de falhas na Tabela 2.2. A linha pontilhada vermelha nas figuras ilustram a duração do evento de falha. As imagens superiores nas Figuras de 5.4 a 5.7 representam os sinais originais de medidas de sensores, e as figuras

abaixo representam a probabilidade de ocorrência de falha calculada com o uso da metodologia proposta. Analisando as figuras, todos os 5 tipos de falhas foram isolados e classificados corretamente pela rede fuzzy/Bayesiana.

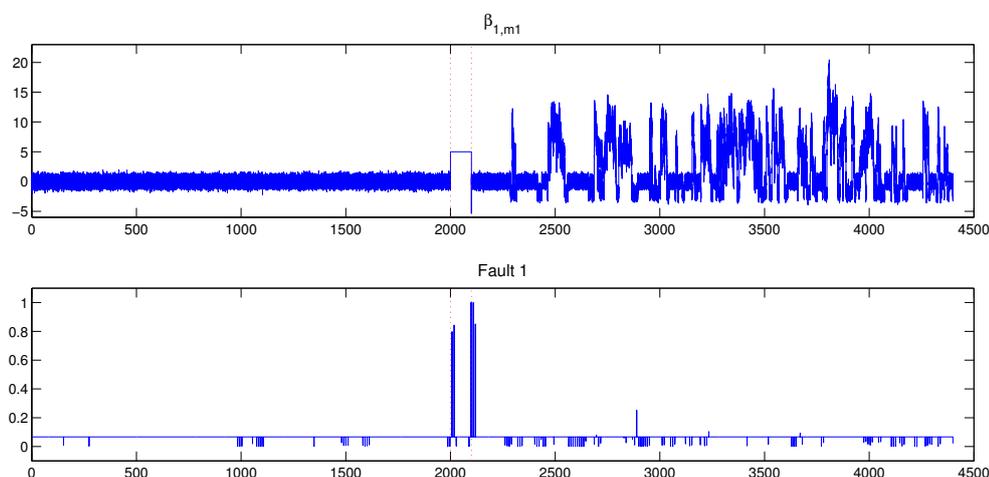


Figura 5.4: Indicação da Falha 1.

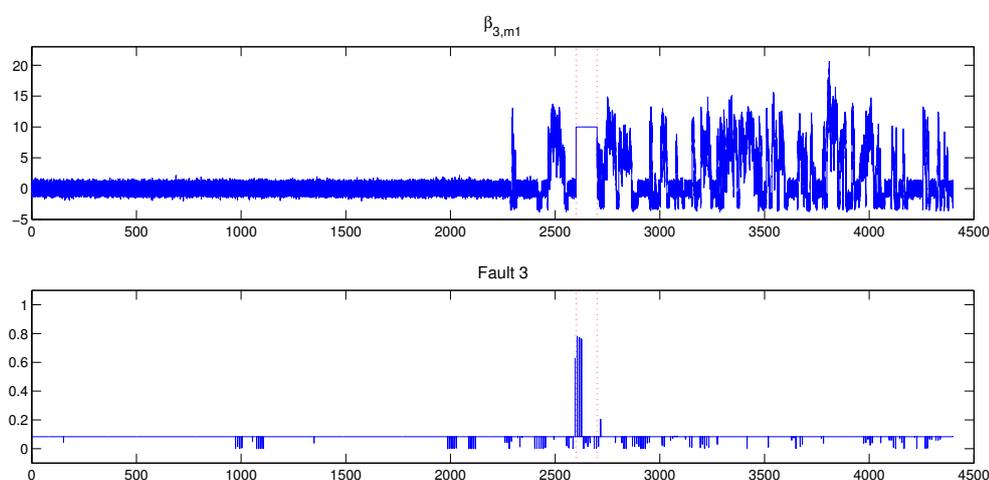


Figura 5.5: Indicação da Falha 3.

O mesmo procedimento foi aplicado a mais de 60 simulações com outros perfis de velocidade de vento e sequência de falhas. Em todos esses testes as falhas  $F_1$ ,  $F_3$ ,  $F_4$ , e  $F_5$  também foram isoladas e detectadas com sucesso.

A falha  $F_2$  apresentou mais dificuldades em sua detecção e isolamento, o que também é relatado por outros trabalhos (ver [2] e referências). Por essa razão, o amostrador de Gibbs

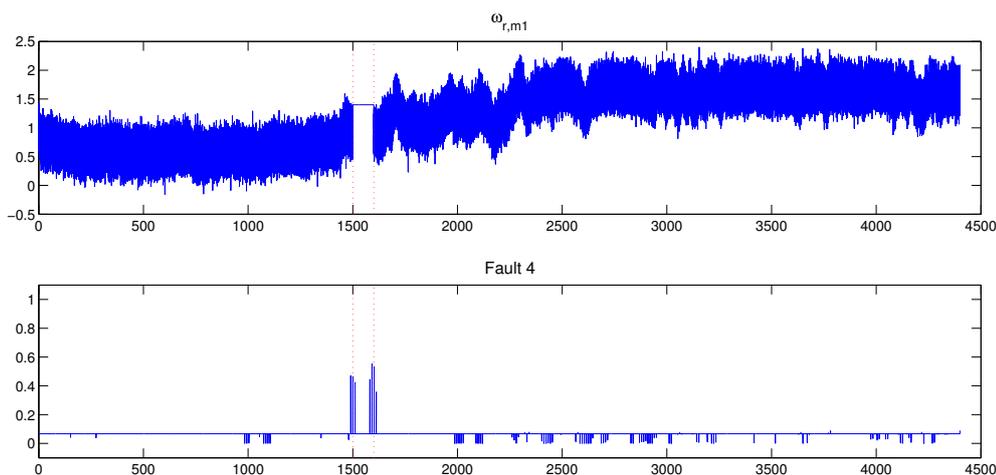


Figura 5.6: Indicação da Falha 4.

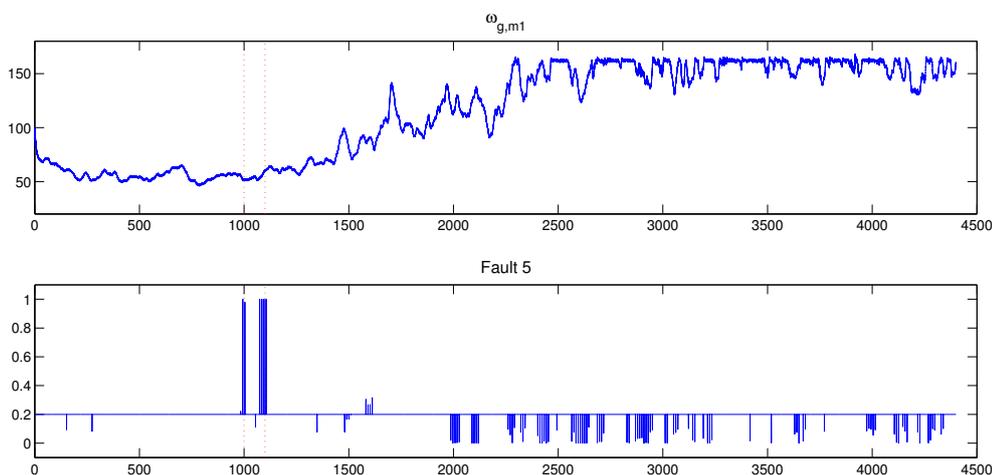


Figura 5.7: Indicação da Falha 5.

recebeu um ajuste especial para esse cenário de falha e um tamanho maior de janela ( $T_w$ ) foi utilizado. Esse novo ajuste tornou o sistema de detecção de novidades mais sensível, e consequentemente apareceram algumas falsas detecções, como pode ser visto na Figura 5.8. O gráfico superior da Figura 5.8 representa o sinal original de medida do sensor, e o inferior representa a probabilidade de ocorrência de falhas indicada pela rede fuzzy/Bayesiana.

A falha  $F_6$  foi detectada corretamente utilizando-se amostragem de Gibbs, no entanto o isolamento não foi bem sucedido. Isso aconteceu devido ao efeito desta falha sobre os sinais, o qual é muito similar ao efeito causado por mudanças rápidas na velocidade do vento, portanto a rede *fuzzy*/Bayesiana não pode determinar com precisão se os padrões de detecção

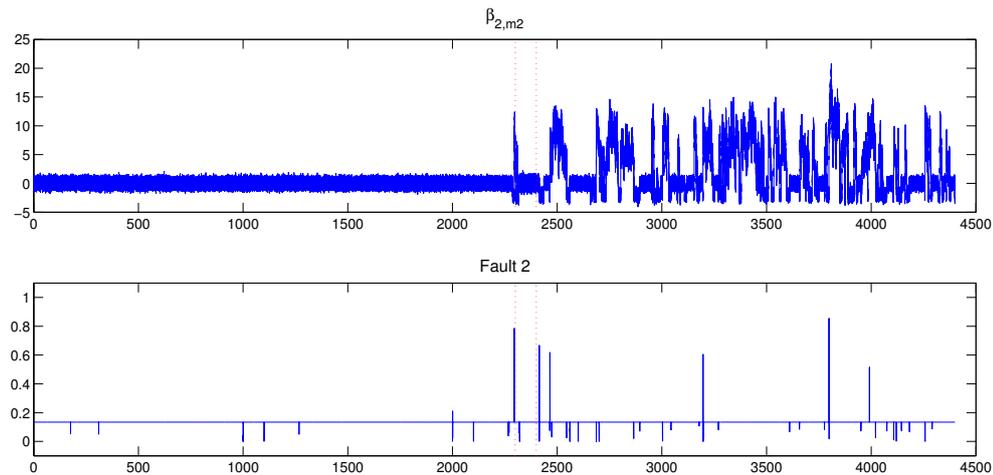


Figura 5.8: Indicação da Falha 2.

correspondiam a falhas ou a variações no vento.

De fato, a metodologia proposta para produção de novos sinais artificiais e seleção de sinais representativos permite futuras melhorias usando o mesmo *framework* de FDI. Com diferentes técnicas de processamento de sinais podem ser produzidos novos sinais. Esse recurso foi utilizado, por exemplo, para permitir a detecção e diagnóstico da falha  $F_9$ . A literatura aponta que essa é uma falha de difícil detecção, a qual não podia ser detectada com o simples uso dos sinais de sensores, no entanto a mesma foi detectada e isolada com sucesso com a introdução de sinais obtidos por meio da decomposição wavelet. A figura 5.9 mostra a indicação correta da ocorrência da falha  $F_9$ .

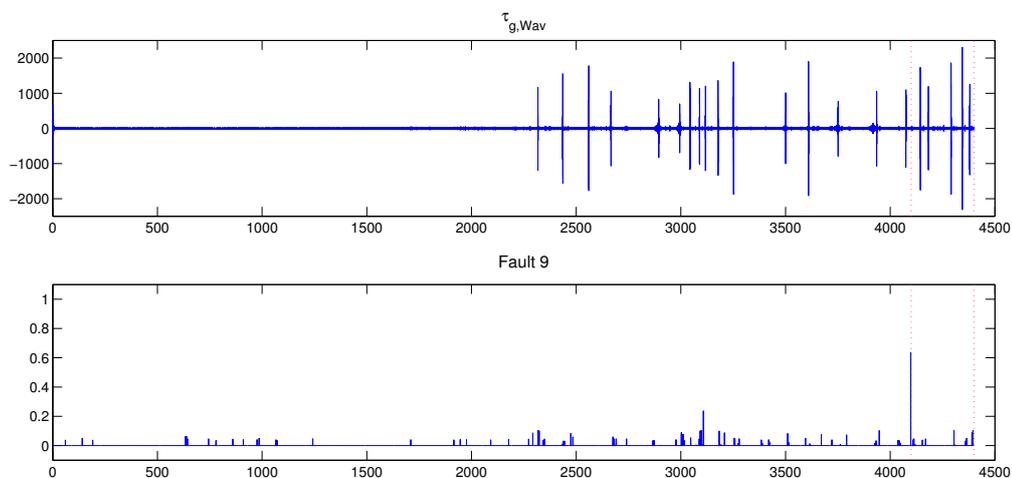


Figura 5.9: Indicação da Falha 9.

A figura 5.10 mostra o exemplo de uma falha que não foi identificada corretamente, a falha  $F_8$ , note que não existe uma indicação de probabilidade em nenhum ponto da simulação. Apesar da incapacidade de detecção de algumas falhas, com o uso da metodologia proposta nesse trabalho, é notável que a maioria das abordagens baseadas em dados na literatura também falham na detecção e isolamento dessas falhas. Além disso a própria proposta metodologica já aponta caminhos para evolução do sistema. Ademais, o sistema proposto nesse trabalho apresentou baixas taxas de falsas detecções. As figuras 5.4 a 5.9 mostram que, com exceção da falha  $F_2$ , nenhuma falha foi indicada fora do seu momento de ocorrência, mesmo que os sinais correspondentes a essas falhas seja bastante afetados durante a ocorrência das demais. A figura 5.11 permite a comparação das indicações de ocorrência de todas as falhas detectadas e isoladas com sucesso, nesta figura as linhas tracejadas vermelhas indicam a ocorrência da falha em questão e as linhas tracejadas verdes indicam a ocorrência de alguma outra falha no sistema.

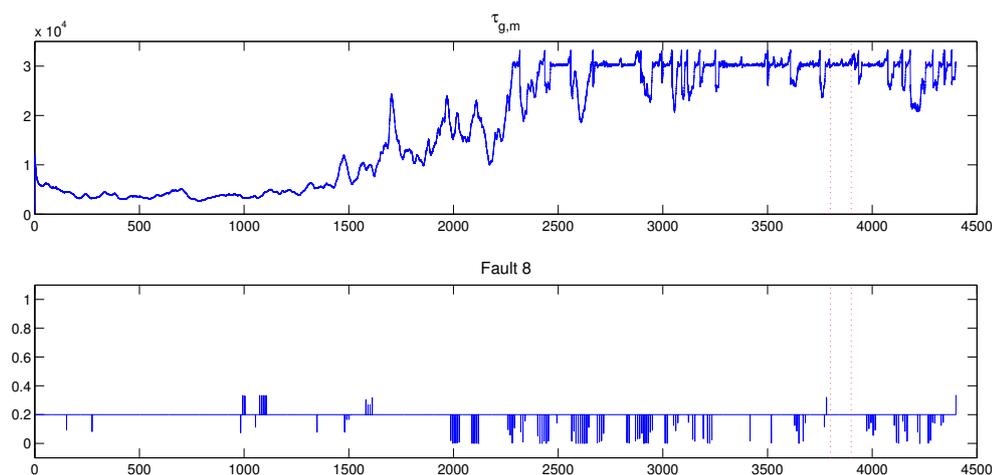


Figura 5.10: Indicação da Falha 8.

A aplicabilidade do algoritmo proposto não está restrito a falhas abruptas. O *benchmark* proposto é composto principalmente por falhas abruptas, e a única falha incipiente presente é a falha  $F_7$ . Contudo, o sistema FDI proposto é capaz de detectar falhas abruptas de pequena magnitude e falhas incipientes. Para ilustrar esse potencial, foi realizada uma simulação especial para a falha  $F_1$  com modificações para que a mesma seja incipiente. Nessa simulação a intensidade da falha aumenta progressivamente entre 1100 segundos e 1160 segundos, em seguida a indicação do sensor  $\beta_{1,m1}$  permanece fixa em  $0.5^\circ$  por 80 segundos e finalmente volta reduzir de intensidade ao longo dos 60 segundos seguintes. A figura 5.12 mostra o comportamento da

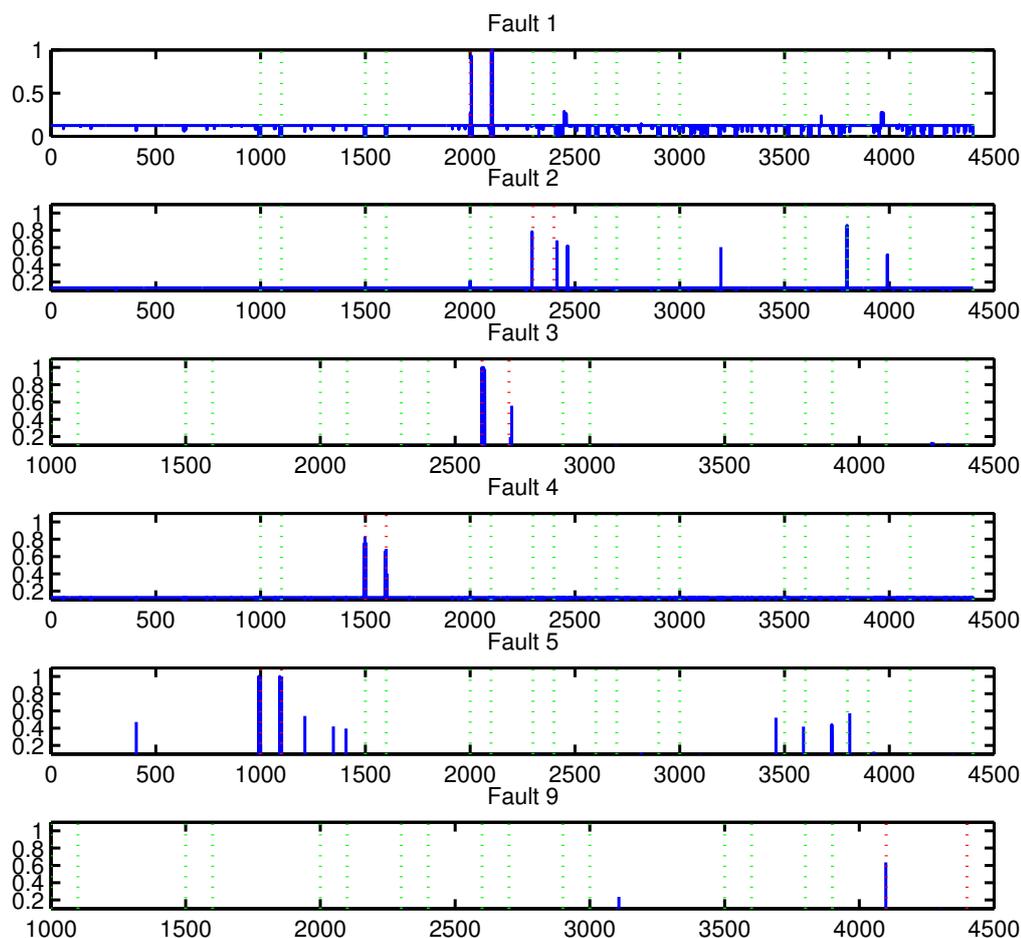


Figura 5.11: Indicação de probabilidade para as falhas detectadas e isoladas.

medida  $\beta_{1,m1}$  e da indicação de probabilidade referente a falha  $F_1$ . A linha tracejada vermelha indica o início da falha. Note que o sistema foi capaz detectar a falha cerca de 20 segundos após o seu início, atraso justificado pelo difícil cenário e pela magnitude semelhante a do ruído de medida.

### 5.3.2 Testes com falhas simultâneas

Foram feitos testes em cenários com ocorrência simultânea de múltiplas falhas para entender a capacidade que o sistema de FDI projetado apresenta para distinção dos cenários de falhas. Nesses testes, foi utilizado o mesmo perfil de velocidade do vento na Figura 5.1. No entanto, a sequência de falhas foi diferente, e segue a ordem da Tabela 5.1. Note que as

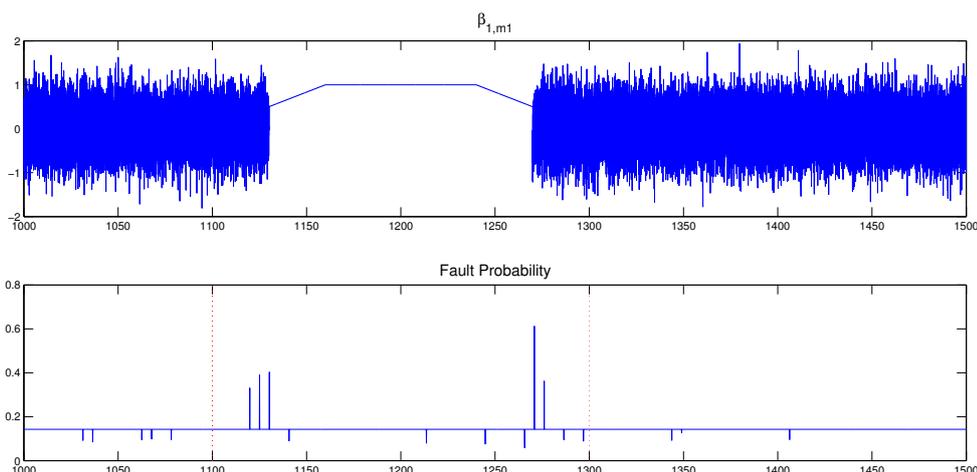


Figura 5.12: Indicação de probabilidade para uma falha incipente de baixa magnitude.

falhas estudadas aqui, são as mesmas dos padrões anteriores, isto é, tem a mesma característica, afetam os mesmos sistemas com a mesma intensidade. No entanto, as falhas neste cenário, quando iniciadas, duram até o fim da simulação. A falha  $F_1$  têm início aos 1500 segundos, a falha  $F_2$  aos 1700 segundos, a falha  $F_3$  aos 1900 segundos, e assim por diante, com cada nova falha se iniciando após 200 segundos. Ou seja, ao termino da simulação, todas as falhas estarão afetando o sistema.

Os resultados indicam maior dificuldade na detecção de falhas simultâneas. As falhas  $F_1$ ,  $F_3$  e  $F_5$  foram detectadas e isoladas com sucesso como mostram as figuras 5.13 a 5.15. As demais não puderam ser detectadas pela amostragem de Gibbs, como pode ser visto nas figuras 5.16 a 5.19.

É compreensível o desempenho inferior para falhas simultâneas, uma vez que a abordagem se baseia em dados e muitos dos sensores falham logo no princípio da simulação. Ainda assim a falha  $F_5$ , por exemplo, pôde ser detectada com diversos sensores já em falha. Esse cenário com diversas falhas ocorrendo simultaneamente não havia sido investigado anteriormente na literatura.

## 5.4 Conclusão

Esta seção mostrou o funcionamento do sistema de FDI proposto nesse trabalho. Os resultados indicaram um bom desempenho, sobretudo para falhas em sensores, com taxa de falsa

Falha #	Descrição	Tipo	Símbolo	Gravidade	Início (s)	Fim (s)
$F_1$	Valor fixo na medida de $\beta_{1,m1}$	Valor Fixo	$\Delta\beta_{1,m1}$	Baixa	1500	4400
$F_2$	Ganho na medida de $\beta_{2,m2}$	Fator de Ganho	$\Delta\beta_{2,m2}$	Baixa	1700	4400
$F_3$	Valor fixo na medida de $\beta_{3,m1}$	Valor Fixo	$\Delta\beta_{3,m1}$	Baixa	1900	4400
$F_4$	Valor fixo na medida de $\omega_{r,m1}$	Valor Fixo	$\Delta\omega_{r,m1}$	Baixa	2100	4400
$F_5$	Ganho nas medidas de $\omega_{r,m2}$ e $\omega_{g,m1}$	Fator de Ganho	$\Delta\omega_{g,m1}$ , $\Delta\omega_{r,m2}$	Baixa	2300	4400
$F_6$	Mudança na dinâmica do atuador de arfagem 2 devido a queda de pressão	Mudança na dinâmica	$\Delta\beta_2$	Alta	2500	4400
$F_7$	Mudança lenta da dinâmica do atuador de arfagem 3 devido a presença de ar no óleo	Mudança na dinâmica	$\Delta\beta_3$	Média	2700	4400
$F_8$	Offset em $\tau_g$	Offset	$\Delta\tau_g$	Média	2900	4400
$F_9$	Mudança na dinâmica do drive train	Mudança na dinâmica	$\Delta\omega_r$ , $\Delta\omega_g$	Média	3100	4400

Tabela 5.1: Configuração de falhas simultâneas.

detecção quase nula. Apesar de algumas falhas não terem sido detectadas e isoladas a princípio o sistema apresentou grandes eficiência na aplicação em um cenário onde o vento representa uma grande dificuldade. Além disso, a proposta têm resultados superiores aos publicados na literatura que se baseiam apenas em dados sem nenhum tipo de modelo.

Este trabalho apresentou também resultados relevantes para cenários de grande dificuldade não considerados na literatura, como a simulação com diversas falhas simultâneas. A metodologia se mostrou ainda capaz de identificar falhas incipientes e de baixa magnitude. Ademais, existem claras possibilidade de obtenção de resultados ainda melhores com o emprego do mesmo *framework* e adotando a metodologia também proposta nesse trabalho para inclusão de sinais artificiais e seleção de sinais representativos.

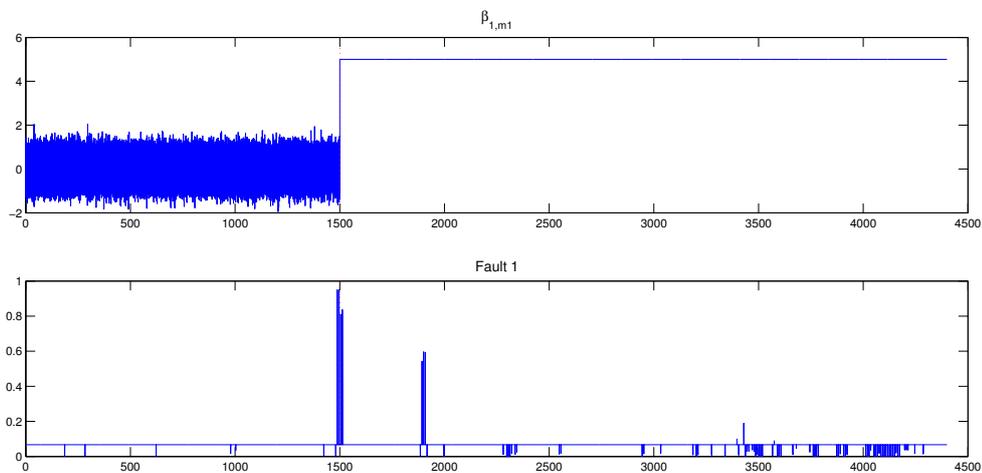


Figura 5.13: Indicação da Falha 1 em teste com falhas simultâneas.

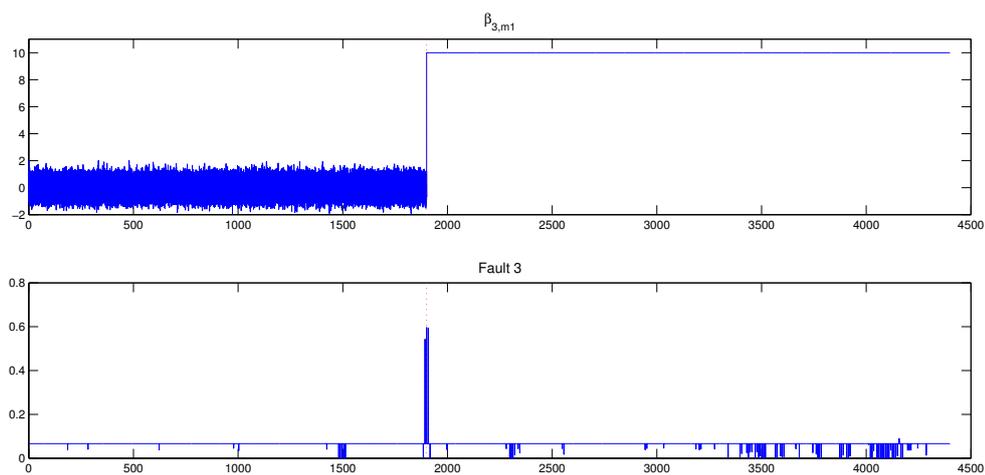


Figura 5.14: Indicação da Falha 3 em teste com falhas simultâneas.

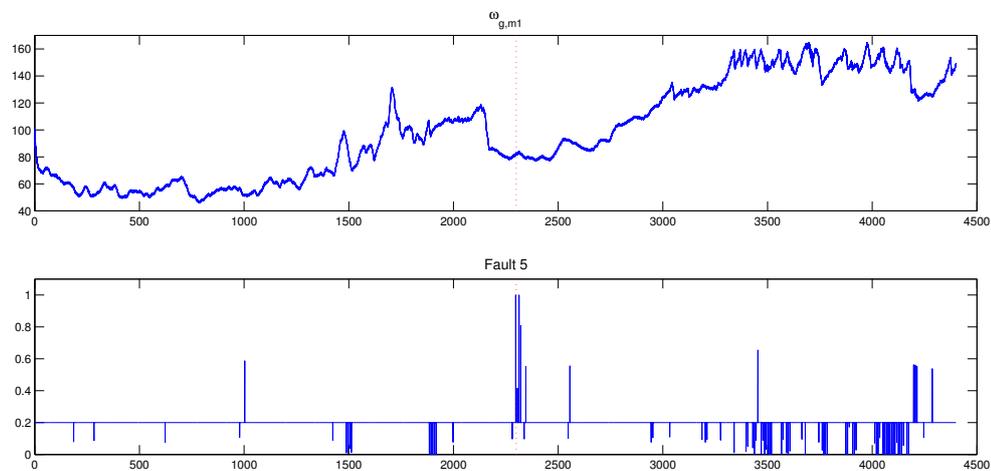


Figura 5.15: Indicação da Falha 5 em teste com falhas simultâneas.

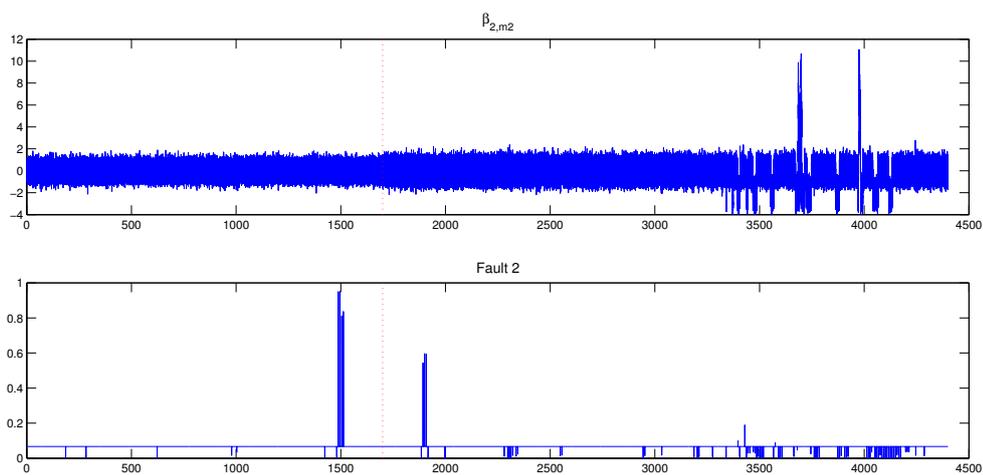


Figura 5.16: Indicação da Falha 2 em teste com falhas simultâneas.

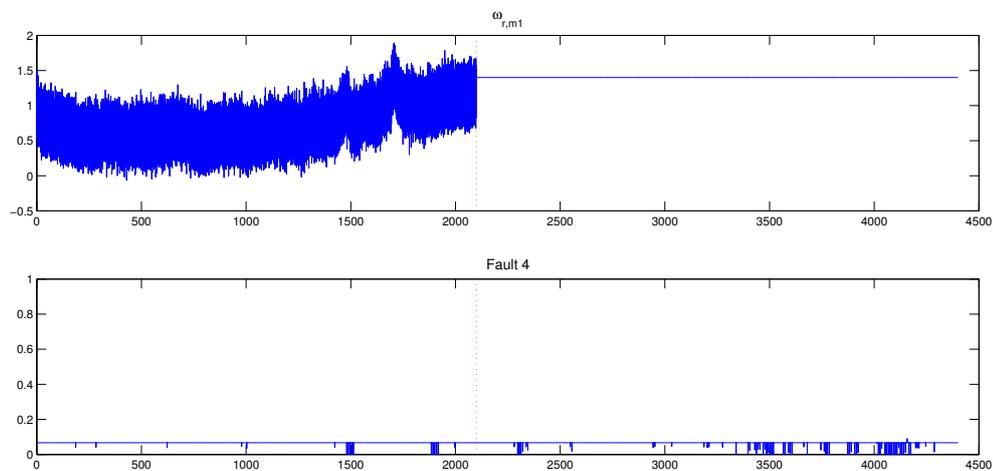


Figura 5.17: Indicação da Falha 4 em teste com falhas simultâneas.

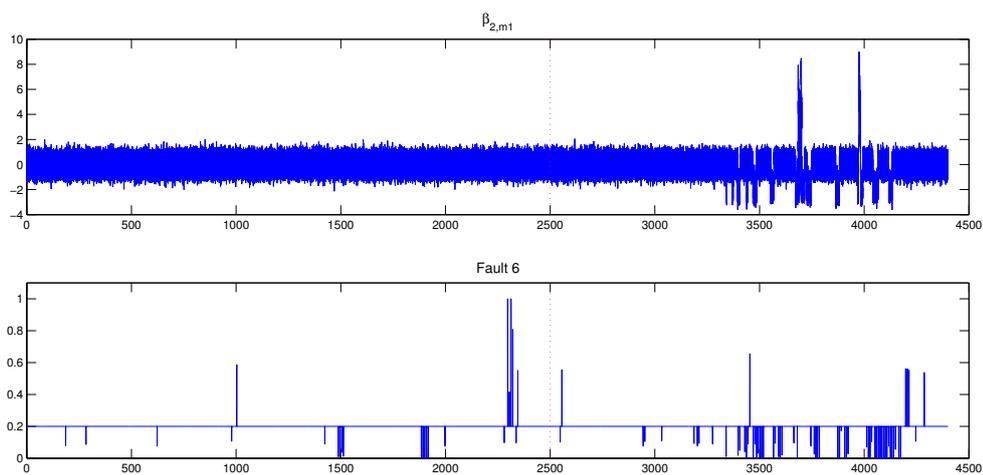


Figura 5.18: Indicação da Falha 6 em teste com falhas simultâneas.

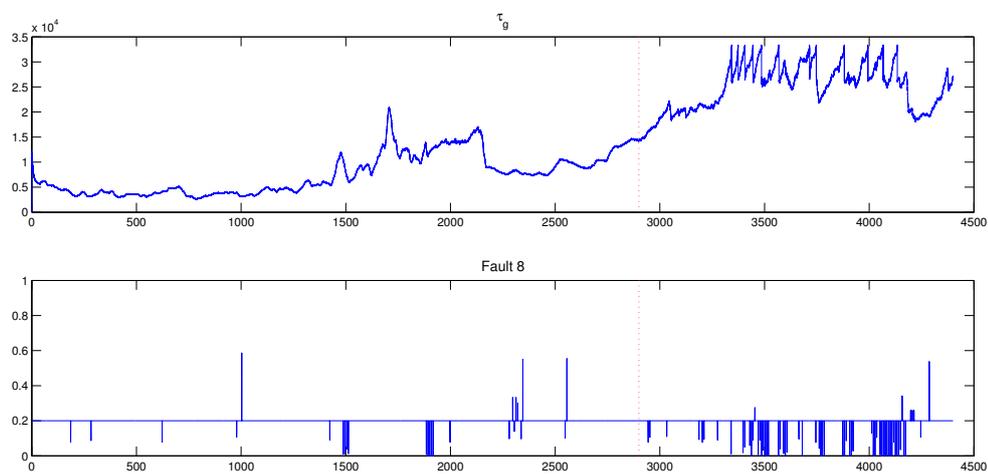


Figura 5.19: Indicação da Falha 8 em teste com falhas simultâneas.

# Capítulo 6

## Conclusões

Neste trabalho foi realizado o desenvolvimento de uma nova metodologia para detecção e isolamento de falhas baseado em dados. A proposta foi aplicada e avaliada em um *benchmark* de turbina eólica, um tipo de sistema que demanda grande confiabilidade e cujo modelo matemático é de difícil representação, ou seja, um ambiente onde estratégias de FDI baseadas em dados são de grande importância e conveniência. Este trabalho apresenta duas principais contribuições.

A primeira contribuição é a metodologia de FDI baseada em dados propriamente dita, apresentada no Capítulo 4. O sistema de FDI é composto por dois módulos: o detector de novidades e a rede *fuzzy*/Bayesiana. O detector de novidades traz uma inovação para detecção de falhas, o emprego da amostragem de Gibbs. Outros trabalhos já utilizaram detecção de novidades e análise de tendências para detectar ocorrência de falhas, mas não se tem notícia da aplicação da amostragem de Gibbs nesse sentido. A rede *fuzzy*/Bayesiana, utilizada para isolamento de falhas, já havia sido utilizadas com esse fim por alguns trabalhos, no entanto, nunca havia sido empregada para um problema complexo como o da turbina eólica, onde diversos sinais de sensores devem ser processados e existe uma grande incerteza associada ao comportamento do vento.

A segunda contribuição, também descrita no Capítulo 4, é a técnica de projeto do sistema FDI. Essa técnica permite diversas variações na seleção de sinais relevantes e nos ajustes da detecção de novidade que podem produzir um sistema de FDI ainda mais eficiente. A mesma metodologia de FDI, poderia ser aplicada com diferentes sinais, que podem resultar de diferentes tipos de processamento, por exemplo, técnicas de análise espectral. Além disso, mostrou-se

uma alternativa para diminuir o grande custo computacional típico de abordagens baseadas em dados, com seleção apenas de sinais mais representativos. O Capítulo 5 mostrou que ajustes no amostrador de Gibbs também podem aumentar a eficiência do sistema de FDI.

O sistema de FDI formulado para o *benchmark* de turbina eólica foi avaliado no Capítulo 5. Os resultados indicam que o sistema é capaz de detectar, sem falsos alarmes, falhas nos sensores, mesmo com ocorrência simultânea, mas que demonstra dificuldade para detectar as demais falhas. No entanto, os resultados obtidos foram satisfatórios, uma vez que a proposta é totalmente baseada em dados. O estado da arte das técnicas de FDI baseada em dados ainda apresenta grande dificuldade em lidar com cenários em que os dados apresentam grande interferência, e as metodologias baseadas em dados propostas por outros autores não foram capazes de detectar todas as falhas sem o uso de modelos identificados. O sistema proposto nesse trabalho apresenta um avanço em relação a essas técnicas, sendo capaz de detectar um número maior de falhas sem o emprego de qualquer tipo de modelo ou resíduo. Além disso melhores resultados pode ser obtidos com o uso de novos sinais artificiais obtidos por técnicas de processamento.

Houveram duas grandes dificuldades encontradas na implementação da proposta. A primeira é a imprevisibilidade do vento e sua capacidade de afetar diversas medições. A segunda é o volume de dados necessário para a implementação desta proposta baseada em dados. A escolha das redes *fuzzy*/Bayesianas se mostrou muito adequada para lidar com as incertezas do vento, mas ainda assim os sinais a serem processados pela amostragem de Gibbs devem ser capazes de fornecer informações precisas sobre as falhas. Nesse contexto, foi de grande importância o emprego da metodologia de produção de sinais artificiais e posterior seleção dos menos correlacionados, pois ao mesmo tempo em que novas informações eram apresentadas ao sistema FDI as informações redundantes eram excluídas aliviando o problema de volume de dados.

## 6.1 Proposta para Trabalhos Futuros

Nesta seção serão apresentadas alguns potenciais caminhos a serem desenvolvidos futuramente por essa pesquisa. Os trabalhos futuros propostos se dividem em dois grupos. O primeiro diz respeito a melhorias no sistema de FDI proposto, baseado essencialmente na inclusão de novos sinais. O segundo propõe uma sequência natural desse trabalho com a formulação de

um sistema de FTC. Uma compreensão melhor das técnicas existentes de FTC pode ser obtida por meio da leitura do Apêndice B.

### 6.1.1 Adição de novos sinais representativos

Como exibido nos resultados do Capítulo 5, nem todas as falhas investigadas foram detectadas com sucesso. Em abordagens baseadas em dados, como a proposta aqui, a quantidade e diversidade de informações são fatores cruciais para a melhora do desempenho da detecção e do isolamento. Uma alternativa de desenvolvimento futuro do sistema de FDI construído nesse trabalho é a inclusão de novos sinais com diferentes características. Esses sinais não seriam obtidos a partir de novos sensores, mas sim a partir do processamento dos sinais de medidas de sensores já existentes, no processo de expansão do banco de sinais.

Os sinais de sensores desse sistema são ricos em ruídos e contém caráter transitório predominante devido a volatilidade do comportamento do vento. Com certa frequência algumas técnicas de análise espectral, com extração de características de tempo-frequência, são empregadas para detecção de falhas. Dois exemplos notáveis dessas técnicas são as transformadas de Wavelet e a HHT, ambas aplicadas frequentemente na extração de características de falhas a partir de sinais de vibração em máquinas elétricas, cuja análise temporal apresenta resultados limitados.

### 6.1.2 Um sistema de FTC data-driven baseado em dados

Uma proposta de trabalho futuro seria a aplicação de técnicas baseadas em dados para a formulação de um sistema de FTC. Poucas pesquisas tratam desse forma o problema, onde de prevalecem, de forma quase absoluta as técnicas baseadas em modelo.

A maioria dos métodos de CR vistos na subseção anterior exigem um modelo do sistema faltoso para que se obtenha a nova estrutura de controle. Em algumas circunstâncias, a obtenção desse modelo se torna complicada, especialmente no caso de faltas multiplicativas, como mostrado em [54]. Diante dessa dificuldade, foram desenvolvidos diversos trabalhos com o uso dos mesmos métodos clássicos de FTC baseados em modelos identificados. No entanto, esse problema motivou o surgimento de sistemas de CR contruídos com abordagens de controle adaptativo, por exemplo o de Tao et al. [55] que propôs uma técnica de reprojeto do controlador adaptativa para falhas em atuadores. Dong [54] propôs um *framework* de FTC baseado

em dados que unifica o uso de modelos identificados, com auxílio de subespaços, e controle preditivo. Técnicas baseadas em subespaço são empregadas com frequência na identificação paramétrica de observadores de diagnóstico [56].

Bazanella et al. [57], apresenta uma técnica de projeto e sintonia de controladores robustos  $H_2$  de forma iterativa baseada em dados, onde os dados do processo são utilizados na minimização de funções objetivas, relacionadas a metas de controle.

A mesma técnica proposta por [57] pode ser usado, em pesquisas futuras, para a abordagem de FTC baseada em dados aqui proposta. Nesta abordagem, poderiam ser usados atuadores e sensores virtuais, que com as abordagens atuais são projetados com base em modelos da planta faltosa, cujos parâmetros no entanto seriam obtidos por meio de técnicas de otimização iterativa como em [57].

# Apêndice A

## Supervisão, Detecção e Diagnóstico de Falhas: Perspectivas Históricas

O aumento contínuo da complexidade e autonomia dos sistemas e processos dinâmicos traz consigo uma forte demanda por sistemas de alta performance, produtos de maior qualidade, e com custos otimizados. O desenvolvimento de sistemas que atendam a todos esses requisitos exige, entre outras coisas, garantias de segurança e confiabilidade. Nesse contexto, atividades de supervisão de sistemas que permitam a detecção e diagnóstico antecipados de falhas é imprescindível.

A supervisão de processos e sistemas consiste em monitorar as condições e estados do sistema visando sinalizar a ocorrência de estados indesejados ou proibidos, e reagindo de forma a evitar a ocorrência de acidentes e danos ao sistema ou aos agentes que interagem com este, dando origem a faltas. Desta forma, a supervisão de processos se trata do monitoramento com o objetivo de evitar a ocorrência de falhas. Um sistema de supervisão analisa continuamente os sinais obtidos no processo e geralmente utiliza um sistema FDI (do inglês, *Fault Detection and Isolation*) capaz de identificar e localizar a ocorrência de falhas através das informações obtidas com análise dos sinais.

Devido à crescente importância dos temas supramencionados, diversos artigos abordam com profundidade assuntos inerentes a sistemas de supervisão e técnicas de FDI. Cita-se como exemplo: [58–67].

Além disso, o desenvolvimento teórico deste campo e suas aplicações foram estabelecidos historicamente através de diversas contribuições publicadas em congressos e simpósios,

entre os quais pode-se salientar a importância da série de simpósios do IFAC (*International Federation of Automatic Control*) denominados SAFEPROCESS (*Fault Detection, Supervision and Safety of Technical Process*).

Como já mencionado, a confiabilidade é um fator chave também para a energia eólica. Os custos com operação e manutenção geralmente oscilam entre 10% e 20% do custo total da energia [68] e o estado da arte para determinação da estratégia de manutenção para turbinas eólicas é a manutenção centrada em confiabilidade, que consiste na manutenção preventiva baseada no desempenho e monitoramento de sinais e parâmetros relativos ao processo. Essa função é geralmente desempenhada por sistemas de detecção e diagnóstico de falhas [68].

## A.1 Definições e Terminologia

Nessa seção serão fornecidas algumas definições e terminologias relevantes no contexto de FDI. Essas definições estão em conformidade nas fornecidas pelo Comitê Técnico do SAFEPROCESS, e nos livros [58] e [67]:

- **Supervisão:** monitoramento do funcionamento de um sistema ou execução de um processo com o objetivo de manter a operação frente a falhas.
- **Falha:** Pode-se definir falha como uma anomalia no sistema ou no processo. Tecnicamente pode ser detectada quando alguma variável ou parâmetro observado está fora da região aceitável de operação. Na prática a falta é verificada através dos sintomas, como sobreaquecimento, desaceleração, ou simplesmente o aumento estatístico de erros no processo. Apesar disso, uma falha não afeta necessariamente o funcionamento normal de um sistema. Por essa razão as falhas são difíceis de se detectar. A interferência das falhas no funcionamento normal do sistema pode dar origem a faltas ou a um mau funcionamento.
- **Falta:** pode ser definida como uma interrupção permanente da capacidade de execução de determinada função. A falta é um evento que tem origem em uma ou mais falhas.
- **Mau funcionamento:** pode ser definido como uma interrupção temporária da capacidade de um sistema de executar uma determinada função requerida. Semelhante a falta, o mau funcionamento é um evento que tem origem em uma ou mais falhas.

- **Distúrbio:** entrada desconhecida e não-controlada, geralmente não-determinística que age no sistema.
- **Perturbação:** entrada que age no sistema, gerando mudanças de estados. Pode ou não ser controlada.
- **Erro:** desvio entre um valor obtido e um outro valor de referência, tomado como correto.
- **Incertezas paramétricas:** erros em parâmetros componentes do modelo matemático que representa um sistema real.
- **Resíduo:** erro calculado com o objetivo de indicar a ocorrência de falhas. É a diferença entre valores obtidos através de medidas e o obtido por modelos matemáticos.
- **Detecção de falhas:** determinação das falhas presentes em um sistema e do instante em que ela ocorreu. Consiste em procedimentos que tem por finalidade gerar sintomas.
- **Sintomas:** mudança observável na normalidade do comportamento, inferida através de uma informação mensurável ou não. O sintoma pode ser analítico, obtido através de uma informação quantificável (é simplesmente um valor/sinal), ou pode ser heurístico, que utiliza conhecimento humano e empírico (é uma sensação associada a quantificadores linguísticos).
- **Comportamento do sistema:** conjunto de todas as combinações e sequências de pares entradas/saídas que um sistema pode apresentar.
- **Isolamento de falhas:** classificação e localização das falhas.
- **Análise ou identificação de falhas:** etapa que sucede o isolamento da falha, consiste na determinação do tipo, intensidade e causas da falha.
- **Diagnóstico de falhas:** identificação qualitativa e quantitativa de uma falha, determinando o tipo, intensidade, localização e momento da ocorrência. Tem início após a detecção da falha e consiste em duas etapas básicas, o isolamento e a identificação da falha. Tem por finalidade associar os sintomas gerados na detecção a elementos do conjunto de faltas. Um sistema de diagnóstico inclui, geralmente, as etapas de detecção e isolamento, sendo denominado sistema de detecção e isolamento de falhas (FDI).

- **Avaliação de falhas:** classificar a falha quanto a intensidade do dano que ela causou ao sistema (isso não têm necessariamente relação com a magnitude da falha propriamente dita).
- **Gerenciamento de falhas:** ações tomadas após o diagnóstico de falhas. É um processo decisório que deve levar em conta os resultados da avaliação de falhas. Muitas vezes, é desejável que essas ações sejam automáticas, assim como a tomada de decisões, no entanto, ambas podem ser feitas por operadores.
- **Tolerância a falhas:** um sistema é dito tolerante a falhas se ele é capaz de compensar as faltas de maneira a evitar falhas no sistema. Geralmente sistemas tolerantes a falhas são sistemas que possuem, além das propriedades de confiabilidade (*reliability*) e segurança (*safety*), mecanismos de redundância. Essa redundância pode ser física, utilizando-se diversos sensores para medir a mesma variável. A redundância também pode ser analítica e utilizar simultaneamente sensores e modelos do sistema.

## A.2 Propriedades relativas ao funcionamento dos sistemas

A supervisão e as técnicas de FDI e FTC têm como objetivo fazer com que o funcionamento do sistemas e processos técnicos apresentem determinadas propriedades como: confiabilidade, disponibilidade, manutenibilidade, integridade de segurança. As definições abaixo são baseadas nas definições aceitas pelo SAFEPROCESS - presentes no dicionário RAM (*Reliability, Availability and Maintainability*) - e no livro [58]:

- **Confiabilidade:** habilidade de realizar uma função requerida por um certo período de tempo. A confiabilidade pode ser quantificada através do MTTF (*Mean Time To Failure*), tempo médio em que o sistema é capaz de realizar todas as suas funções normalmente, que pode ser calculado por:

$$MTTF = \frac{1}{\lambda}, \quad (\text{A.1})$$

onde  $\lambda$  é a taxa de faltas por unidade de tempo. Nota-se que a confiabilidade é depreciada com a ocorrência de faltas e mau funcionamentos.

- **Manutenabilidade:** é a qualidade dos mecanismos através dos quais o sistema pode sofrer manutenção. A manutenibilidade pode ser quantificada através do MTTR (*Mean*

*Time To Repair*), tempo médio que o sistema leva pra restabelecer a normalidade de suas funções, que é dado por:

$$MTTR = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{i=1}^N T_{Ri}, \quad (\text{A.2})$$

sendo  $T_{Ri}$  é o tempo de reparo da  $i$ -ésima falha. Esse tempo pode ser afetado pelo tempo levado no diagnóstico e pelo tempo levado na ação de gerenciamento propriamente dita.

- **Disponibilidade:** probabilidade de um sistema estar operando satisfatoriamente e efetivamente em um período de tempo. A disponibilidade pode ser quantificada, através do MTTF e MTTR por:

$$A = \frac{MTTF}{MTTF + MTTR}. \quad (\text{A.3})$$

Nota-se que a disponibilidade é afetada não apenas pela ocorrência de falhas e mau funcionamentos, mas também pelo tempo que esses demoram para serem resolvidos e a normalidade restabelecida, que deve ser pequeno em relação ao MTTF para que a disponibilidade seja alta.

- **Integridade de segurança:** é a probabilidade de um sistema realizar funções de segurança satisfatoriamente e sob todas as condições em um período de tempo. Mecanismos de tolerância a falhas são utilizados para garantir essa propriedade.

### A.3 Tipologia das falhas

As falhas podem ser enquadradas em diferentes categorias de acordo com a região de ocorrência em um sistema, a forma que ela afeta o seu funcionamento e com o seu comportamento temporal.

As falhas podem ser classificadas como abruptas ou incipientes de acordo com a forma temporal que ela surge no sistema, ou seja, o seu comportamento transitório:

- **Falha abrupta:** resultante em desvios comportamentais aparentemente instantâneos, isto é, grandes desvios ocorridos em um curto espaço de tempo.
- **Falha incipiente:** resultante em desvios comportamentais que demonstram uma progressão com o tempo, sendo mais difíceis de ser detectadas e tomando um tempo maior desta tarefa.

Ainda a respeito do comportamento temporal da falha, ela pode ser classificada como permanente, temporária ou intermitente:

- **Falha permanente:** atua permanentemente no sistema ou processo até ser realizada uma ação de reparo. Geralmente é originada em um defeito físico.
- **Falha temporária:** resulta em desvios comportamentais temporários, com o sistema retornando a normalidade espontaneamente após um certo tempo.
- **Falha intermitente:** dura um intervalo de tempo limitado, no entanto afeta o sistema frequentemente.

As falhas podem ainda afetar diferentes partes do sistema e dessa forma serem classificadas como:

- **Falha no sensor:** modifica o comportamento normal de um componente de medida do sistema.
- **Falha no atuador:** modifica o comportamento normal de um dispositivo de manipulação do sistema.
- **Falha na planta:** modifica o comportamento dinâmico da planta.

Finalmente as falhas podem ser classificadas de acordo com a forma que ela influencia no comportamento do sistema:

- **Falha aditiva:** influencia o comportamento de uma variável do processo através da adição do efeito da falha sobre esta variável.
- **Falha multiplicativa:** influencia o comportamento de uma variável do processo através da multiplicação da variável pelo efeito da falta.

## A.4 Avaliação de Sistemas de FDI

O projeto de sistemas de diagnóstico de falhas, historicamente, enfrenta o *trade-off* entre robustez e sensibilidade. Naturalmente, espera-se de um sistema dessa natureza pequenos números de falsas detecções e altos números de detecções corretas, no entanto, para que se

detecte mais falhas o sistema deve se tornar mais sensível o que conseqüentemente aumenta a frequência de falsas detecções. Portanto, para avaliar os sistemas de FDI são usadas essas duas importantes métricas: a taxa de alarmes falsos (FAR) e a taxa de detecção de falhas (FDR).

Considere que o sistema de FDI produza como saída uma função de avaliação da ocorrência de falha  $J$ , através da qual a falha é indicada pelo sistema se o valor dessa função superar uma avaliação limiar (*threshold*),  $J_{th}$ , ou seja, se  $J > J_{th}$ . Considere, ainda, o vetor de falhas  $f$ , tal que  $f = 0$  signifique a ausência de qualquer falha. Ding [60] define FAR e FDR, sob o ponto de vista estatístico, da seguinte forma:

**Definição A.1** *A probabilidade FAR, denominada taxa de falso alarme, é determinada, sob o ponto de vista estatístico, por:*

$$FAR = \text{prob}(J > J_{th} | f = 0) \quad (\text{A.4})$$

**Definição A.2** *A probabilidade FDR, denominada taxa de detecção de falhas, é determinada, sob o ponto de vista estatístico, por:*

$$FDR = \text{prob}(J > J_{th} | f \neq 0) \quad (\text{A.5})$$

De forma geral, um sistema de FDI consiste em duas etapas principais: a detecção de falhas, muitas vezes relacionada a um processo de geração de resíduos e a associação dos mesmos a "sintomas" de falhas, e o isolamento que deve avaliar os sintomas e associá-los a cenários de falhas.

## A.5 Revisão de Técnicas de Detecção de Falhas

As técnicas de detecção de falhas podem ser divididas em dois grandes grupos:

- **Técnicas baseadas em modelo:** utilizam necessariamente um modelo explícito do processo, esse modelo pode ser obtido diretamente através dos princípios da física ou através de alguma técnica de identificação;
- **Técnicas baseadas em dados:** utilizam apenas dados sobre o processo, sem nenhum tipo de modelo sobre a dinâmica do mesmo;

Uma ideia geral a respeito das diferentes técnicas de detecção podem ser vista em [61–63] e mais recentemente em [69, 70]. A figura A.1 traz uma visão geral dos diversos métodos de detecção existentes.

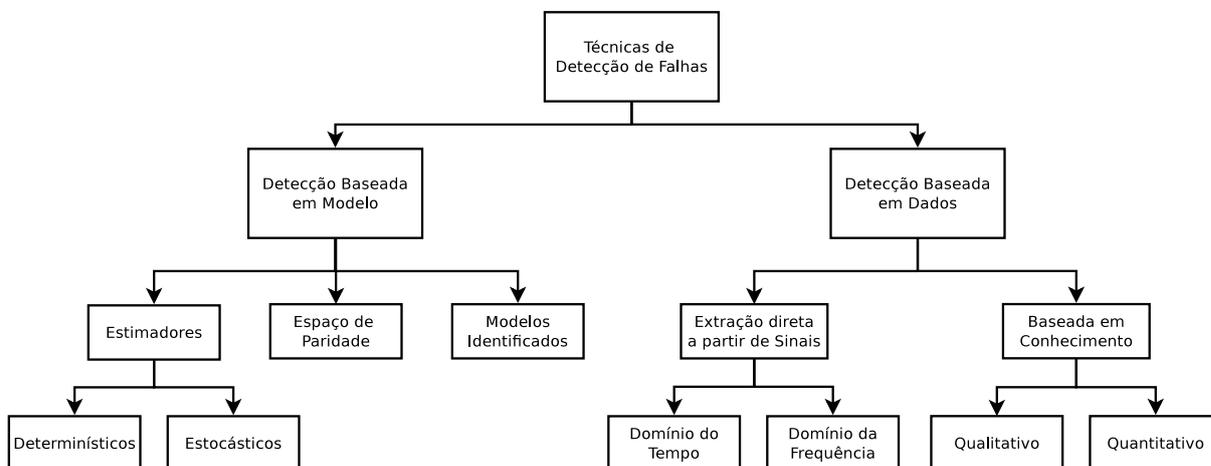


Figura A.1: Classificação das técnicas de detecção de falhas.

### A.5.1 Técnicas de Detecção de Falhas Baseadas em Modelo

A ideia geral por trás da detecção baseada em modelo do processo está baseada na comparação de sinais obtidos no processo em tempo real com sinais obtidos através de redundância, seja ela física ou analítica. Desta comparação se originam os sinais de resíduos, cuja avaliação deve determinar a ocorrência (ou não) da falha. Se não houver resíduo, o sistema deve indicar ausência de falhas, caso contrário, o resíduo deve ser avaliado, através de técnicas de processamento de sinais e extração de características, para que se determine a ausência ou ocorrência de falha. Desta forma, a detecção de falhas baseada em modelos constitui-se de dois elementos principais, o gerador de resíduos e o avaliador de resíduos.

A tarefa fundamental das técnicas de FDI baseadas em modelo é a geração de resíduos independentemente de perturbações e ruídos. A partir disso, Ding [60] classifica as técnicas de detecção de falhas baseadas em modelos em três grupos:

- métodos baseados em estimadores;
- métodos com espaço de paridade;
- métodos baseados em modelos identificados.

### A.5.1.1 Métodos Baseados em Estimadores

As técnicas baseadas em estimadores consistem em obter redundância analítica para os sinais do processo, substituindo o modelo do processo por estimadores/reconstrutores capazes de estimar de forma confiável as saídas ou estados do processo.

Em geral, esses estimadores podem ser determinísticos, os observadores de estados, ou estocásticos, baseados em Filtros de Kalman.

Considere o sistema (A.6):

$$\begin{aligned}\dot{x} &= f(x, u) \\ y &= h(x, u)\end{aligned}\tag{A.6}$$

sendo  $u \in \mathbb{R}^p$ ,  $x \in \mathbb{R}^n$ ,  $y \in \mathbb{R}^m$  são, respectivamente, os vetores de entradas, estados e saídas,  $f(x, u)$  e  $h(x, u)$  são funções continuamente diferenciáveis. O sistema (A.7) é um observador gerador de resíduos, também denominado observador de diagnóstico, para (A.6):

$$\begin{aligned}\dot{\hat{x}} &= \Phi(\hat{x}, u) \\ r &= \phi(\hat{x}, u, y)\end{aligned}\tag{A.7}$$

onde  $r$  é o vetor de resíduos [71].

Para o caso mais simples de sistemas LIT abaixo:

$$\begin{aligned}\dot{x} &= Ax + Bu \\ y &= Cx + Du\end{aligned}\tag{A.8}$$

onde o par  $(A, C)$  é detectável, pode-se simplesmente expressar o observador da forma:

$$\begin{aligned}\dot{\hat{x}} &= A\hat{x} + Bu + L(y - C\hat{x} - Du) \\ r &= y - C\hat{x} - Du.\end{aligned}\tag{A.9}$$

Desta forma, o projeto de um observador para detecção de falhas se resume à determinação do ganho  $L$ , para sistemas LIT, ou das funções  $\Phi(\hat{x}, u)$  e  $\phi(\hat{x}, u, y)$  para sistemas não lineares, tais que  $r$  convirja para zero na ausência de falhas.

Diversas soluções já foram apresentadas nesse contexto, dentre as quais podemos citar com aplicações recentes: o observador de Luenberger [72], observadores  $H_\infty$  [73], observadores PI [74], observadores PMI [75], observadores PD [76] observadores adaptativos [77], observadores por modos deslizantes [78] e observadores descritores [79].

Outro tipo de estimador de estados, também muito utilizado, são os baseados em filtros de Kalman. Considere o sistema discreto abaixo:

$$\begin{aligned}x(k+1) &= Ax(k) + Bu(k) + \omega(k) \\y(k) &= Cx(k) + Du(k) + v(k),\end{aligned}\tag{A.10}$$

onde os sinais  $\omega(k)$  e  $v(k)$  podem ser modeladas como variáveis aleatórias de distribuição normal que correspondem a ruídos no processo e na medição com média nula e desvios padrões de  $Q$  e  $R$  (aqui modeladas como sendo matrizes constantes), respectivamente, ou seja:

$$\omega(k) = N(0, Q)\tag{A.11}$$

$$v(k) = N(0, R)\tag{A.12}$$

e cuja dinâmica, expressa pelas matrizes  $A$ ,  $B$ ,  $C$  e  $D$ , é conhecida,  $u(k)$  é a entrada que é conhecida,  $y(k)$  a saída conhecida, e  $x(k)$  é o estado cuja estimativa se deseja obter.

O Filtro de Kalman é um algoritmo capaz de estimar os estados  $x(k+1)$  para um sistema como o descrito acima. Esse filtro pode ser caracterizado genericamente como o sistema capaz de fornecer a estimativa  $\bar{x}(k+1)$ , através da equação abaixo:

$$\bar{x}(k+1) = E[x(k+1)|y(0), y(1), \dots, y(k)]\tag{A.13}$$

De forma semelhante ao do observador de estados, o estimador com filtro de Kalman, é utilizado no contexto de detecção de falhas através da obtenção do vetor de resíduos  $r$  dado por:

$$r(k) = \bar{x}(k) - x(k).\tag{A.14}$$

Desde as primeiras aplicações do filtro de Kalman em sistemas de FDI, por Mehra e Peschon em 1971, com metodologia válida apenas para sistemas LIT, surgiram diversas modificações e aplicações destes estimadores para detecção de falhas. Algumas variações do filtro de Kalman com aplicações recentes e notáveis são: filtro de Kalman estendido (EKF) [80], que podem ser empregados para detecções em sistemas não lineares; filtros de Kalman *unscented* (UKF) [81] e filtros de Kalman adaptativos [82], que apresentam alterações que permitem mais precisão para FDI; os filtros de Kalman aumentados [83] que permitem diagnóstico e estimação de estados simultânea.

### A.5.1.2 Métodos com Espaço de Paridade

A característica fundamental de abordagens com espaço de paridade é o emprego de modelos no espaço de estados para geração de resíduos. Apesar desse tipo de modelo já ser utilizados nas abordagens com observadores de estados vistas anteriormente, existe uma diferença substancial aqui: esses modelos são utilizados para gerar relações de paridades (ou consistência) para verificar a consistência entre as saídas do processo e do modelo, e não observadores de estados cuja a saída são sempre estados estimados.

Por ser flexível, o espaço de paridade permite diversas composições de geradores de resíduos. De forma geral, para um sistema como o expresso em (A.10), onde o par  $(A, C)$  é observável, pode-se obter a seguinte relação de paridade:

$$y_s(k) = H_o x(k-s)x(k-s) + H_u u_s(k) \quad (\text{A.15})$$

onde  $H_o$  e  $H_u$  são matrizes formadas a partir de  $A$ ,  $B$ ,  $C$  e  $D$ . Pode-se construir um gerador de resíduos baseado em (A.15) tal que:

$$r(k) = v_s(y_s(k) - H_u u(k)) \quad (\text{A.16})$$

onde os vetores  $v_s$  são denominados vetores de paridade que compõem o espaço de paridade  $P_s$ :

$$P_s = \{v_s | v_s H_o = 0\}. \quad (\text{A.17})$$

### A.5.1.3 Métodos Baseados em Modelos Identificados

Técnicas de identificação de modelos ou parâmetros vêm sendo utilizados por muito tempo em qualquer tipo de ciência que requeira conhecimento sobre modelos matemáticos do processo. Com as técnicas já bem desenvolvidas de identificação de sistemas pode-se com facilidade obter um parâmetro ou mesmo um modelo completo que aproxime satisfatoriamente toda sorte de processos. As técnicas de detecção de falhas baseadas em modelos identificados consistem em produzir resíduos a partir da comparação de variáveis do processo obtidas a partir de medições com as mesmas obtidas computacionalmente através do modelo identificado. O livro [66] apresenta uma ideia geral das técnicas de identificação e aborda profundamente suas aplicações no contexto de FDI.

Diversas técnicas de identificação podem ser utilizadas no contexto de FDI. Algumas técnicas de identificação com exemplos recentes de aplicações para sistemas de FDI são: es-

timação paramétrica com filtro de Kalman [84], identificação *fuzzy* [85], identificação neural [86], e identificação neurofuzzy (ANFIS) [87].

## **A.5.2 Técnicas de Detecção de Falhas Baseadas em Dados**

As técnicas de detecção de falhas baseadas se fundamentam na extração de informações a respeito da ocorrência das falhas através do uso de medidas e informações do processo, sem nenhum uso de modelos matemáticos para descrever a dinâmica do processo. Podem ser usados, no entanto, modelos para o tratamento de dados, assim como abordagens baseadas em geradores de resíduos baseados em dados. A essência da detecção baseada em dados está na extração de características, que são associados a sintomas de falhas.

Os sintomas podem ser extraídos diretamente dos sinais, a partir de análise em diferentes domínios, ou podem ser extraídos a partir de uma avaliação qualitativa ou quantitativa, baseada na história de dados do processo.

### **A.5.2.1 Abordagens baseadas em extração direta a partir de sinais:**

esse tipo de extração obtém os sintomas a partir de características latentes dos sinais medidos, e dispensa o uso de conhecimento prévio acerca do processo. Essas características podem ser visualizadas em análises no domínio do tempo, domínio da frequência, ou tempo-frequência.

Em análises no domínio do tempo são extraídas características mais proeminentes do sinal como médias, tendências, valor RMS, taxa de variação, entre outras.

As análises no domínio da frequência utilizam ferramentas de análise espectral (como transformada de Fourier discreta e transformada rápida de Fourier) para que se possam extrair características que não são observadas no domínio da frequência.

Em determinadas situações os sinais apresentam grande variação temporal do espectro de frequência, como sistemas em regime transitório. Nestes casos, pode-se lançar mão de técnicas capazes de decompor os sinais medidos em componentes tempo-frequência para que se retire características relativas a falhas. Existem diversas ferramentas matemáticas dessa natureza, entre as quais pode-se citar algumas das principais com aplicações recentes em detecção de falhas: as transformadas Wavelet [88], transformada de Fourier de curto termo (STFT) [89], transformada rápida de Fourier (FFT) [90], a transformada de Hilbert-Huang

(HHT) [91] e distribuição de Wigner-Ville (WVD) [92]. Essas aplicações se estendem a diversos tipos de sistemas, como linhas de transmissão, veículos aéreos não tripulados e motores, no entanto, existe uma forte concentração dessas técnicas em análise de falhas por meio de sinais de vibrações em sistemas mecânicos.

#### **A.5.2.2 Abordagens baseadas em conhecimento:**

essas técnicas exigem um grande volume de dados sobre o processo compondo uma base de conhecimento que é utilizada para realizar a extração de características relativas à ocorrência de falhas. As técnicas baseadas em conhecimentos podem ser classificadas entre as que realizam análise qualitativa e as que realizam análise quantitativa.

A técnica de detecção de falhas qualitativa baseada em conhecimento mais antiga e mais conhecida é a que utiliza sistemas especialistas. Nestas técnicas um sistema de inteligência artificial é alimentado com uma série de regras obtidas a partir da experiência humana. Um poderoso tipo de sistema especialista, com larga aplicação em detecção de falhas, são os sistemas com lógica *fuzzy*, onde são formuladas uma série de regras SE-ENTÃO para que se detecte diferentes cenários de falhas. As abordagens com sistemas especialistas apresentam baixo custo e são de simples implementação, no entanto, para cada processo haverá uma solução diferente e dedicada. Buscando generalizar esses sistemas, formulou-se um sistema especialista universal no trabalho de Kodavade e Apte [93].

Outra importante modalidade de detecção de falhas qualitativa baseada em conhecimento é análise qualitativa de tendências (QTA), na qual a característica a ser extraída é uma abstração da informação sobre a tendência [63]. Essa alternativa apresenta importantes vantagens sobre as técnicas baseadas em modelo, uma vez que o uso de observadores ou estimadores não distingue com precisão fenômenos transitórios de falhas. Muitos trabalhos utilizam ferramentas de processamento de sinais, como transformada de Fourier ou Wavelet, para facilitar a captura das tendências.

Uma técnica de QTA aplicada para detecção de falhas é a detecção de novidades, na qual a falha é caracterizada como uma novidade, ou seja, um desvio comportamental do sistema [64]. Essa técnica consiste em extrair padrões anômalos de uma sequência de observações de uma variável mensurável do sistema (uma série temporal). Essa sequência temporal é analisada por um detector de novidades que dispõe de uma janela deslizante. Para cada deslizamento deve-

se construir um modelo para a ocorrência de novidades, que deve indicar a probabilidade de ocorrência de violação para cada uma das observações.

As abordagens com análise quantitativa propõem tratar o problema de detecção de falhas como um problema de reconhecimento de padrões. Nesse caso, as características a serem extraídas são informações quantificáveis. As técnicas de análise quantitativas podem ser estatísticas ou não estatísticas.

Dentre as abordagens estatísticas figuram principalmente o PCA (Análise de Componentes Principais), o ICA (Análise de Componentes Independentes) e o SVM (Máquina de Vetores de Suporte), além das diversas derivações desses métodos que já foram desenvolvidas nos últimos anos.

O PCA é a técnica estatística mais popular e antiga. Ela consiste em projetar um grande volume de dados do processo em um conjunto com menor dimensão de componentes principais [56]. Considere a matriz  $X$  abaixo, formada por  $N$  amostras de dados contendo leituras de  $m$  variáveis do processo:

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N1} & x_{N2} & \dots & x_{Nm} \end{bmatrix}, \quad (\text{A.18})$$

as informações significativas a respeito da variabilidade desses dados são extraídas com a decomposição em valores singulares (SVD) da matriz de covariância  $\Phi$  de  $X$ :

$$\Phi = P\Sigma P^T, \quad (\text{A.19})$$

tal que  $\Sigma = \text{diag}(\lambda_1, \dots, \lambda_m)$  e  $P^T$  é a matriz transposta a  $P$ , uma matriz unitária, onde  $\lambda_1 \geq \dots \geq \lambda_m \geq 0$  são os autovalores de  $\Phi$ . Tendo-se interesse em  $p$  componentes principais, pode-se decompor  $\Sigma$  e  $P$  da seguinte forma:

$$\Sigma = \begin{bmatrix} \Sigma_{pc} & 0 \\ 0 & \Sigma_{res} \end{bmatrix} \quad (\text{A.20})$$

$$P = \begin{bmatrix} P_{pc} & P_{res} \end{bmatrix}, \quad (\text{A.21})$$

tais que  $\Sigma_{pc} = \text{diag}(\lambda_1, \dots, \lambda_p)$  e  $\Sigma_{res} = \text{diag}(\lambda_{p+1}, \dots, \lambda_m)$ . Desta forma, qualquer vetor de observações  $x$  pode ser projetado em dois subespaços ortogonais ( $x = \hat{x} + \tilde{x}$ ):

$$\hat{x} = P_{pc} P_{pc}^T x \quad (\text{A.22})$$

$$\tilde{x} = P_{res} P_{res}^T x. \quad (\text{A.23})$$

Peng et al. [94] trazem uma aplicação recente de PCA para FDI em um componente de segurança de reatores nucleares, onde a confiabilidade deve ser máxima.

O objetivo do PLS é bastante semelhante com o do PCA. A ideia chave desta técnica é a redução do volume de dados, como no PCA, estabelecendo, no entanto, a relação entre dois conjuntos de dados, geralmente uma matriz de dados  $X$  e de saída  $Y$ , identificando as variáveis latentes. Para mais detalhes sobre o PLS, pode-se consultar [95], que traz a ideia geral da técnica, além de exemplos de aplicações para detecção de falhas.

Outra importante ferramenta estatística, o ICA, parte do princípio que se sinais têm origem em diferentes processos físicos, então esses sinais são estatisticamente independentes, e tenta utilizar o princípio recíproco para obter sinais independentes a partir de mistura de sinais [96].

No ICA, a matriz  $X$  em (A.18) é assumida como sendo combinação linear de variáveis independentes  $s_1, \dots, s_k$ , tais que:

$$X^T = A \cdot S, \quad (\text{A.24})$$

onde  $S_{k \times N}$  é a matriz de componentes independentes, e  $A_{m \times k}$  é a matriz de *mixing* que não é conhecida e deve ser encontrada. O objetivo do algoritmo do ICA é encontrar um matriz de *demixing*  $W$ , capaz de transformar  $X$  em  $\hat{S}$  ( $\hat{S} = WX$ ). Um exemplo de aplicação recente do ICA, para um *benchmark* de um reator, está presente em [97].

## A.6 Revisão de Técnicas de Isolamento de Falhas

As técnicas de detecção, vistas anteriormente, geram, após análise das variáveis do processo, sinais que indicam anomalias no sistemas. Esses sinais, que por generalidade recebem os nomes de resíduos, podem ser: resíduos, de fato, obtido através da diferença entre sinais; probabilidades, para métodos estatísticos; graus de pertinência, em métodos que usam lógica *fuzzy*, por exemplo; ou qualquer outro tipo de indicativo de anomalias. Em geral, essas indicações precisam ainda ser avaliadas e para que se indique se de fato ocorre uma falha, em caso positivo, qual tipo e intensidade. A esse processo de avaliação dá-se o nome de isolamento de falhas. O problema de isolamento de falhas, geralmente, se resume a um problema de classi-

ficação. Será feita uma breve revisão de alguns dos principais métodos de classificação com aplicações em problemas de FDI.

### **A.6.1 $K$ Vizinhos Mais Próximos (KNN)**

O classificador KNN é um algoritmo de classificação simples e não-paramétrico que se baseia na premissa que um dado de uma determinada classe de operação vai apresentar características quantitativas próximas aos de seus pares. Para isso, em geral, calcula-se a distância (geralmente a distância euclidiana) para determinados pontos de testes usados na fase de treinamento e verifica-se os  $K$  pontos de testes mais próximos. A classe que tiver mais representantes entre os  $K$  vizinhos mais próximos deve ser a classe a qual o dado pertence.

Existem diversos aprimoramentos do algoritmo KNN, a maioria no sentido de alcançar a escolha ótima do número  $K$ , por exemplo o WKNN e o EWKNN. O grande problema do algoritmo é a quantidade de memória e o tempo de execução, uma vez que classificações mais precisas com um banco de dados maior para o conjunto de treino, e a distância é calculada para cada um dos elementos desse conjunto na fase de classificação online.

Podem-se citar algumas aplicações desse algoritmo no contexto de FDI em rolamentos de motores [98], balanceamento de motores [99], caixa de câmbio [100] e usinas termelétricas [101].

### **A.6.2 Redes Neurais Artificiais (ANN)**

As ANNs foram inspiradas pelo estudo do cérebro humano e reconhecimento dele como uma poderosa ferramenta de processamento. Sua concepção foi uma tentativa de fazer com que dispositivos eletrônicos e computacionais fossem capazes de ter um desempenho tão eficiente quanto o do cérebro humano.

As ANNs apresentam grande potencial para aproximação de sistemas não lineares e de aprendizagem adaptativa. A tecnologia de ANN é utilizada e desenvolvida há muitas décadas e sua aplicação em FDI já é bastante difundida. Existem diversos tipos de redes neurais: redes com funções de bases radiais (RBF), redes com backpropagation, redes com dinâmica recorrente, mapas de Kohonen (SOM), entre outras. As ANNs podem ser aplicadas para FDI por duas estratégias de aprendizado: supervisionado ou não supervisionado. As estratégias não supervisionadas são, na realidade, alternativas de detecção como modelo identificado via ANN.

Com o aprendizado supervisionado ela funciona como classificador, associando os sintomas às falhas.

As aplicações de ANN para FDI surgem constantemente e para toda sorte de processos. Alguns exemplos podem ser vistos em [63] e [70] e em suas referências.

### A.6.3 Máquina de Vetores de Suporte (SVM)

O SVM é uma técnica de aprendizado de máquinas estatístico com grande capacidade de generalização e de grande difusão recente, com aplicações para classificação de todo tipo de dado, sobretudo com o emprego de SVM não linear, que permite a classificação de dados que não podem ser separadas por um hiperplano.

A ideia fundamental por trás do algoritmo do SVM é a solução de um problema de otimização envolvendo mapeamento dos dados. Para a solução deste problema utilizam-se funções *kernel*. O desempenho do classificador pode ser aprimorado com a escolha da função adequada para o problema. As funções geralmente utilizadas são polinomiais, gaussianas e sigmoidais.

As primeiras aplicações do SVM para FDI datam do fim dos anos de 1990. Pode-se citar alguns exemplos de sistemas de FDI utilizando SVM as seguinte aplicações recentes: em rolamentos de motores [102, 103], para o *benchmark* do processo do Tennessee Eastman [104, 105], para uma turbina a gás [106], para um processo de secagem [107].

Desenvolvido a partir do SVM, o SVDD (Descrição de Dados de Vetores de Suporte) é também muito utilizada no contexto de FDI. O SVDD considera apenas amostras da classe de interesse para encontrar os "limites" dessa classe. O SVDD foi usado recentemente para estratégias de FDI para o processo de Tennessee Eastman [108], circuitos analógicos [109] e sistemas de refrigeração [108].

### A.6.4 Lógica *fuzzy*

A Lógica *fuzzy* utiliza regras de inferência *fuzzy* e particiona o espaço de característica em conjuntos *fuzzy*. Esta combinação trata a tarefa de classificação de forma semelhante ao tratamento do raciocínio humano, ou seja, as proposições e as relações de pertinência não são dicotômicas, mas carregam um grau de pertinência. A teoria *fuzzy* tem uma gama de aplicações

que transcende os problemas de classificação, sendo aplicadas em problemas de identificação, inferência, controle, otimização, entre outros.

No contexto de classificação, a lógica *fuzzy* basicamente realiza a tarefa de indicação probabilística da classe, avaliando o grau de certeza de afirmações de pertinência (por exemplo, "o elemento X pertence a classe Y") a partir de regras *fuzzy* (construídas com estruturas SE-ENTÃO).

Além de poder ser usado para classificar, a lógica *fuzzy* também pode ser usada com fim de clusterização de dados. A clusterização, apesar de parecer muito semelhante a classificação, se diferencia pois nesse caso as classes (aqui chamadas de *clusters*) não são conhecidas de antemão. A técnica é muito útil em circunstâncias em que se têm uma grande massa de dados e se deseja agrupá-los, de forma a encontrar alguma semelhança entre os elementos do mesmo *cluster*, constituindo uma poderosa ferramenta de mineração de dados.

Além disso, a lógica *fuzzy*, assim como as ANN's, pode ser utilizada em sistemas FDI, com formulação diferente da tratada nessa seção, no contexto de identificação de sistema, constituindo, neste caso um sistema de detecção (e não isolamento) baseado em modelo.

No contexto de isolamento de falhas, a lógica *fuzzy* é usada, geralmente, de forma que cada um dos cenários de falha constituem uma classe, e se procura qual a classificação mais pertinente dado um conjunto de sintomas.

As aplicações dos classificadores *fuzzy* para isolamento de falhas aparecem em diversos tipos de sistemas, como por exemplo: processos químicos [110], sistema de drive DC [111], processos industriais [112], turbinas a gás [113], veículos autônomos [114], entre outros.

### **A.6.5 Sistemas Imunológicos Artificiais (AIS)**

Os sistemas imunológicos artificiais (AIS) são algoritmos computacionais inspirados no comportamento do sistema imunológico humano. O sistema imunológico natural pode ser visto como um sistema de detecção capaz de distinguir corpos próprios (pertencentes ao organismo) de não-próprios (estranhos ao organismo). Na natureza, os linfócitos são células de defesa responsáveis por detectar e reconhecer os agentes patogênicos, unindo-se a eles. Os receptores dos linfócitos não podem se unir a todos os agentes patogênicos, quanto maior a compatibilidade entre esses receptores e os agentes patogênicos maior a probabilidade de ocorrer a união. Além deste tipo de resposta mediada por células de defesa, os sistemas imunológicos naturais tam-

bém oferecem outro tipo de resposta imune, a resposta imunitária humoral, onde elementos de defesa presentes no sangue, os anticorpos, têm sua produção acionada por agentes externos, os antígenos. Os anticorpos são produzidos especificamente para um tipo de antígeno, e só a ele pode ser ligado.

Baseados nesse funcionamento do sistema imunológico natural, surgiram diferentes gerações de AIS [115–118]. A primeira geração, surgida nos meados da década de 1990, realiza a detecção de anomalias baseadas no princípio de discriminação próprio/não-próprio. Nessa geração, se destacam, devido a aplicações em FDI, as técnicas de seleção negativa. A segunda geração de AIS, surgida na década de 2000, se baseia no Modelo de Perigo. Entre os algoritmos de AIS dessa geração que se destacam com aplicações em FDI estão o algoritmo de Células Dendríticas e a detecção de falhas inspirada no Modelo de Perigo. Outro algoritmo com aplicações em FDI é o algoritmo de receptores do tipo Toll, baseado em uma teoria intermediária entre a clássica e do Modelo de Perigo, a dos não-próprios infecciosos.

Algumas técnicas de AIS com aplicações no contexto de FDI são: reconhecimento *fuzzy* de antígenos [115], *natural killers* (NK) [116], FDI inspirada em modelo de perigo [117] e em seleção negativa [118].

### A.6.6 Redes Bayesianas

As redes Bayesianas constituem uma metodologia de modelagem do conhecimento probabilístico a respeito de um sistema baseado em relações de causas e efeito. As redes Bayesianas são usadas para predições e decisões baseada em conhecimento apenas parcial das informações.

A inferência Bayesiana utiliza o conhecimento guardado nas redes Bayesianas e se baseia sobretudo no teorema de Bayes para probabilidade condicional, que é um modelo adequado para inferência em cenários incertos com evidências sólidas e certas, isto é, quando as evidências podem simplesmente ser classificadas entre verdadeiras ou falsas. O teorema de Bayes permite calcular  $P(H_i|\varepsilon_j)$ , isto é, a probabilidade de a hipótese  $H_i$  ser verdadeira dado que a evidência  $\varepsilon_j$  é conhecida.

Para classificação, a inferência Bayesiana é usada para calcular a probabilidade de hipóteses referentes a relações de pertinência entre dados e classes serem verdadeiras dadas um conjunto de evidências que certamente são verdadeiras.

# Apêndice B

## Controle Tolerante a Falhas

Na década de 1980, paralelamente ao intenso desenvolvimento das técnicas de FDI, surgia um importante conceito para o aumento da confiabilidade de sistemas: o FTC. Esses estudos surgiram, inicialmente, motivados por acidentes na aviação civil, mas possuem aplicações, atualmente, em todo tipo de sistemas. Enquanto os sistemas de FDI são responsáveis pela supervisão dos processos, os sistemas de FTC devem garantir o funcionamento normal ou mínimo dos mesmos e muitas vezes dependem de informações providas por um sistema de FDI.

Uma evolução natural desse trabalho seria o desenvolvimento de um sistema de FTC também baseado em dados, que também fosse aplicável ao *benchmark* de turbina eólica em questão. Algumas das principais técnicas de FTC serão abordadas rapidamente durante esta seção, e será formulada uma proposta de sistema FTC para o problema da turbina eólica.

Alguns trabalhos revisionais oferecem bastante informações sobre conceitos, técnicas e aplicações de sistemas de FTC, entre os quais pode-se citar [119–121].

Os sistemas de FTC podem ser divididos em dois grandes grupos: os sistemas de FTC passivo (PFTC), onde as metas e os componentes da malha de controle permanecem intactas diante de falhas, e os sistemas de FTC ativo (AFTC), onde são executadas alterações no controlador ou na malha de controle após a detecção e diagnóstico da falha. Os sistemas de AFTC podem ser desenvolvidos através de dois tipos de abordagens, acomodação de falhas (FA), onde a ação de controle em consequência da falha é aplicada sobre a parte faltosa do sistema, e reconfiguração de controle (CR), onde o controle é feito sobre a parte saudável do sistema. A proposta de trabalho futuro apresentada aqui se baseia em um mecanismo de CR, portanto, serão fornecidas informações gerais sobre algumas técnicas de FTC, com maior ênfase para as de

CR.

### **B.0.7 Controle tolerante a falhas passivo**

Nos sistemas de PFTC, a lei de controle não é alterada, tampouco a malha de controle. O objetivo de controle, prevê a manutenção do funcionamento diante de falhas. Nos PFTC, os controladores são projetados para apresentarem robustez a determinados tipos conhecidos de falhas. Neste contexto, as falhas são tratadas como incertezas ou perturbações no sistema. A tarefa de projetar o controlador consiste, dessa forma, em fazer com que o sistema em malha fechada seja robusto as falhas. A grande vantagem desses sistemas é que eles dispensam um sistema dedicado a FDI. Em contrapartida, eles apresentam uma capacidade de tolerância a falhas bastante limitada.

### **B.0.8 Acomodação de Falhas**

Nos sistemas de FA, os controladores sofrem alterações em sua estrutura ou em seus parâmetros para evitar as consequências das falhas. Nessa estratégia a malha de controle e as ligações de entrada e saída do controlador não são alteradas. As técnicas de FA exigem, além da sinalização de falhas fornecida pelos sistemas de FDI, de um modelo para o sistema faltoso.

### **B.0.9 Controle Reconfigurável**

Nos sistemas de FTC com CR, existe alteração na malha de controle, excluindo-se componente faltosos, e estabelecendo uma nova meta de controle que envolva apenas a parte saudável do sistema.

O sistema reconfigurado em malha fechada idealmente deve apresentar o mesmo comportamento que o sistema nominal sem falhas, para isso existem quatro importantes metas de desempenho para o sistema reconfigurado:

- a) *Meta de estabilização da malha:* o sistema reconfigurado em malha fechada deve ser assintoticamente estável.
- b) *Meta de recuperação de equilíbrio da malha:* o sistema reconfigurado em malha fechada deve atenuar as perturbações, rastreamento uma determinada referência.

- c) *Meta de recuperação da trajetória de saída da malha:* o sistema reconfigurado em malha fechada deve apresentar exatamente a mesma saída do sistema nominal livre de falhas à determinada referência com presença de perturbações específicas.
- d) *Meta de recuperação da trajetória dos estados da malha:* o sistema reconfigurado em malha fechada deve apresentar exatamente os mesmos estados do sistema nominal livre de falhas à determinada referência com presença de perturbações específicas.

Tipicamente, os sistemas com CR são constituídos de quatro partes: um sistema de FDI; um controlador reconfigurável (ou diversos controladores); um mecanismo de reconfiguração do controle, que reconfigura os diversos elementos do sistema em caso de ocorrência de falhas; e um regulador de referência, que ajusta a entrada de referência em caso de degradação da performance. Seguem alguns dos principais métodos de CR.

#### **B.0.9.1 Redundância Física**

A reconfiguração de sistemas com redundância física se resume a presença de hardwares duplicados que simplesmente são chaveados em caso de falhas. Se trata de uma solução muito simples e eficaz, no entanto extremamente cara. Por essa razão, esta técnica é, geralmente, aplicada em cenários onde a segurança é uma questão muito crítica, como em plantas nucleares ou em espaçonaves.

As pesquisas em sistemas de FTC, no entanto, se concentram no desenvolvimento de emprego de redundância analítica, onde a falha é compensada sem o uso de hardwares redundantes. Mesmo sistemas com redundância física, emprega-se em paralelo a redundância analítica.

#### **B.0.9.2 Projeção**

A reconfiguração de sistemas por projeção, também conhecida por controle de modelos múltiplos (MM), é baseada num conjunto de modelos lineares que descrevem a dinâmica do sistema em diferentes cenários, com a presença de diferentes falhas. Essa técnica consiste em projetar um controlador para cada um dos modelos referentes a cada situação de falha prevista. Todos os controladores são implementados, e devem estar subordinados a um sistema capaz de determinar o controlador global a ser utilizado em cada situação (indicada pelo FDI) como uma combinação dos diferentes controladores projetados.

A combinação dos controladores são feitas de duas formas principais. A primeira é através de pesos probabilísticos que são atribuídos através de filtros de Kalman (descrito por [122]). A segunda forma, bastante utilizada, consiste num simples chaveamento dos diversos controladores, como descrito em [123], onde é utilizado um banco de controladores LQR para controle de vôo. Na aplicação de chaveamentos deve-se levar em conta os impactos dos mesmos sobre a estabilidade do sistema.

Métodos de múltiplo modelos já são bem utilizados para modelagem e controle de sistemas não lineares. Um ponto forte desta técnica é a facilidade de implementação, uma vez que o projeto dos controladores é *offline*. No entanto o esforço para projetar todos os controladores *offline* é elevado. O grande problema desta técnica é o risco de o sistema convergir para uma situação faltosa não prevista, uma vez que os controladores são projetados para serem ideais para um número finito de cenários faltosos. Além disso, em geral essa estratégia é bastante suscetível a determinadas incertezas no modelo.

### **B.0.9.3 Controle por Aprendizagem**

Um sistema de controle por aprendizagem é aquele que possui a capacidade de melhorar seu desempenho no futuro a partir informações obtidas no presente e no passado *online* e em malha fechada. é uma técnica interessante em situações onde o sistema atua diante de incertezas, ou quando as informações iniciais são extremamente limitadas.

Os sistemas de FTC que utilizam essa abordagem são constituídos de dois blocos principais. O primeiro é um componente rápido cuja função é obter estimativas, geralmente um filtro de Kalman. O segundo componente é mais lento e é responsável por reter o conhecimento adquirido.

É importante salientar a diferença entre o controle adaptativo e o controle por aprendizagem. Os dois podem ser implementados utilizando algoritmos de otimização e ajuste de parâmetros (por exemplo, redes neurais e algoritmos genéticos) e ambos podem utilizar para isto informações obtidas *online* em malha fechada. No entanto existe uma diferença fundamental no objetivo dos dois tipos de sistemas. Os sistemas adaptativos tem como objetivo mudar o comportamento com o uso através de atualizações e otimizações. A aprendizagem, de outra forma, busca desenvolver um modelo global estático, que seja capaz de associar cada cenário a um comportamento. Naturalmente os sistemas de controle por aprendizagem podem precisar

se adaptar, de certa forma, para acomodar a novas experiências. O controle adaptativo pode ser utilizado em acomodação de falhas, mas não é suficiente para resolver o problema de reconfiguração de controle.

A abordagem baseada em controle por aprendizagem é especialmente interessante no caso de sistemas com incertezas não-lineares. Um estudo completo sobre o controle inteligente tolerante a falhas é feito em [124]. Essa aplicação para esses sistemas foi proposta inicialmente em [125], onde é utilizado um sistema de controle por aprendizagem híbrido com filtro de Kalman estendido e utiliza como exemplo um veículo submarino. Outro trabalho interessante é [126], que compara o desempenho de um sistema capaz de acomodar falhas, utilizando lógica *fuzzy* para ajustar os ganhos de um controlador PI para uma planta geradora híbrida de energia, com um que utiliza controle por aprendizado, armazenando o conhecimento em uma rede neural.

Uma das dificuldades ao lidar com essa abordagem é a dificuldade de se obterem provas de estabilidades desses sistemas. Outra é o alto custo computacional associado ao processo de aprendizagem.

#### B.0.9.4 Reprojetado de controlador

Esta é a abordagem de controle reconfigurável dominante atualmente. Nessa abordagem o controlador nominal é substituído por outro controlador para ser usado em caso de falhas, o qual é projetado *online* após a indicação de falhas fornecida pelo sistema de FDI. Esse novo controlador deve fazer com que a planta reconfigurada atenda as metas de FTC, e se comporte como um modelo de referência.

De forma geral, para o caso linear, nesse método considera-se a dinâmica do controlador descrita abaixo:

$$u_c(t) = -Kx(t) + Vr(t), \quad (\text{B.1})$$

onde  $x(t)$  é o vetor de estados e  $r(t)$  é a referência. O projeto de controle reconfigurável, através dessa abordagem, consiste na determinação das matrizes  $V$  e  $K$ , que façam com que o sistema em malha fechada apresente a mesma dinâmica do modelo de referência, mesmo diante de falhas. Isto é, dada uma planta faltosa:

$$\dot{x}_f(t) = A_f x_f(t) + B_f u_f(t) + B_d d(t), \quad (\text{B.2})$$

$$y_f(t) = C_f x_f(t), \quad (\text{B.3})$$

e um modelo de referência, que apresenta o comportamento desejado em malha fechada:

$$\dot{x}_m(t) = Mx_m(t) + Nr(t), \quad (\text{B.4})$$

$$y_m(t) = Px_m(t). \quad (\text{B.5})$$

As matrizes  $K$  e  $V$  de B.1, são tais que:

$$A_f x_f(t) + B_f K - M = 0, \quad (\text{B.6})$$

$$B_f V - N = 0. \quad (\text{B.7})$$

Sendo assim, a abordagem por reprojeto de controladores consiste num projeto *online* de controladores que atendam a B.6 e B.7. Ou então, caso não seja possível atendê-las, minimize-as.

Existem diversas técnicas desenvolvidas para alcançar esse resultado, por exemplo: pseudo-inversa [127], seguidor de modelo linear [128], seguidor de modelo adaptativo [129], atribuição de autovalores [130], seguidor de modelo ótimo [131], seguidor de modelo preditivo [132]. Em [120], é feita uma revisão sobre cada um desses métodos.

#### B.0.9.5 Máscara de Falhas

Em geral, as técnicas citadas anteriormente de FTC consistem em modificar ou selecionar o controlador ideal para cada situação de falha. O uso da técnica de máscara de falhas, também conhecida por *fault-hiding*, consiste num paradigma diferente, isto é, nesta abordagem o controlador não é modificado. A ideia geral da Máscara de falhas é utilizar um bloco de reconfiguração entre o controlador e a planta diante da ocorrência de falhas.

O bloco de reconfiguração  $\zeta(t)$  é conectado a todos os sensores e atuadores do sistema, se comunicando com eles através do par de vetores de sinais  $u_f$  e  $y_f$  e ao controlador nominal, através do par  $u_c$  e  $y_c$ . Esse bloco deve funcionar simultaneamente como um tradutor e um corretor. Ele deve corrigir o vetor de saídas médias  $y_f$ , afetadas pelas falhas, de tal forma que o controlador o perceba através de  $y_c$ , como seria a medida em uma situação livre de falhas. E ainda deve traduzir o sinal de controle  $u_c$  em um sinal de controle  $u_f$ , capaz de manter o funcionamento adequado da planta faltosa.

Desta forma, o bloco de reconfiguração está associado a um operador matemático  $\Omega_{BR}$  tal que:

$$(u_f, y_c) = \Omega_{BR}(u_c, y_f, \zeta(0)), \quad (\text{B.8})$$

e a planta reconfigurada está associada a um operador  $\Omega_{PR}$  tal que:

$$(y_c, z_f) = \Omega_{PR}(u_c, d, x(0), \zeta(0)), \quad (\text{B.9})$$

onde  $d$  é a referência,  $x(0)$  é o estado inicial e  $z_f$  é a saída controlada.

O bloco de reconfiguração deve atender às condições de inatividade, que garantem que o bloco não deve afetar no controle antes da ocorrência das falhas, o que deve significar que o bloco de reconfiguração pode ser implementado e executado durante o funcionamento normal da planta, sendo ativado apenas diante da ocorrência de falhas.

A planta reconfigurada, após a ocorrência de falhas, é composta pela planta faltosa, pelo controlador nominal (que segue inalterado) e pelo bloco de reconfiguração. Em [133], Richter propõe três metas que garantem que o controlador nominal é capaz de tratar a planta faltosa como a planta nominal, quando esta for reconfigurada. As metas são:

- a) *Meta de mascaramento fraco*: para cada condição inicial  $x(0)$ , da planta, deve existir uma condição inicial do bloco de reconfiguração  $\zeta(0)$ , de tal forma que a planta reconfigurada apresente o mesmo comportamento da planta nominal;
- b) *Meta de mascaramento assintótico*: as saídas da planta reconfigurada deve se aproximar assintoticamente das saídas da planta livre de falhas, para quaisquer condições iniciais;
- c) *Meta de mascaramento rigoroso*: as saídas da planta reconfigurada deve ser igual às saídas da planta livre de falhas, para quaisquer condições iniciais;

Naturalmente, a terceira meta implica na segunda, que por sua vez implica na primeira. Dependendo da aplicação, é desejável que o bloco de reconfiguração atenda a uma dessas metas. Além dessas metas aplicáveis ao bloco de reconfiguração, as metas de desempenho para o sistema reconfigurado, presentes na introdução desta seção ainda são válidas, com as adaptações pertinentes ao contexto de Máscara de falhas.

O bloco de reconfiguração pode ser constituído de dois elementos: sensores virtuais e atuadores virtuais.

O sensor virtual é acionado em caso de falhas em sensores, e pode ser um observador de Luenberger, ou algum outro tipo de estimador de estados, de acordo com a aplicação. No caso do observador de Luenberger, o desafio do projeto se resume ao cálculo de uma matriz de ganhos do observador  $L$ , cujas técnicas para determiná-la estão presentes em diversas literaturas. O sensor virtual foi utilizado pela primeira vez com intuito de mascarar falhas em [134].

O atuador virtual é um o bloco de reconfiguração utilizado para mascarar falhas nos atuadores. O projeto do atuador virtual pode ser feito sob diferentes abordagens, uma das quais, é encará-lo como o observador dual, que vem sendo estudado há décadas. De forma geral, independentemente da abordagem o desafio do projeto do atuador virtual consiste na determinação de duas matrizes  $M$  e  $N$ . Essas matrizes são tais que:

$$u_f(t) = Mx_\Delta(t) + Nu_c(t), \quad (\text{B.10})$$

onde  $x_\Delta(t)$  são os estados do atuador virtual. A primeira utilização de atuadores virtuais para SCTFA estão em [135, 136].

A descrição completa desses blocos, e técnicas detalhadas para o projeto destes estão presentes em [135] e [133].

As principais vantagens dessa abordagem sobre as demais técnicas para FTC são:

- O projeto do bloco de reconfiguração é totalmente independente do projeto do controlador nominal, que não precisará sofrer quaisquer alterações diante da ocorrência de falhas.
- Pode ser utilizado para qualquer tipo de controlador (projetado com qualquer técnica ou abordagem), inclusive para controladores humanos.
- Numa situação em que o controlador é um ser humano, essa abordagem minimiza a dificuldade na lida com cenários faltosos, pois sob o ponto de vista do controlador a planta reconfigurada será semelhante a planta livre de falhas.
- Possibilita, em caso de falhas, uma intervenção mínima, conservando o controlador, e muitas vezes representando uma redução dos custos financeiros e de processamento, evitando redundâncias físicas ou reprojets *online*, por exemplo.

- Aplicáveis a diferentes classes de plantas, como lineares, não-lineares e LPV.

Essa abordagem apresenta como principal limitação o fato de ser baseada em modelo, isto é, a necessidade de existência de um modelo matemático da planta, com as devidas modelagens de falhas, a partir do qual o bloco de reconfiguração é projetado.

As pesquisas nessa área ainda são poucas, uma vez que os primeiros trabalhos que mencionam o termo *fault hiding* datam de 2006 [134–136]. No entanto aplicações em diversas classes de sistemas vêm surgindo, como por exemplo: sistemas lineares invariantes no tempo [136, 137], sistemas não-lineares [133, 134, 138], sistemas lineares com parâmetros variantes (LPV) [139–142], sistemas PWA (*piecewise affine*) [143, 144], sistemas de eventos discretos [145], sistemas Hammerstein-Wiener [146], sistemas Lure [147], sistemas de controle em rede [148].

# Referências Bibliográficas

- [1] F. D. Bianchi, H. de Battista, and R. J. Mantz, *Wind Turbine Control Systems: Principles, Modelling and Gain Scheduling Design*. Advances in Industrial Control, Springer London, 2006.
- [2] P. F. Odgaard, J. Stoustrup, and M. Kinnaert, “Fault-tolerant control of wind turbines: A benchmark model,” *IEEE Transactions on Control Systems Technology*, vol. 21, pp. 1168–1182, July 2013.
- [3] C. Projects, B. Toxicology, D. Studies, and N. Council, *Environmental Impacts of Wind-Energy Projects*. National Academies Press, 2007.
- [4] O. Anaya-Lara, D. Campos-Gaona, E. Moreno-Goytia, and G. Adam, *Offshore Wind Energy Generation: Control, Protection, and Integration to Electrical Systems*. Wiley, 2014.
- [5] F. Pimenta, W. Kempton, and R. Garvine, “Combining meteorological stations and satellite data to evaluate the offshore wind power resource of southeastern brazil,” *Renewable Energy*, vol. 33, no. 11, pp. 2375–2387, 2008.
- [6] D. Gamerman and H. F. Lopes, *Markov chain Monte Carlo: Stochastic Simulation for Bayesian Inference*. Texts in Statistical Sciences: Chapman and Hall, 1997.
- [7] P. F. Odgaard, J. Stoustrup, and M. Kinnaert, “Fault-tolerant control of wind turbines - a benchmark model,” in *7th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes*, pp. 155–160, IFAC, 2009.
- [8] J. Ribrant and L. M. Bertling, “Survey of failures in wind power systems with focus on swedish wind power plants during 1997-2005,” *IEEE Transactions on Energy conversion*, vol. 22, no. 1, pp. 167–173, 2007.

- [9] Y. Sinha and J. Steel, “A progressive study into offshore wind farm maintenance optimisation using risk based failure analysis,” *Renewable and Sustainable Energy Reviews*, vol. 42, pp. 735 – 742, 2015.
- [10] B. Hahn, M. Durstewitz, and K. Rohrig, “Reliability of wind turbines,” in *Wind energy*, pp. 329–332, Springer, 2007.
- [11] J. M. P. Pérez, F. P. G. Márquez, A. Tobias, and M. Papaelias, “Wind turbine reliability analysis,” *Renewable and Sustainable Energy Reviews*, vol. 23, pp. 463 – 472, 2013.
- [12] Q. Yingning, S. Juan, and F. Yanhui, “Wind turbine fault simulation,” in *2nd IET Renewable Power Generation Conference*, pp. 1–4, Sept 2013.
- [13] P. Tchakoua, R. Wamkeue, M. Ouhrouche, F. Slaoui-Hasnaoui, T. A. Tameghe, and G. Ekemb, “Wind turbine condition monitoring: State-of-the-art review, new trends, and future challenges,” *Energies*, vol. 7, no. 4, pp. 2595–2630, 2014.
- [14] L. Yafeng, L. Guoxing, and Y. Jun, “Fault diagnosis of wind turbine blades based on fuzzy theory,” in *Control, Automation and Systems Engineering (CASE), 2011 International Conference on*, pp. 1–3, July 2011.
- [15] X. Wei, M. Verhaegen, and T. Van den Engelen, “Sensor fault diagnosis of wind turbines for fault tolerant,” in *Proceedings of the 17th World Congress The International Federation of Automatic Control*, vol. 17, pp. 3222–3227, 2008.
- [16] K. Rothenhagen and F. W. Fuchs, “Doubly fed induction generator model-based sensor fault detection and control loop reconfiguration,” *IEEE Transactions on Industrial Electronics*, vol. 56, no. 10, pp. 4229–4238, 2009.
- [17] K. Rothenhagen and F. W. Fuchs, “Current sensor fault detection, isolation, and reconfiguration for doubly fed induction generators,” *IEEE Transactions on Industrial Electronics*, vol. 56, no. 10, pp. 4239–4245, 2009.
- [18] M. Hilbert, C. Kuech, and K. Nienhaus, “Model based fault detection of wind turbine drive trains,” *Chemical Engineering Transactions*, vol. 33, pp. 937–942, 2013.

- [19] A. Zhou, D. Yu, and W. Zhang, "A research on intelligent fault diagnosis of wind turbines based on ontology and FMECA," *Advanced Engineering Informatics*, vol. 29, no. 1, pp. 115–125, 2015.
- [20] I. Attoui and A. Omeiri, "Contribution to the fault diagnosis of a doubly fed induction generator for a closed-loop controlled wind turbine system associated with a two-level energy storage system," *Electric Power Components and Systems*, vol. 42, no. 15, pp. 1727–1742, 2014.
- [21] B. Tang, W. Liu, and T. Song, "Wind turbine fault diagnosis based on morlet wavelet transformation and wigner-ville distribution," *Renewable Energy*, vol. 35, no. 12, pp. 2862–2866, 2010.
- [22] L. Wenyi, W. Zhenfeng, H. Jiguang, and W. Guangfeng, "Wind turbine fault diagnosis method based on diagonal spectrum and clustering binary tree SVM," *Renewable Energy*, vol. 50, pp. 1–6, 2013.
- [23] J. Hang, J. Zhang, and M. Cheng, "Fault diagnosis of wind turbine based on multisensors information fusion technology," *IET Renewable Power Generation*, vol. 8, pp. 289–298, April 2014.
- [24] A. R. Nejad, P. F. Odgaard, Z. Gao, and T. Moan, "A prognostic method for fault detection in wind turbine drivetrains," *Engineering Failure Analysis*, vol. 42, pp. 324–336, 2014.
- [25] L. Hocine, Z. Nora, and K. M. Samira, "Wind turbine gearbox fault diagnosis based on symmetrical components and frequency domain," *Electrical Engineering*, pp. 1–10, 2015.
- [26] A. Hu, X. Yan, and L. Xiang, "A new wind turbine fault diagnosis method based on ensemble intrinsic time-scale decomposition and WPT-fractal dimension," *Renewable Energy*, vol. 83, pp. 767 – 778, 2015.
- [27] B. Chen, P. J. Tavner, Y. Feng, W. W. Song, and Y. Qiu, "Bayesian network for wind turbine fault diagnosis.," 2012.

- [28] J. Chen and G. Hao, “Research on the fault diagnosis of wind turbine gearbox based on bayesian networks,” in *Practical Applications of Intelligent Systems* (Y. Wang and T. Li, eds.), vol. 124 of *Advances in Intelligent and Soft Computing*, pp. 217–223, Springer Berlin Heidelberg, 2012.
- [29] P. L. Negre, V. Puig, and I. Pineda, “Model-based fault detection and identification of wind turbines—a field data approach,” in *Proceedings of the European Wind Energy Conference*, March 2011.
- [30] N. Laouti, N. Sheibat-Othman, and S. Othman, “Support vector machines for fault detection in wind turbines,” in *Proceedings of the 18th IFAC World Congress*, vol. 18, pp. 7067–7072, 2011.
- [31] W. Chen, S. Ding, A. Haghani, A. Naik, A. Khan, and S. Yin, “Observer-based FDI schemes for wind turbine benchmark,” in *Proceedings of the 18th IFAC World Congress*, vol. 18, pp. 7073–7078, 2011.
- [32] X. Zhang, Q. Zhang, S. Zhao, R. M. Ferrari, M. M. Polycarpou, and T. Parisini, “Fault detection and isolation of the wind turbine benchmark: An estimation-based approach,” in *Proceedings of the 18th IFAC World Congress*, vol. 18, pp. 8295–8300, 2011.
- [33] C. Svärd and M. Nyberg, “Automated design of an fdi-system for the wind turbine benchmark,” in *Proceedings of the 18th IFAC World Congress*, vol. 18, pp. 8307–8315, 2011.
- [34] A. A. Ozdemir, P. Seiler, and G. J. Balas, “Wind turbine fault detection using counter-based residual thresholding,” in *Proceedings of the 18th IFAC World Congress*, vol. 18, pp. 8289–8294, 2011.
- [35] N. Laouti, S. Othman, M. Alamir, and N. Sheibat-Othman, “Combination of model-based observer and support vector machines for fault detection of wind turbines,” *International Journal of Automation and Computing*, vol. 11, no. 3, pp. 274–287, 2014.
- [36] S. M. Tabatabaeipour, P. F. Odgaard, T. Bak, and J. Stoustrup, “Fault detection of wind turbines with uncertain parameters: a set-membership approach,” *Energies*, vol. 5, no. 7, pp. 2424–2448, 2012.

- [37] N. Sheibat-Othman, S. Othman, M. Benlahrache, and P. Odgaard, “Fault detection and isolation in wind turbines using support vector machines and observers,” in *American Control Conference*, pp. 4459–4464, June 2013.
- [38] S. Yin, G. Wang, and H. R. Karimi, “Data-driven design of robust fault detection system for wind turbines,” *Mechatronics*, vol. 24, no. 4, pp. 298–306, 2014.
- [39] H. Sanchez, T. Escobet, V. Puig, and P. F. Odgaard, “Fault diagnosis of an advanced wind turbine benchmark using interval-based arrs and observers,” *IEEE Transactions on Industrial Electronics*, vol. 62, pp. 3783–3793, June 2015.
- [40] J. Blesa, D. Rotondo, V. Puig, and F. Nejjari, “{FDI} and {FTC} of wind turbines using the interval observer approach and virtual actuators/sensors,” *Control Engineering Practice*, vol. 24, pp. 138–155, 2014.
- [41] S. Simani, S. Farsoni, and P. Castaldi, “Fault diagnosis of a wind turbine benchmark via identified fuzzy models,” *IEEE Transactions on Industrial Electronics*, vol. 62, pp. 3775–3782, June 2015.
- [42] H. Badihi, Y. Zhang, and H. Hong, “Wind turbine fault diagnosis and fault-tolerant torque load control against actuator faults,” *IEEE Transactions on Control Systems Technology*, vol. 23, pp. 1351–1372, July 2015.
- [43] S. Dey, P. Pisu, and B. Ayalew, “A comparative study of three fault diagnosis schemes for wind turbines,” *IEEE Transactions on Control Systems Technology*, vol. PP, no. 99, pp. 1–1, 2015.
- [44] M. F. S. V. D’Angelo, R. M. Palhares, R. H. C. Takahashi, and R. H. Loschi, “Fuzzy/-Bayesian change point detection approach to incipient fault detection,” *IET Control Theory & Applications*, vol. 5, no. 4, p. 539, 2011.
- [45] T. Kohonen, *Selg-Organizing Maps*. Springer Series in Information Sciences, Springer, 2001.
- [46] J. C. Bezdek, *Pattern recognition with fuzzy objective function algorithms*. Plenum Press, 1981.

- [47] G. Casella and E. I. George, “Explaining the gibbs sampler,” *The American Statistician*, vol. 46, no. 3, pp. pp. 167–174, 1992.
- [48] M. Fitzpatrick, “Geometric ergodicity of the Gibbs sampler for the Poisson change-point model,” *Statistics & Probability Letters*, vol. 91, pp. 55–61, 2014.
- [49] O. Namaki-Shoushtari and B. Huang, “Bayesian control loop diagnosis by combining historical data and process knowledge of fault signatures,” *IEEE Transactions on Industrial Electronics*, vol. 62, no. 6, pp. 3696–3704, 2015.
- [50] D. Wang, S. Sun, and P. Tse, “A general sequential monte carlo method based optimal wavelet filter: A bayesian approach for extracting bearing fault features,” *Mechanical Systems and Signal Processing*, vol. 52-53, no. 1, pp. 293–308, 2015.
- [51] K. Zhang, R. Gonzalez, B. Huang, and G. Ji, “Expectation-maximization approach to fault diagnosis with missing data,” *IEEE Transactions on Industrial Electronics*, vol. 62, no. 2, pp. 1231–1240, 2015.
- [52] S. Frühwirth-Schnatter, “On fuzzy bayesian inference,” *Fuzzy Sets and Systems*, vol. 60, no. 1, pp. 41–58, 1993.
- [53] M. D’Angelo, R. M. Palhares, L. B. Cosme, L. A. Aguiar, F. S. Fonseca, and W. M. Caminhas, “Fault detection in dynamic systems by a fuzzy/Bayesian network formulation,” *Applied Soft Computing*, vol. 21, pp. 647 – 653, 2014.
- [54] J. Dong, *Data driven fault tolerant control: a subspace approach*. PhD thesis, Delft University of Technology, 2009.
- [55] G. Tao, S. Chen, and S. M. Joshi, “An adaptive actuator failure compensation controller using output feedback,” *IEEE Transactions on Automatic Control*, vol. 47, no. 3, pp. 506–511, 2002.
- [56] S. Yin, X. Li, H. Gao, and O. Kaynak, “Data-based techniques focused on modern industry: An overview,” *IEEE Transactions on Industrial Electronics*, vol. 62, pp. 657–667, Jan 2015.
- [57] A. S. Bazanella, L. Campestrini, and D. Eckhard, *Data-Driven Controller Design: The  $\mathcal{H}_2$  Approach*. Communications and Control Engineering, Springer Netherlands, 2011.

- [58] R. Isermann, *Fault-Diagnosis Systems: An Introduction from Fault Detection to Fault Tolerance*. Springer, 2006.
- [59] R. Isermann, *Fault-Diagnosis Applications: Model-Based Condition Monitoring: Actuators, Drives, Machinery, Plants, Sensors, and Fault-tolerant Systems*. Springer, 2011.
- [60] S. X. Ding, *Model-based Fault Diagnosis Techniques: Design Schemes, Algorithms, and Tools*. Springer, 2008.
- [61] V. Venkatasubramanian, R. Rengaswamy, K. Yin, and S. N. Kavuri, “A review of process fault detection and diagnosis: Part i: Quantitative model-based methods,” *Computers & Chemical Engineering*, vol. 27, no. 3, pp. 293 – 311, 2003.
- [62] V. Venkatasubramanian, R. Rengaswamy, and S. N. Kavuri, “A review of process fault detection and diagnosis: Part ii: Qualitative models and search strategies,” *Computers & Chemical Engineering*, vol. 27, no. 3, pp. 313 – 326, 2003.
- [63] V. Venkatasubramanian, R. Rengaswamy, S. N. Kavuri, and K. Yin, “A review of process fault detection and diagnosis: Part iii: Process history based methods,” *Computers & Chemical Engineering*, vol. 27, no. 3, pp. 327 – 346, 2003.
- [64] M. F. S. V. D’Angelo, R. M. Palhares, W. M. Caminhas, R. H. C. Takahashi, R. D. Maia, and A. P. Lemos, “Detecção de falhas: Uma revisão com aplicações,” in *Tutoriais do XVIII Congresso Brasileiro de Automática*, pp. 1–46, Abril 2010.
- [65] R. J. Patton, P. M. Frank, and R. N. Clark, *Issues of Fault Diagnosis for Dynamic Systems*. Springer Publishing Company, Incorporated, 1st ed., 2010.
- [66] S. Simani, R. Patton, and C. Fantuzzi, *Model-Based Fault Diagnosis in Dynamic Systems Using Identification Techniques*. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2003.
- [67] J. Chen and R. J. Patton, *Robust Model-based Fault Diagnosis for Dynamic Systems*. Norwell, MA, USA: Kluwer Academic Publishers, 1999.
- [68] P. Tchakoua, R. Wamkeue, M. Ouhrouche, F. Slaoui-Hasnaoui, T. A. Tameghe, and G. Ekemb, “Wind turbine condition monitoring: State-of-the-art review, new trends, and future challenges,” *Energies*, vol. 7, no. 4, p. 2595, 2014.

- [69] Z. Gao, C. Cecati, and S. Ding, “A survey of fault diagnosis and fault-tolerant techniques-part i: Fault diagnosis with model-based and signal-based approaches,” *IEEE Transactions on Industrial Electronics*, vol. 62, no. 6, pp. 3757–3767, 2015.
- [70] Z. Gao, C. Cecati, and S. Ding, “A survey of fault diagnosis and fault-tolerant techniques-part ii: Fault diagnosis with knowledge-based and hybrid/active approaches,” *IEEE Transactions on Industrial Electronics*, vol. 62, no. 6, pp. 3768–3774, 2015.
- [71] Y. Yang, S. Ding, and L. Li, “On observer-based fault detection for nonlinear systems,” *Systems and Control Letters*, vol. 82, pp. 18–25, 2015.
- [72] K. Emami, T. Fernando, B. Nener, H. Trinh, and Y. Zhang, “A functional observer based fault detection technique for dynamical systems,” *Journal of the Franklin Institute*, vol. 352, no. 5, pp. 2113–2128, 2015.
- [73] F. R. L. Estrada, J.-C. Ponsart, D. Theilliol, and C. M. Astorga-Zaragoza, “Robust  $H_-/H_\infty$  fault detection observer design for descriptor-LPV systems with unmeasurable gain scheduling functions,” *International Journal of Control*, pp. 1–12, 0. doi:10.1080/00207179.2015.1044261.
- [74] K. Zhang, B. Jiang, V. Cocquempot, and H. Zhang, “A framework of robust fault estimation observer design for continuous-time/discrete-time systems,” *Optimal Control Applications and Methods*, vol. 34, no. 4, pp. 442–457, 2013.
- [75] M. Zhong and Q. Cao, “Pmi based fault estimation for linear time-varying systems,” pp. 4364–4368, 2013.
- [76] A. Filasová, D. Krokavec, and V. Serbák, “Application of descriptor approaches in design of PD observer-based actuator fault estimation,” *Archives of Control Sciences*, vol. 25, no. 1, pp. 51–64, 2015.
- [77] M. Gholizadeh and F. R. Salmasi, “Estimation of state of charge, unknown nonlinearities, and state of health of a lithium-ion battery based on a comprehensive unobservable model,” *IEEE Transactions on Industrial Electronics*, vol. 61, pp. 1335–1344, March 2014.

- [78] X. Han, E. Fridman, and S. K. Spurgeon, “Sampled-data sliding mode observer for robust fault reconstruction: A time-delay approach,” *Journal of the Franklin Institute*, vol. 351, no. 4, pp. 2125–2142, 2014.
- [79] Q. Jia, H. Li, Y. Zhang, and X. Chen, “Robust observer-based sensor fault reconstruction for discrete-time systems via a descriptor system approach,” *International Journal of Control, Automation and Systems*, vol. 13, no. 2, pp. 274–283, 2015.
- [80] W. Huang and X. Su, “Design of a fault detection and isolation system for intelligent vehicle navigation system,” *International Journal of Navigation and Observation*, vol. 2015, 2015.
- [81] P. Lu, L. Van Eykeren, E.-J. van Kampen, and Q. P. Chu, “Sensor fault detection and estimation for quadrotors using kinematic equations,” in *Advances in Aerospace Guidance, Navigation and Control*, pp. 363–379, Springer, 2015.
- [82] S. Y. Kim, C. H. Kang, and C. G. Park, “A fault detection algorithm using an adaptive fading kalman filter for various types of gnss fault,” in *Proceedings of the 2015 6th International Conference on Intelligent Systems, Modelling and Simulation*, pp. 113–117, 2015.
- [83] F. B. Hmida, K. Khémiri, J. Ragot, and M. Gossa, “Three-stage kalman filter for state and fault estimation of linear stochastic systems with unknown inputs,” *Journal of the Franklin Institute*, vol. 349, no. 7, pp. 2369–2388, 2012.
- [84] Z. Sun and Z. Yang, “Joint parametric fault diagnosis and state estimation using KF–ML method,” in *Proceedings of the 19th World Congress of the International Federation of Automatic Control*, pp. 8293–8298, IFAC, 2014.
- [85] L. F. Mendonca, J. ao MC Sousa, and J. M. G. S. da Costa, “An architecture for fault detection and isolation based on fuzzy methods,” *Expert Systems with Applications*, vol. 36, no. 2, Part 1, pp. 1092 – 1104, 2009.
- [86] A. Fekih, H. Xu, and F. N. Chowdhury, “Neural networks based system identification techniques for model based fault detection of nonlinear systems,” *International Journal of Innovative Computing, Information and Control*, vol. 3, no. 5, pp. 1073–1085, 2007.

- [87] R. Razavi-Far, H. Davilu, V. Palade, and C. Lucas, “Model-based fault detection and isolation of a steam generator using neuro-fuzzy networks,” *Neurocomputing*, vol. 72, no. 13–15, pp. 2939 – 2951, 2009.
- [88] M. Patel and R. Patel, “Fault detection and classification on a transmission line using wavelet multi resolution analysis and neural network,” *International Journal of Computer Applications*, vol. 47, no. 22, pp. 27–33, 2012.
- [89] H. Gao, L. Liang, X. Chen, and G. Xu, “Feature extraction and recognition for rolling element bearing fault utilizing short-time fourier transform and non-negative matrix factorization,” *Chinese Journal of Mechanical Engineering*, vol. 28, no. 1, pp. 96–105, 2015.
- [90] C. da Costa, M. Kashiwagi, and M. H. Mathias, “Rotor failure detection of induction motors by wavelet transform and fourier transform in non-stationary condition,” *Case Studies in Mechanical Systems and Signal Processing*, 2015.
- [91] L. Xiang and A. Hu, “New feature extraction method for the detection of defects in rolling element bearings,” *Journal of Engineering for Gas Turbines and Power*, vol. 134, no. 8, p. 084501, 2012.
- [92] L. Xiang and X. Yan, “A self-adaptive time-frequency analysis method based on local mean decomposition and its application in defect diagnosis,” *Journal of Vibration and Control*, p. 1077546314538992, 2014.
- [93] D. V. Kodavade and S. D. Apte, “A universal object oriented expert system frame work for fault diagnosis,” *International Journal of Intelligence Science*, vol. 2, no. 3, pp. 63–70, 2012.
- [94] X. Peng, Q. Li, and K. Wang, “Fault detection and isolation for self powered neutron detectors based on principal component analysis,” *Annals of Nuclear Energy*, vol. 85, pp. 213 – 219, 2015.
- [95] F. Harrou, M. N. Nounou, H. N. Nounou, and M. Madakyaru, “PLS-based {EWMA} fault detection strategy for process monitoring,” *Journal of Loss Prevention in the Process Industries*, vol. 36, pp. 108 – 119, 2015.

- [96] A. Hyvärinen, J. Karhunen, and E. Oja, *Independent Component Analysis. Adaptive and Cognitive Dynamic Systems: Signal Processing, Learning, Communications and Control*, Wiley, 2004.
- [97] L. Cai, X. Tian, and S. Chen, “A process monitoring method based on noisy independent component analysis,” *Neurocomputing*, vol. 127, pp. 231–246, 2014.
- [98] A. Moosavian, H. Ahmadi, A. Tabatabaeefar, and M. Khazaei, “Comparison of two classifiers; k-nearest neighbor and artificial neural network, for fault diagnosis on a main engine journal-bearing,” *Shock and Vibration*, vol. 20, no. 2, pp. 263–272, 2013.
- [99] A. Moosavian, H. Ahmadi, B. Sakhaei, and R. Labbafi, “Support vector machine and k-nearest neighbour for unbalanced fault detection,” *Journal of Quality in Maintenance Engineering*, vol. 20, no. 1, pp. 65–75, 2014.
- [100] Z. Su, B. Tang, J. Ma, and L. Deng, “Fault diagnosis method based on incremental enhanced supervised locally linear embedding and adaptive nearest neighbor classifier,” *Measurement: Journal of the International Measurement Confederation*, vol. 48, no. 1, pp. 136–148, 2014.
- [101] X. Wang, L. Ma, and T. Wang, “Hybrid PSO based k nearest neighbor classifier for intelligent fault diagnosis,” *International Journal of Applied Mathematics and Statistics*, vol. 48, no. 18, pp. 550–558, 2013.
- [102] X. Liu, L. Bo, and H. Luo, “Bearing faults diagnostics based on hybrid LS-SVM and EMD method,” *Measurement: Journal of the International Measurement Confederation*, vol. 59, pp. 145–166, 2015.
- [103] C. Rajeswari, B. Sathiyabhama, S. Devendiran, and K. Manivannan, “Bearing fault diagnosis using multiclass support vector machine with efficient feature selection methods,” *International Journal of Mechanical and Mechatronics Engineering*, vol. 15, no. 1, pp. 1–12, 2015.
- [104] S. Yin, X. Gao, H. R. Karimi, and X. Zhu, “Study on support vector machine-based fault detection in tennessee eastman process,” *Abstract and Applied Analysis*, vol. 2014, 2014.

- [105] A. Wang, M. Sha, L. Liu, and F. Zhao, "Fault diagnosis of TE process based on ensemble improved binary-tree SVM," pp. 908–912, 2010.
- [106] D. Zhou, H. Zhang, and S. Weng, "A new gas path fault diagnostic method of gas turbine based on support vector machine," *Journal of Engineering for Gas Turbines and Power*, vol. 137, no. 10, 2015.
- [107] N. Pooyan, M. Shahbazian, K. Salahshoor, and M. Hadian, "Simultaneous fault diagnosis using multi class support vector machine in a dew point process," *Journal of Natural Gas Science and Engineering*, vol. 23, pp. 373–379, 2015.
- [108] F. Theljani, K. Laabidi, S. Zidi, and M. Ksouri, "Tennessee eastman process diagnosis based on dynamic classification with SVDD," *Transactions of the ASME Journal of Dynamic Systems, Measurement and Control*, vol. 137, no. 9, 2015.
- [109] Y. Jiang, Y. Wang, and H. Luo, "Fault diagnosis of analog circuit based on a second map SVDD," *Analog Integrated Circuits and Signal Processing*, 2015.
- [110] S. Dash, R. Rengaswamy, and V. Venkatasubramanian, "Fuzzy-logic based trend classification for fault diagnosis of chemical processes," *Computers & Chemical Engineering*, vol. 27, no. 3, pp. 347–362, 2003.
- [111] M. Inacio, A. Lemos, and W. Caminhas, "Fault diagnosis with evolving fuzzy classifier based on clustering algorithm and drift detection," *Mathematical Problems in Engineering*, vol. 2015(2015), p. 14. doi:<http://dx.doi.org/10.1155/2015/368190>.
- [112] C. D. Bocaniala and J. S. da Costa, "A fuzzy classification technique applied to fault diagnosis," in *Computational Intelligence in Fault Diagnosis*, pp. 105–123, Springer, 2006.
- [113] E. Applebaum, "Fuzzy classification for fault isolation in gas turbine engines," in *Joint 9th IFSA World Congress and 20th NAFIPS International Conference*, vol. 1, pp. 292–297, July 2001.
- [114] X. Bian, C. Mou, Z. Yan, and J. Xu, "Reliability analysis of AUV based on fuzzy fault tree," in *International Conference on Mechatronics and Automation*, pp. 438–442, Aug 2009.

- [115] G. C. Silva, R. M. Palhares, and W. M. Caminhas, “Immune inspired fault detection and diagnosis: A fuzzy-based approach of the negative selection algorithm and participatory clustering,” *Expert Systems with Applications*, vol. 39, no. 16, pp. 12474 – 12486, 2012.
- [116] C. A. Laurentys, R. M. Palhares, and W. M. Caminhas, “A novel artificial immune system for fault behavior detection,” *Expert Systems with Applications*, vol. 38, no. 6, pp. 6957 – 6966, 2011.
- [117] C. A. Laurentys, R. M. Palhares, and W. M. Caminhas, “Design of an artificial immune system based on danger model for fault detection,” *Expert Systems with Applications*, vol. 37, no. 7, pp. 5145 – 5152, 2010.
- [118] C. A. Laurentys, G. Ronacher, R. M. Palhares, and W. M. Caminhas, “Design of an artificial immune system for fault detection: A negative selection approach,” *Expert Systems with Applications*, vol. 37, no. 7, pp. 5507 – 5513, 2010.
- [119] M. Blanke, M. Staroswiecki, and N. E. Wu, “Concepts and methods in fault-tolerant control,” in *Proceedings of the American Control Conference*, vol. 4, pp. 2606–2620, IEEE, 2001.
- [120] J. Lunze and J. H. Richter, “Reconfigurable fault-tolerant control: A tutorial introduction,” *European Journal of Control*, vol. 14, no. 5, pp. 359 – 386, 2008.
- [121] Y. Zhang and J. Jiang, “Bibliographical review on reconfigurable fault-tolerant control systems,” *Annual Reviews in Control*, vol. 32, no. 2, pp. 229 – 252, 2008.
- [122] M. Verhaegen, S. Kanev, R. Hallouzi, C. Jones, J. Maciejowski, and H. Smail, “Fault tolerant flight control - a survey,” in *Fault Tolerant Flight Control* (C. Edwards, T. Lombaerts, and H. Smaili, eds.), vol. 399 of *Lecture Notes in Control and Information Sciences*, pp. 47–89, Springer Berlin Heidelberg, 2010.
- [123] J. Aravena, K. Zhou, X. Rong Li, and F. Chowdhury, “Fault tolerant safe flight controller bank,” *Fault Detection, Supervision and Safety of Technical Processes 2006*, vol. 2, pp. 807–812, 2007.
- [124] R. Stengel, “Intelligent failure-tolerant control,” *IEEE Control Systems*, vol. 11, pp. 14–23, June 1991.

- [125] J. Farrell, T. Berger, and B. Appleby, "Using learning techniques to accommodate unanticipated faults," *IEEE Control Systems Magazine*, vol. 13, no. 3, pp. 40–49, 1993.
- [126] W. Yang, K. Y. Lee, S. T. Junker, and H. Ghezel-Ayagh, "Fuzzy fault diagnosis and accommodation system for hybrid fuel-cell/gas-turbine power plant," *IEEE Transactions on Energy Conversion*, vol. 25, pp. 1187–1194, Dec 2010.
- [127] Z. Gao and P. J. Antsaklis, "Stability of the pseudo-inverse method for reconfigurable control systems," *International Journal of Control*, vol. 53, no. 3, pp. 717–729, 1991.
- [128] Z. Gao and P. J. Antsaklis, "Reconfigurable control system design via perfect model following," *International Journal of Control*, vol. 56, no. 4, pp. 783–798, 1992.
- [129] S. Chen, G. Tao, and S. Joshi, "On matching conditions for adaptive state tracking control of systems with actuator failures," *IEEE Transactions on Automatic Control*, vol. 47, pp. 473–478, Mar 2002.
- [130] J. Jiang, "Design of reconfigurable control systems using eigenstructure assignments," *International Journal of Control*, vol. 59, no. 2, pp. 395–410, 1994.
- [131] D. P. Looze, J. L. Weiss, J. S. Eterno, and N. M. Barrett, "An automatic redesign approach for restructurable control systems," *IEEE Control Systems Magazine*, vol. 5, pp. 16–22, May 1985.
- [132] M. J. M and J. C. N, "Mpc fault-tolerant flight control case study: Flight 1862," in *IFAC Safeprocess Conference*, (Washington DC), June 2003.
- [133] J. H. Richter, *Reconfigurable Control of Nonlinear Dynamical Systems: A Fault-hiding Approach*. Lecture Notes in Control and Information Sciences, Springer, 2011.
- [134] N. E. Wu, S. Thavamani, Y. Zhang, and M. Blanke, "Sensor fault masking of a ship propulsion system," *Control Engineering Practice*, vol. 14, no. 11, pp. 1337 – 1345, 2006.
- [135] T. Steffen, *Control Reconfiguration of Dynamical Systems: Linear Approaches and Structural Tests*. Lecture Notes in Control and Information Sciences, New York, 2005.

- [136] J. Lunze, “Control reconfiguration after actuator failures: The generalised virtual actuator,” vol. 6, pp. 1240–1245, 2006.
- [137] A. F. Locatelli and N. L. Schiavoni, “Fault hiding and reliable regulation in control systems subject to polynomial exogenous signals.,” *European Journal of Control*, vol. 16, 2010.
- [138] J. H. Richter, T. Schlage, and J. Lunze, “Control reconfiguration of a thermofluid process by means of a virtual actuator,” *IET Control Theory and Applications*, vol. 1, no. 6, pp. 1606–1620, 2007.
- [139] D. Rotondo, F. Nejjari, and V. Puig, “A virtual actuator and sensor approach for fault tolerant control of lpv systems,” *Journal of Process Control*, vol. 24, no. 3, pp. 203–222, 2014.
- [140] S. De Oca, V. Puig, M. Witczak, and L. Dziekan, “Fault-tolerant control strategy for actuator faults using lpv techniques: Application to a two degree of freedom helicopter,” *International Journal of Applied Mathematics and Computer Science*, vol. 22, no. 1, pp. 161–171, 2012.
- [141] J.-C. Ponsart, D. Theilliol, and C. Aubrun, “Virtual sensors design for active fault tolerant control system applied to a winding machine,” *Control Engineering Practice*, vol. 18, no. 9, pp. 1037–1044, 2010.
- [142] S. M. Tabatabaeipour, J. Stoustrup, and T. Bak, “Fault-tolerant control of discrete-time lpv systems using virtual actuators and sensors,” *International Journal of Robust and Nonlinear Control*, vol. 25, no. 5, pp. 707–734, 2015.
- [143] J. H. Richter, W. Heemels, N. Van De Wouw, and J. Lunze, “Reconfigurable control of piecewise affine systems with actuator and sensor faults: Stability and tracking,” *Automatica*, vol. 47, no. 4, pp. 678–691, 2011.
- [144] J. H. Richter, W. Heemels, N. Van De Wouw, and J. Lunze, “Reconfigurable control of PWA systems with actuator and sensor faults: stability,” in *Proceedings of the IEEE Conference on Decision and Control*, pp. 1060–1065, 2008.

- [145] T. Wittmann, J. H. Richter, and T. Moor, “Fault-hiding control reconfiguration for a class of discrete event systems,” vol. 4, pp. 49–54, 2013.
- [146] J. H. Richter and J. Lunze, “Reconfigurable control of hammerstein systems after actuator failures: Stability, tracking, and performance,” *International Journal of Control*, vol. 83, no. 8, pp. 1612–1630, 2010.
- [147] J. H. Richter, M. M. Seron, and J. A. De Doná, “Virtual actuator for lure systems with lipschitz-continuous nonlinearity,” in *IFAC Proceedings Volumes (IFAC-PapersOnline)*, vol. 8, pp. 222–227, 2012.
- [148] A. M. Amani, A. Afshar, and M.-B. Menhaj, “Fault tolerant control of networked control system in presence of actuator failure using predictive reconfiguration,” in *IEEE International Conference on Control and Automation*, pp. 477–482, Dec 2009.