## Maicon Melo Alves

## Delphos: Sistema de Predição de Danos para Aerogeradores usando Redes de Sensores e Atuadores sem Fio

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Informática, Universidade Federal do Rio de Janeiro, como requisito parcial à obtenção do título de Mestre em Informática

Orientadoras: Luci Pirmez, Dsc. Silvana Rossetto, Dsc.

> Rio de Janeiro 2012

S171 Alves, Maicon Melo

Delphos: Sistema de Predição de Danos para Aerogeradores usando Redes de Sensores e Atuadores sem Fio / Maicon Melo Alves. – 2012. 98 f.: il.

Dissertação (Mestrado em Informática) – Universidade Federal do Rio de Janeiro, Instituto de Matemática, Núcleo de Computação Eletrônica, 2012.

Orientadoras: Luci Pirmez ; Silvana Rossetto

 Rede de Sensores Sem Fio (Teses). – 2. Sistema de Predição de Dano (Teses). –
Modelo para Análise de Séries Temporais ARMA (Teses). 4. Sistema Híbrido de Redes Neurais e Lógica Nebulosa – I. Luci Pirmez (Orient.). II. Silvana Rossetto (Orient.). III. Universidade Federal do Rio de Janeiro, Instituto de Matemática, Núcleo de Computação Eletrônica. IV. Título.

CDD.

## Maicon Melo Alves

Delphos: Sistema de Predição de Danos para Aerogeradores usando Redes de Sensores e Atuadores sem Fio

> Dissertação de Mestrado submetida ao Corpo Docente do Programa de Pós-Graduação em Informática da Universidade Federal do Rio de Janeiro e à banca externa convidada como parte dos requisitos necessários para obtenção do título de Mestre em Informática.

Aprovada em: Rio de Janeiro 11 de albril de2012.

Prof<sup>a</sup>. Luci Pirmez – Orientadora D.Sc., COPPE/UFRJ, Brasil UFRJ/PPGI

Prof<sup>a</sup>. Silvana Rossetto – Orientadora D.Sc., PUC-RIO, Brasil UFRJ/PPGI

Prof<sup>a</sup>. Flávia Coimbra Delicato D.Sc., COPPE/UFRJ, Brasil UFRJ/PPGI

Prof. Célio Vinicius Neves de Albuquerque Ph. D., University of California, EUA UFF/IC

noemikodrigues

Prof<sup>ª</sup>. Noemi de La Rocque Rodriguez D.Sc., PUC-RIO, Brasil PUC-RIO/DI

Rio de Janeiro 2012

Dedico esse trabalho a minha amada esposa Cristiane. Minha vida sem você não faz sentido. Também dedico a minha filha Giovana que, além de ser a princesa mais linda do mundo, é um verdadeiro presente de Deus.

#### AGRADECIMENTOS

Ao Senhor Deus por ter permitido que eu alcançasse mais esse sonho, me mantendo forte e determinado nos momentos mais difíceis ao longo desta caminhada.

Além de dedicar esse trabalho, também gostaria agradecer a minha esposa Cristiane. Esse sonho não seria possível sem tudo o que você fez por mim durante todo esse tempo. Obrigado por estar sempre ao meu lado. Te amo.

A minha mãe, irmã Karoline e irmão Johny. Vocês são a minha base e força. Também agradeço ao meu pai.

Aos meus familiares, tios, tias, cunhados, cunhadas, primos, primas, sobrinhos e afilhado. Vocês são minha alegria de viver.

Aos colegas do Laboratório de Redes sem Fio e Multimídia (LabNet) da UFRJ, Érico, Joffre, Tiago, Hélio, Paula, Renato, Rafael e Humberto. Foi muito bom conviver com vocês ao longo destes dois anos. Obrigado por terem proporcionado um ambiente saudável e descontraído, mas ao mesmo tempo disciplinado. Aprendi muito com vocês.

Em especial aos colegas do LabNet Igor, Henrique, Cláudio e Sandro. Ao Igor, por toda a ajuda dispensada e constante disponibilidade ao longo destes dois anos. Ao Henrique, por termos dividido vários trabalhos e dificuldades ao longo dessa jornada. Ao Cláudio, por todo interesse em ajudar a mim e a todos os membros do LabNet. Ao Sandro, agradeço por todos os momentos que dividimos as dificuldades e os desafios durante as disciplinas e a pesquisa de tese. Posso dizer que essa caminhada foi mais fácil devido ao seu auxílio e presença.

Aos professores do PPGI pelas orientações e ensinamentos e, em especial, a professora Flávia Delicato pelas correções e revisões dos trabalhos. Professora, a sua ajuda foi fundamental para o meu sucesso.

A minha co-orientadora Silvana Rossetto por sua disponibilidade em ensinar, sempre com paciência e dedicação. Muito obrigado pelos seus ensinamentos e por suas tão valiosas dicas. Seu bom senso e sua visão apurada permitiram construir um trabalho do qual me orgulho muito.

A minha orientadora Luci Pirmez por primeiramente ter acreditado no meu potencial e ter me aceitado no programa. Agradeço por todos os momentos em que Sra. se dispôs a me ajudar, me ensinando e me mostrando o caminho a seguir durante estes dois anos. Sinto-me honrado por ter sido orientado por uma das professoras mais bem conceituadas na área de Redes de Computadores. Muito obrigado mesmo e faço votos para que possamos voltar a trabalhar juntos em breve.

Aos colegas da Petrobras, especialmente Rafael, Janssen e Habacuque. Obrigado por terem segurado as pontas nos momentos em que estive ausente.

Na Petrobras, gostaria de agradecer ao meu líder de equipe Cleber, ao meu coordenador na Jamyl e ao meu ex-gerente Simonides. Ao Cleber e ao Jamyl, por terem sempre confiado na minha ética e terem compreendido os momentos em que não pude estar presente nas atividades cotidianas da empresa. Ao Simonides (e também ao Jamyl), por ter aprovado a minha participação no programa de pós graduação da empresa.

A Petrobras pelo incentivo na carreira. Como brasileiro, sinto um imenso orgulho de trabalhar nessa empresa.

"A mente é minha arma. E uma mente necessita de livros da mesma forma que uma espada necessita de uma pedra de amolar se quisermos que se mantenha afiada". Tyrion Lannister Personagem do livro "Songs of Ice and Fire" do autor George R. R. Martin.

## RESUMO

ALVES, Maicon Melo. Delphos: Sistema de Predição de Danos para Aerogeradores usando Redes de Sensores e Atuadores sem Fio. Rio de Janeiro, 2012. Dissertação (Mestrado em Informática) - Programa de Pós-Graduação em Informática, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2012.

Esse trabalho propõe um sistema de predição de danos para aerogeradores, denominado Delphos. Trata-se de um sistema descentralizado, construído a partir de uma rede de sensores e atuadores sem fio, onde todo o processo decisório é executado dentro da própria rede. O objetivo do Delphos é predizer quando o aerogerador irá se apresentar em um estado de dano e atuar em sua operação a fim de evitar acidentes, reduzir os custos de manutenção e impedir que ocorram atrasos na geração de energia. Para isso, o Delphos utiliza um modelo para previsão de séries temporais, denominado ARMA, e um sistema nebuloso capaz de eliminar a influência da temperatura no processo de predição de danos

Palavras-chave: Rede de Sensores e Atuadores Sem Fio. Monitoramento de Estruturas. Predição de Danos. Modelo para Previsão de Séries Temporais ARMA. Sistema Híbrido de Redes Neurais e Lógica Nebulosa (ANFIS)

## ABSTRACT

ALVES, Maicon Melo. Delphos: Sistema de Predição de Danos para Aerogeradores usando Redes de Sensores e Atuadores sem Fio. Rio de Janeiro, 2012. Dissertação (Mestrado em Informática) - Programa de Pós-Graduação em Informática, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2012.

This work proposes a damage prediction system for wind turbines. The system, called Delphos, is a decentralized system, built from a wireless sensor and actuator network, where all decision-making process is performed within the network. The purpose of Delphos is to predict when the turbine will reach a damage state in order to act in its operation to prevent accidents, reducing maintenance costs and delays in the power generation. Delphos relies on a time series forecasting model, called ARMA, and a fuzzy system to eliminate the influence of temperature in the process of damage prediction.

Keywords: Wireless Sensor and Actuator Networks. Structural Health Monitoring. Failure Prediction. ARMA Model. Neuro Fuzzy Inference System (ANFIS).

## LISTA DE FIGURAS

Figura 1.(a) Mote MICAz (b) e Placa MDA100	21
Figura 2. Pilha de protocolos de nós da RSSF	21
Figura 3. Topologia básica de uma RSSF	23
Figura 4. (a) Dados de vibração e (b) Espectro de força	25
Figura 5. Resultado gerado pelo processo de Curve Fitting	26
Figura 6. Modelo Sugeno de primeira ordem com duas regras SE-ENTAO	29
Figura 7. Arquitetura ANFIS para as duas regras	29
Figura 8. Exemplo de série temporal não-estacionária	32
Figura 9. Exemplo de série temporal sazonal	32
Figura 10. Origem e horizonte em uma série temporal	33
Figura 11. Etapas para construção de modelos ARMA	36
Figura 12. Arquitetura lógica do sistema Delphos	44
Figura 13. Diagrama de seqüência da fase de Decisão de Anormalidade	47
Figura 14. Diagrama de seqüência da etapa de Predição de Danos	49
Figura 15. Diagrama de seqüência da fase de Reação	54
Figura 16. Correlogramas das Funções de Autocorrelação (ACF) e Autocorrelação Pa (PACF)	arcial 59
Figura 17. Correlogramas das Funções de Autocorrelação (ACF) e Autocorrelação Pa (PACF) para a primeira diferenciação da série	arcial 60
Figura 18. Correlogramas dos resíduos do modelo estimado	62
Figura 19. Exemplos de Evolução de Dano e sem Dano	68
Figura 20. Cenário de RASSF contendo seis nós sensores	70
Figura 21. Curvas ROC para Margem de Erro igual a 2	75
Figura 22. Curvas ROC para Margem de Erro igual a 3	76
Figura 23. Total de verdadeiros para número de sensores igual a 6	78
Figura 24. Total de verdadeiros para a distribuição de amostras 50%-50%	79
Figura 25. Total de verdadeiros para número de sensores igual a 6	82
Figura 26. Resultado dos Experimentos A e B para número de sensores igual a 6	83
Figura 27. Tempo de resposta do Delphos para realizar atuação no aerogerador	85
Figura 28. Maior consumo de energia para as abordagens centralizada e descentralizada	86
Figura 29. Avaliação do consumo de memória	87
Figura 30. Tempo de vida da RASSF	90
Figura 31. Comparativo entre os resultados do experimento usando sensores reais com experimento de eficiência A	e do 91
Figura 32. Comparativo entre o Delphos e o sistema de Kusiak e Li (KUSIAK e LI 2010)	93

## LISTA DE TABELAS

Tabela 1. Configurações de parâmetros que apresentaram menores erros	56
Tabela 2. Resultados dos critérios AIC, BIC e HQC	61
Tabela 3. Frequências obtidas no experimento de coleta de dados de vibração	66
Tabela 4. Resultados da calibração para o Experimento A	74
Tabela 5. Resultados do Experimento A para RASSF composta por 6 sensores	76
Tabela 6. Resultados da calibração para o Experimento B	80
Tabela 7. Resultados do Experimento B para RASSF composta por 6 sensores	81

### LISTA DE ABREVIATURAS E SIGLAS

- ACF Autocorrelation Function
- AIC Akaike Information Criterion
- ANFIS Adaptive Neuro-Fuzzy Inference System
- AR AutoRegressive
- ARMA Auto-Regressive Moving Averages
- ARIMA Auto-Regressive Integrated Moving Averages
- BIC Schwarz Bayesian Criterion
- DLAC Damage Localization Assurance Criterion
- FAC Função de Autocorrelação
- FACP Função de Autocorrelação Parcial
- FFT Fast Fourier Transform
- FN Falso Negativo
- FP Falso Positivo
- GARCH Generalized Autoregressive Conditional Heteroskedasticity
- GPL Gnu Public License
- HP Horizonte de Previsão
- HQC Hannan–Quinn Information Criterion
- iNCE Instituto Tércio Pacitti de Aplicações e Pesquisas Computacionais
- LABNET Laboratório de Redes e Multimídia
- LTS Lightweight Tree-based Synchronization
- MA *Moving Averages*
- ME Margem de Erro
- MEMS Sistemas micro eletro-mecânicos
- MMS Média Móvel Simples
- NARX Nonlinear Autoregressive with Exogenous Input
- PACF Partial Autocorrelation Function

- PSD Power Spectrum Density
- RAM Random Access Memory
- RASSF Rede de Sensores e Atuadores sem Fio
- **RBS** Reference Broadcast Syncronization
- **ROC** *Receiver Operating Characteristics*
- ROM Read Only Memory
- RSSF Rede de Sensores sem Fio
- SARMA Sazonal Auto-Regressive Moving Averages
- SCADA Supervisory Control and Data Aquisition
- SES Suavização Exponencial Simples
- SHM Structural Health Monitoring
- TPSN Timing-sync Protocol for Sensor Networks
- UFRJ Universidade Federal do Rio de Janeiro
- VARMA Vector Auto-Regressive Moving Averages
- VN Verdadeiro Negativo
- VP Verdadeiro Positivo

# Sumário

1	Intr	rodução	15
2	Cor	nceitos Básicos	20
	2.1	Redes de Sensores e Atuadores sem Fio	20
	2.2	Monitoramento de Estruturas Civis	23
	2.2	.1 Detecção de Danos em Estruturas Civis	25
	2.3	Adaptive Neuro Fuzzy Inference System (ANFIS)	27
	2.4	Predição de Séries Temporais	31
3	Tra	balhos Relacionados	38
4	Del	lphos: Sistema de Predição de Danos Neuro-Fuzzy para RASSF	42
	4.1	Arquitetura Lógica	42
	4.2	Arquitetura Física	45
	4.3	Operação do Sistema	45
	4.3	.1 Fase de Decisão de Anormalidade	46
	4.3	.2 Fase de Predição de Dano	48
	4.3	.3 Fase de Colaboração	49
	4.3	.4 Fase de Reação	53
5	Eta	pas de Pré-implantação do Delphos	55
	5.1	Treinamento do ANFIS	55
	5.2	Estimação do Modelo ARMA	56
	5.2	.1 Definição de Evolução de Dano	57
	5.2	.2 Processo de Estimação do Modelo ARMA	58
6	Exp	perimentos Realizados com o Delphos	63
	6.1	Limitações do Ambiente do Experimento de Coleta de Dados de Vibração	63
	6.1	.1 Inserção Artificial de Dano	64
	6.1. Col	.2 Simulação da Influência da Temperatura sobre as Frequências N letadas	Vaturais 64
	6.1	.3 Simulação de Evolução de Dano Real	65
	6.2	Experimentos Realizados para a Coleta de Dados de Vibração	65
	6.3	Definição da Base de Dados de Experimentos	67
	6.4	Cenário dos Experimentos	69
	6.5	Descrição das Métricas	70
	6.6	Configuração do Ambiente dos Experimentos	72
	6.7 (Expe	Experimentos de Eficiência do Delphos Considerando a Interferência An erimento A)	nbiental 73
	6.7	.1 Calibração do Delphos para o Experimento A	73

6.7	7.2 Experimento de Avaliação de Eficiência do Delphos (Experimento A)	76
6.8 (Expe	Experimentos de Eficiência Não Considerando a Interferência Ambi erimento B)	ental 80
6.8	8.1 Calibração do Delphos para o Experimento B	80
6.8	8.2 Experimento de Avaliação de Eficiência do Delphos (Experimento B)	81
6.9	Comparação Entre os Experimentos de Eficiência A e B	83
6.10	Experimentos para Avaliar o Ganho da Descentralização	84
6.11	Experimentos de Impacto do Delphos na RASSF	86
6.1	11.1 Avaliação da Quantidade de Memória Utilizada pelo Delphos	87
6.1	11.2 Experimentos para Avaliação do Tempo de Vida da Rede	88
6.12	Experimentos para Avaliação da Eficiência do Delphos usando Sensores Reais	90
6.13	Comparação entre os Resultados de Eficiência do Delphos e de Outro Sistema	91
7 Co	onclusões	94
7.1	Trabalhos Futuros	96
8 Re	eferências	98

## 1 Introdução

O esgotamento das reservas de hidrocarbonetos frente à crescente demanda mundial por energia e o problema de aquecimento global agravado pelo uso de combustíveis fósseis geram consequências políticas e sociais que demandam a busca por fontes de energia renováveis. Nesse cenário, a *energia eólica* tem sido apontada como sendo uma fonte de energia renovável bastante atrativa, pois apresenta características positivas como maturidade tecnológica, custos relativamente competitivos e uma política de incentivos adotada por nações em várias partes do globo. Os ventos movimentam pás gigantes em equipamentos denominados **aerogeradores** que são responsáveis por efetuar a conversão da energia cinética de translação em energia cinética de rotação. Esses equipamentos têm experimentado significativos avanços tecnológicos, tais como, uma maior aerodinâmica das pás e melhor operação das turbinas, que reduzem consideravelmente seus custos, eliminando um dos principais entraves ao aproveitamento comercial da energia eólica.

Todavia, apesar desses avanços tecnológicos, ainda existem diversos desafios que precisam ser superados ao empregar aerogeradores. Entre esses desafios está a capacidade de identificar a presença de alterações estruturais que afetam adversamente a integridade da estrutura, podendo causar danos no futuro. Os componentes dos aerogeradores (geradores, engrenagens e pás dos rotores) têm sido historicamente propensos a danos, sendo registrados em média de dois a três incidentes por ano para um único aerogerador (SWARTZ *et al.* 2008).

Nesse contexto, torna-se recomendável o uso de sistemas automáticos capazes de identificar com antecedência a ocorrência de danos nos aerogeradores e antecipar ações de controle. Os sistemas de monitoramento de integridade de estruturas civis (SHM, do inglês *Structural Health Monitoring*) permitem detectar, localizar e predizer danos nas estruturas a fim de evitar acidentes como, por exemplo, o colapso total da estrutura (FARRAR *et al.* 2003). Em particular, o uso de técnicas de **predição de danos** em aerogeradores tem potencial para permitir: (i) preparar antecipadamente recursos necessários para o processo de manutenção; (ii) minimizar substituições desnecessárias de componentes; e (iii) evitar a parada brusca do equipamento.

A abordagem tradicional de monitoramento dos aerogeradores requer inspeções presenciais que possuem um alto custo. Uma alternativa é a utilização de sistemas compostos por sensores inteligentes que são dispositivos providos de recursos de processamento, armazenamento e comunicação sem fio. A capacidade de comunicação permite que os nós sensores sejam agrupados e dêem origem a uma Rede de Sensores sem Fio (RSSF) (AKYILDIZ e VURAN 2010). Os dispositivos de sensoriamento normalmente utilizados em RSSFs para aplicações de SHM são, entre outros, sensores de umidade, de temperatura e acelerômetros. Os acelerômetros são usados para obter informações de vibração que permitem extrair as **frequências naturais** da estrutura a fim de identificar alterações estruturais que denotem a presença de dano (WALFORD e ROBERTS 2006). Utilizar um sistema de monitoramento automatizado e periódico para os aerogeradores pode efetivamente contribuir para: (i) melhorar a segurança na usina eólica; (ii) minimizar o tempo de *downtime*; e (iii) gerar energia de forma mais confiável e economicamente eficaz (CIANG *et al.* 2008).

Apesar da crescente aplicação das RSSF em diversas áreas, os sensores são dispositivos passivos e altamente limitados em termos de fonte de energia e capacidade de processamento, armazenamento e comunicação, os quais basicamente coletam e disseminam dados, mas não atuam no ambiente. Por outro lado, as Redes de Atuadores e Sensores sem Fio (RASSF) incluem dispositivos atuadores capazes de tomar decisões e executar ações no ambiente físico em resposta a situações interpretadas pelos sensores. Assim, é possível dentro da própria rede obter informações sobre a saúde da estrutura e executar ações de manutenção preditiva.

Entretanto, o uso de RASSFs como infra-estrutura para monitorar aerogeradores e atuar como ferramenta de controle acabou gerando uma série de novos desafios. Entre esses desafios está a necessidade de adaptar técnicas de processamento de sinais usadas em SHM ou de métodos de inteligência computacional ou estatística de acordo com as limitações dos recursos dos nós da RASSF, ou seja, é necessário ajustar tais procedimentos para que possam ser executados nos nós sem que haja prejuízo quanto ao resultado final. Outro desafio importante está relacionado ao desenvolvimento de mecanismos descentralizados capazes de predizer danos em usinas eólicas de forma precisa e confiável, permitindo que a tomada de decisão e a execução de medidas de controle sejam efetuadas dentro da própria rede (*in-network processing*) (TIAN e EKICI 2007).

Diante desses desafios, esse trabalho apresenta a proposta de um sistema **descentralizado**, denominado **Delphos**, que faz uso de RASSF para efetuar o monitoramento automatizado e remoto de aerogeradores, a fim de predizer danos e executar ações antecipadas de controle como, por exemplo, o desligamento emergencial do equipamento. O Delphos é considerado descentralizado porque o processo decisório de predição de dano é executado dentro da rede por todos os seus nós, e não apenas em um nó centralizador. A principal vantagem de se executar um processamento dentro da rede (*in-network processing*)

é a possibilidade de atuar na operação do equipamento (através de dispositivos atuadores), já que o sistema fornece seus resultados com **maior agilidade**. No caso dos aerogeradores, a atuação pode consistir em diminuir a rotação das pás ou efetuar um controle para que o equipamento entre em funcionamento apenas em horários determinados. Como consequência do Delphos ser um mecanismo de predição descentralizado, é possível de acordo com os experimentos realizados, obter uma maior economia de energia e aumento de vida útil da RSSF, já que o número de transmissões diminui se comparado com um mecanismo de predição centralizado.

A fim de aumentar a confiabilidade do processo de predição, os nós da RASSF **colaboram** entre si a fim com a finalidade de alcançar um único resultado de predição. Este processo de colaboração permite aumentar a confiabilidade do processo de predição, pois as condições da pá são observadas sob diferentes perspectivas ou ângulos de acordo com cada um dos sensores dispostos na pá. Outra questão é que a redundância dos nós sensores inseridos na pá fornecem plenas condições de executar técnicas de tolerância a falhas

Para realizar a predição de danos, o sistema proposto utiliza um modelo estatístico para análise de séries temporais denominado modelo de Auto-regressão e Médias Móveis (ARMA) (MORETTIN e TOLOI 2006) (BOX *et al.* 1994) cuja finalidade é predizer valores relacionados às frequências naturais da estrutura. Outro método como a classificação Bayesiana ou árvore de decisão poderia ser usado para realizar a predição de dano (SALFNER *et al.* 2010). No entanto, optou-se por um modelo estatístico, pois o mecanismo de predição de dano precisa utilizar técnicas/métodos computacionalmente viáveis do ponto de vista dos recursos computacionais presentes nos nós sensores de uma RASSF. O ARMA foi escolhido porque realiza um cálculo de baixa complexidade, baseado em coeficientes préidentificados (definidos por um processo que pode ser executado fora da rede, poupando recursos dos nós sensores).

Vários trabalhos, incluindo Xia *et al.* (XIA *et al.* 2006), Moser e Moaveni (MOSER E MOAVENI 2011) e Liu e Dewolf (LIU e DEWOLF 2007) demonstram que a frequência natural pode sofrer variações ao ser influenciada pela temperatura. Essas variações envolvem o aumento ou a diminuição das frequências naturais da estrutura que são as informações primárias e mais utilizadas para se identificar alterações significativas no estado físico da estrutura (SALAWU 1997).

Portanto, é possível **aumentar a acurácia** do Delphos ao levar em conta a influência que a temperatura exerce sobre as frequências naturais, pois ao eliminar essa influência o

sistema analisa dados que permitem tornar mais confiável o entendimento sobre o estado da estrutura, refletindo diretamente na qualidade e eficiência do processo de predição de danos. Para eliminar essa influência, o Delphos executa um filtro de interferências ambientais, **onde este** filtro é aplicado antes da predição de valores de frequência para que seja possível analisá-las sem a influência da temperatura. Para realizar esse filtro é utilizado um sistema de Lógica Nebulosa automaticamente gerado através do Adaptive Neuro Fuzzy Inference System (ANFIS) que é um sistema híbrido de Redes Neurais e Lógica Nebulosa (KURIAN et al. 2006). De forma geral, o ANFIS utiliza uma base de dados e um algoritmo de treinamento para gerar um sistema nebuloso completo do tipo Sugeno. A escolha pelo emprego do ANFIS se deve a dois fatores. Em primeiro lugar, a utilização de Redes Neurais permite identificar a partir de dados reais, a função que relaciona a temperatura e a sua influência sobre frequências naturais. Sendo assim, as próprias informações contidas na base de dados revelam essa relação de influência, não tendo a necessidade de contar com o conhecimento de um especialista. O outro fator está relacionado com a adoção de uma abordagem baseada em Lógica Nebulosa, a qual permite lidar mais apropriadamente com informações imprecisas, tais como os conceitos de muito, médio e pouco que estão associados à interferência da temperatura nos valores de frequência natural.

Enfim, as contribuições desse trabalho estão relacionadas (i) a concepção do processo decisório de predição de danos de forma descentralizada a fim de fornecer uma resposta mais ágil para que ações de controle possam ser executadas no aerogerador, (ii) correlação de variáveis ambientais com a finalidade de aumentar a acurácia do processo de predição e (iii) a cooperação dos nós da RASSF com a finalidade de aumentar a confiabilidade da resposta dada pelo sistema proposto.

A RASSF utilizada neste trabalho é composta por nós sensores, um nó sorvedouro e um atuador. O processo de predição de danos (leitura dos sensores, filtro de interferências ambientais e cálculo da série temporal) é executado em todos os nós sensores da RASSF e, ao término de cada etapa de predição, os sensores trocam seus resultados para confirmar as predições. No caso de iminência de dano, a rede envia sinais de alerta para o nó sorvedouro ou comandos para o atuador para que esse realize ações de controle no ambiente.

O restante desse trabalho está organizado da seguinte forma. No Capítulo 2 apresenta-se os conceitos básicos relacionados com esse trabalho. No Capítulo 3 são destacados os trabalhos relacionados. No Capítulo 4 é apresentada a arquitetura computacional do sistema de predição de danos proposto. O Capítulo 5 descreve as etapas de pré-implantação do

Delphos. O Capítulo 6 apresenta os experimentos efetuados com esse sistema. Por fim, o Capítulo 7 apresenta as conclusões finais e os trabalhos futuros.

### 2 Conceitos Básicos

Nesta seção são descritos os conceitos básicos que sustentam os temas abordados e são necessários para o entendimento do trabalho proposto.

Portanto, inicialmente são apresentados os conceitos de Redes de Sensores e Atuadores sem Fio, descrevendo sua topologia básica e os dispositivos usados nesta rede. Posteriormente, são descritos os conceitos relacionados ao monitoramento de estruturas e ao processo de detecção de danos que servem de base para compor o processo de predição de dano. Em seguida, são apresentadas as definições do ANFIS (*Adaptive Neuro Fuzzy Inference System*) que será usado para criar o sistema nebuloso responsável por efetuar o filtro de interferências ambientais. Por último, são descritos os conceitos de predição de séries temporais, apresentando o modelo ARMA (*Autoregressive Moving Averages*) que é o aparato estatístico usado para realizar efetivamente a predição de dano.

#### 2.1 Redes de Sensores e Atuadores sem Fio

Com os avanços recentes em tecnologias de *sistemas micro eletro-mecânicos* (MEMS) foi possível criar pequenos dispositivos de baixo custo, baixo consumo de energia, providos de comunicação sem fio, e capazes de monitorar grandezas físicas e realizar processamento computacional. O uso conjunto de uma grande quantidade desses dispositivos formam as Redes de Sensores Sem Fio (RSSFs) (AKYILDIZ e VURAN 2010).

As RSSFs apresentam grande potencial de aplicabilidade em diversos cenários, como em ambientes militares, na pesquisa e vigilância de desastres naturais e na exploração de locais de difícil acesso (eg., desertos, áreas montanhosas, vulcões, etc.). Na área militar, as RSSFs podem ser usadas para detectar e acompanhar a movimentação de um intruso. Em ambientes naturais, as RSSFs podem ser utilizadas para monitorar diversas grandezas físicas e tentar prever a ocorrência de desastres naturais (terremotos, tsunamis e erupções de vulcões). Enfim, as RSSFs possuem ampla aplicabilidade nas mais diversas áreas (YICK *et al.* 2008).

Os nós que formam as RSSFs (denominados *motes*) consistem tipicamente de um micro-controlador, uma unidade de memória, uma fonte de energia, um *transceiver* e uma ou mais placas de sensoriamento (GETACHEW e MITIKU 2011). Uma grande variedade de plataformas vem sendo desenvolvidas, como o SunSPOT da Sun, e os dispositivos da família MICA (AKYILDIZ e VURAN 2010). A Figura 1(a) apresenta o modelo MICAz da família MICA, plataforma desenvolvida pela empresa Crossbow. A Figura 1(b) mostra um exemplo

de placa de sensoriamento, chamada MDA100, que pode ser acoplada à plataforma MICAz, sendo capaz de medir temperatura e luminosidade.



## Figura 1.(a) Mote MICAz (b) e Placa MDA100

Diferente das redes tradicionais, as RSSFs possuem suas próprias características e limitações. Quantidade de energia limitada, curto alcance de comunicação, pequena banda passante, recursos de processamento e armazenamento extremamente moderados são exemplos de limitações presentes em cada um dos nós sensores de uma RSSF (YICK *et al.* 2008). Essas premissas imprimem uma série de desafios quanto ao desenvolvimento de aplicações, protocolos e serviços para essas redes, os quais devem apresentar um baixo custo computacional para que possam ser executados adequadamente nestes dispositivos (YICK *et al.* 2008).





Além do requisito de simplicidade em relação à dependência de recursos computacionais, o *software* criado para ser executado nos nós da rede deve sempre minimizar o consumo de energia, já que os nós são dotados de baterias com carga finita e, portanto, precisam estender ao máximo a sua vida útil. Portanto, enquanto protocolos e aplicações de redes tradicionais primam pelo desempenho, os protocolos das RSSF visam executar suas

atividades com mínimo de energia possível (AKYILDIZ e VURAN 2010). A pilha de protocolos utilizada pelos nós da RSSF está descrita na Figura 2.

A Figura 2 possui duas perspectivas diferentes: uma relacionada aos protocolos comuns de comunicação em rede (blocos horizontais) e a segunda diz respeito aos planos que permitem gerenciar o nó e executar tarefas em conjunto (blocos verticais) (DELICATO 2005).

Os nós sensores dispõem de hardware para comunicação sem fio e as camadas física e de enlace são responsáveis por criar o nível de abstração adequado para as camadas superiores. A camada de rede é utiliza para efetuar o roteamento das informações dentro da própria rede. Nas RSSF não há uma concepção de diferentes redes, mas mesmo assim ainda há a necessidade de se efetuar o roteamento ou repasse de mensagens ou pacotes. Isso acontece devido à limitação física do equipamento de comunicação presente nos nós sensores que pode não ser capaz de alcançar outro nó um pouco mais distante. A camada de transporte é capaz de prover através dos seus protocolos, um fluxo constante de dados entre a origem e o destino. Esse recurso só é utilizado quando a aplicação da rede necessita de tal fluxo. Por questões de limitação de energia, nem sempre o estabelecimento desse fluxo é executado. As RSSF geralmente não são criadas ou implantadas pensando em um propósito geral, mas são preparadas para executar uma aplicação específica. Conseqüentemente, os protocolos de aplicação são desenvolvidos levando-se em conta a finalidade da rede. No entanto, existem outros protocolos dessa camada que são utilizados para dar suporte ao funcionamento de uma RSSF. Como exemplo, pode-se citar os protocolos de sincronização como o Reference Broadcast Syncronization (RBS) ou o Lightweight Tree-based Synchronization (LTS) que são usados para prover a sincronização entre os nós (SIVRIKAYA e YENER 2004).

Os blocos verticais representam os planos de gerenciamento presentes em cada nó sensor. O plano de gerenciamento de tarefas é capaz de coordenar a execução de tarefas em conjunto para que apenas alguns nós realizem, por exemplo, a tarefa de sensoriamento enquanto os outros apenas são usados para realizar o roteamento. Já o plano de gerenciamento da mobilidade pode ser usado para obter informações sobre os nós vizinhos presentes em uma determinada área. Por último, o plano de gerenciamento de energia tem como função efetuar a propagação de informações que ajudem um determinado nó a reduzir o seu consumo de energia (DELICATO 2005).

De forma geral, apenas dois elementos compõem uma rede de sensores sem fio: nós sensores comuns e um nó especial chamado de sorvedouro, mais comumente referenciado

pelo termo em inglês *sink*. Os nós comuns são responsáveis por efetuar todo o sensoriamento e repasse de informações até o *sink*. Essa descrição pode ser visualizada na Figura 3.



Figura 3. Topologia básica de uma RSSF

O *sink* não apresenta as mesmas limitações dos nós sensores comuns e, geralmente, possui conectividade com outra rede como, por exemplo, a Internet. A maneira como os dados coletados na rede são entregues ao *sink* segue um modelo denominado por **modelo de entrega de dados**. As RSSFs podem utilizar diversos modelos de entrega de dados como as entregas (i) contínua, (ii) dirigidas a eventos, (iii) iniciadas pelo observador ou (iv) híbridas. O modelo de entrega contínua constitui no envio periódico de dados para o *sink*. Já o modelo dirigido a eventos, tem como premissa o fato de que o *sink* só receba dados mediante a ocorrência de um evento pré-estabelecido. O modelo de entrega iniciada pelo observador permite que o usuário coordene o processo de entrega de dados. Por fim, o modelo híbrido pode ser usado quando se deseja unir as características dos demais modelos (DELICATO 2005).

### 2.2 Monitoramento de Estruturas Civis

Estruturas físicas depois de construídas podem sofrer ações oriundas de intempéries, como o vento e a chuva, e apresentar danos ao longo do tempo que nem sempre são facilmente identificados diante de uma análise a olho nu. Por esse motivo, é preciso dispor de instrumentos de medição e técnicas capazes de fornecer informações mais precisas sobre o estado atual de uma estrutura civil.

A finalidade dos Sistemas de Monitoramento de Estruturas Civis (SHM, do inglês *Structural Health Monitoring*) consiste na observação de uma estrutura ao longo do tempo a fim de executar medições, extrair características dessas medições e, por fim, efetuar análises estatísticas sobre as características obtidas com o objetivo de determinar o atual estado da estrutura (FARRAR e WORDEN 2007).

O processo, ou sistema de SHM, busca por evidências na estrutura que corroborem sobre uma alteração em seu equilíbrio funcional. Essas evidências, denominadas por dano, podem ser definidas como mudanças introduzidas em uma estrutura que adversamente afeta o seu desempenho atual ou futuro. Para identificar danos em uma estrutura é preciso que seja efetuada uma comparação do seu estado atual com um estado considerado como saudável. O estado inicial é, por diversas vezes, considerado como um estado em que a estrutura ainda não apresenta danos e, neste caso, o estado inicial se insere no sistema de monitoramento como uma assinatura que define a salubridade da estrutura (FARRAR e WORDEN 2007).

Uma das principais motivações para se utilizar um processo de SHM é a melhoria na execução de processos de manutenção e inspeção (FARRAR e WORDEN 2007). Dessa forma, procura-se estabelecer um processo de SHM para que as manutenções possam ser efetuadas antes que se acumule uma série de danos até o ponto em que a estrutura entre em colapso, ou seja, que se apresente em um estágio de total inoperabilidade e insegurança.

Os paradigmas de manutenção mais comuns são a manutenção corretiva, a preventiva e a preditiva. A **manutenção corretiva**, que é considerada como uma abordagem mais antiga (JARDINE *et al.* 2006), visa substituir componentes de uma estrutura quando esses já apresentam danos. Esse tipo de manutenção também é conhecida pelo termo em inglês *run-to-failure*, ou seja, o equipamento ou estrutura executa seu procedimento normal (*run*) até que a dano ocorra. Apesar de ser o paradigma de manutenção mais simples, ele apresenta a desvantagem de não evitar que a estrutura seja interditada de forma brusca ou inesperada (*breakdown*) (MARCUS 2002).

Já a **manutenção preventiva** ou planejada (*planned maintenance*) tem como principal objetivo evitar que o equipamento atinja um estado de parada brusca, efetuando inspeções em intervalos periódicos independentemente do estado físico da estrutura. Com isso, os componentes ou subsistemas podem ser substituídos antes que alcancem um estado de dano e ocasionem uma interdição inesperada na estrutura. A principal desvantagem dessa abordagem é o alto custo das freqüentes inspeções que muitas vezes são desnecessárias, já que o equipamento não necessita de nenhum reparo. Outro ponto é que os componentes são

substituídos baseando-se em um tempo de vida útil e não em seu estado real. Sendo assim, muitos componentes em boas condições de uso podem ser precocemente substituídos. Essas questões tornam a manutenção preventiva uma prática economicamente onerosa (JARDINE *et al.* 2006).

Outra abordagem vem sendo considerada como uma alternativa aos elevados custos da manutenção preventiva. Trata-se da **manutenção preditiva** (ou *condition-based maintenance*), método adotado para monitorar e diagnosticar a condição do equipamento com a finalidade de **predizer** quando um dano irá ocorrer. Essa abordagem permite que a manutenção ou inspeção seja feita antes que a dano ocorra (HIGGS *et al.* 2004), mas sem a necessidade de substituições precoce dos equipamentos. Um programa de manutenção preditiva eficientemente implantado pode reduzir significativamente os custos com manutenção ao reduzir o número de operações de manutenção desnecessárias (JARDINE *et al.* 2006).

#### 2.2.1 Detecção de Danos em Estruturas Civis

Existem diversas técnicas que podem ser utilizadas para verificar se a estrutura apresenta algum tipo de dano. O monitoramento da vibração emitida pela estrutura é uma das técnicas mais aceitas na área de SHM para identificar possíveis alterações na saúde de uma determinada estrutura (FARRAR *et al.* 2003). Isso porque as medidas de vibração permitem extrair e identificar as **frequências naturais** de uma estrutura ou objeto. As frequências naturais (ou modais) são utilizadas para identificar alterações na massa de um determinado objeto. Dessa forma, a presença de micro-rachaduras, micro-danos ou danos, acarretam em uma mudança nas frequências naturais de uma estrutura e, por conseguinte, tornam exeqüível o processo de detecção de danos (SALAWU 1997).



Figura 4. (a) Dados de vibração e (b) Espectro de força

Os valores de vibração, como ilustrado na Figura 4 (a), são coletados por sensores denominados acelerômetros. As frequências naturais são obtidas através de um processamento efetuado sobre as medidas de vibração coletadas. Em geral, esse processamento é dividido em três etapas distintas. Na primeira etapa, as informações de vibração passam por um processo chamado de Transformada Rápida de Fourier (FFT, do inglês *Fast Fourier Transform*), onde os dados são convertidos do domínio de tempo para o domínio de frequência (GETACHEW e MITIKU 2011). Como resultado desse processo, é produzido um vetor de números reais que servirá como parâmetro de entrada para a próxima etapa do processo (HACKMANN *et al.* 2008). A Figura 4 (b) apresenta um gráfico que exemplifica a saída gerada pela FFT.

A segunda etapa, denominada *Power Spectrum Density* (PSD), efetua uma suavização na curva gerada pela FFT, ou seja, os ruídos são suavizados a fim de evidenciar a presença dos picos de frequência. A saída gerada pelo PSD é utilizada como entrada para a terceira e última etapa que é denominada *Curve Fitting*. Esse procedimento procura identificar os valores de frequência associados aos picos da curva de espectro (HACKMANN *et al.* 2008). A Figura 5 mostra o resultado gerado por essa etapa. É interessante ressaltar que alguns trabalhos, como (DOS SANTOS *et al.* 2012) e (LEMOS *et al.* 2011), aplicam o método de *Curve Fitting* diretamente no espectro de força, ou seja, sem ter a necessidade de efetuar o processo de *Power Spectrum Density*.

Cada um dos picos de frequência identificado pelo *Curve Fitting* está associado a um **modo de frequência natural** (GETACHEW e MITIKU 2011). A quantidade de modos de frequência natural está relacionado com as propriedades físicas e estruturais de uma determinada estrutura.



Figura 5. Resultado gerado pelo processo de Curve Fitting

Normalmente, o processo de identificação dos picos de frequência é executado tanto na implantação da estrutura quanto na sua fase de operação. A execução na fase inicial tem a função de obter a assinatura de salubridade da estrutura. O mesmo processo é novamente executado ao longo do tempo para que se possa efetuar um comparativo com os valores coletados e com a assinatura anteriormente obtida (DOS SANTOS *et al.* 2012) (LEMOS *et al.* 2011).

Como resultado do processo de extração das frequências naturais, obtêm-se um vetor denominado por  $\boldsymbol{\omega}$  em que cada posição desse vetor armazena uma frequência relacionada a um modo de frequência natural da estrutura. Portanto, referencia-se como  $\boldsymbol{\omega}_0$  o vetor de frequências naturais que é usado como **assinatura de salubridade** da estrutura e como  $\boldsymbol{\omega}_t$  a assinatura do estado da estrutura em um dado momento **t**. A variação de frequências naturais, indicada por  $\Delta \boldsymbol{\omega}$ , é obtida através da Equação 1. Essa variação permite identificar o quanto a estrutura sofreu modificações desde seu estado inicial. É interessante notar que o valor de  $\Delta \boldsymbol{\omega}$  sempre será positivo (uso do módulo na fórmula), pois o interesse está em verificar o quanto as frequências se alteraram e não se a diferença foi negativa ou positiva (DOS SANTOS *et al.* 2012).

# $\Delta \omega = |\omega_0 - \omega_t|$ Equação 1. Variação de frequências naturais

A variação das frequências é comparada com um limite (ou *trhreshold*), denominado por **T**, que é considerado como o valor máximo de tolerância de variação das frequências da estrutura. A estrutura só será considerada em uma condição de dano se esse valor T for ultrapassado (DOS SANTOS *et al.* 2012) (LEMOS *et al.* 2011).

## 2.3 Adaptive Neuro Fuzzy Inference System (ANFIS)

No mundo real são usadas palavras vagas e imprecisas como "muito", "pouco" e "bastante" para descrever situações do cotidiano como, por exemplo, um comando a ser executado ou uma ordem a ser proferida. Apesar de ser naturalmente intrínseca ao conhecimento humano, a matemática tradicional não é capaz de modelar esses termos lingüísticos. Por esse motivo, o cientista Lofti Zadeh introduziu o conceito de Lógica Nebulosa (ZADEH 1965), com o intuito de interpretar a incerteza inerente a esses termos e definir a estratégia necessária para controlar a linguagem vaga e imprecisa que reflete o entendimento humano (MOSTARDINHA 2006).

Portanto, o principal objetivo da Lógica Nebulosa é generalizar a idéia representada pela teoria dos conjuntos convencionais, aproximando-se da imprecisão e do aspecto vago do raciocínio humano (KOSKO 1994). Outra vantagem da Lógica Nebulosa é que ela reduz as dificuldades de implementação nos casos em que o profissional não possui um conhecimento completo sobre o problema (MORATORI *et al.* 2005).

Os sistemas nebulosos são sistemas computacionais que utilizam os conceitos da Lógica Nebulosa para efetuar controle de processos e executar tomada de decisões. Esses sistemas são constituídos pelos componentes de nebulização, inferência e desnebulização, além de uma base de semânticas que se refere aos rótulos associados aos conjuntos nebulosos e uma base de regras difusas que possuem o formato SE-ENTÃO.

O processo de nebulização é aquele em que os valores escalares (precisos) de entrada são mapeados em conjuntos nebulosos nas variáveis lingüísticas. Já a inferência tem a função de realizar a aplicação das regras difusas (contidas na base de regras difusas) e verificar quais regras são ativadas pelos valores de entrada. Por último, o processo de desnebulização permite que os valores nebulosos de saída sejam mapeados em valores escalares a fim de que o sistema nebuloso forneça uma saída precisa (MOSTARDINHA 2006).

Em sistemas nebulosos do tipo **Takagi-Sugeno** (TAKAGI e SUGENO 1985) o processo de desnebulização é feito através do resultado de uma equação que envolve os valores de entrada, ou seja, cada regra possui como conseqüente o resultado de uma equação conforme exemplificado na Equação 2 (TAKAGI e SUGENO 1985).

## $F_i = p_i^* x + q_i^* y + r_i$

#### Equação 2. Desnebulização pelo modelo Sugeno

Na Equação 2 as incógnitas x e y são valores de entrada passados para o sistema nebuloso e as variáveis p, q e r são parâmetros definidos para cada regra nebulosa. Caso mais de uma regra seja ativada, o sistema apura o **peso da regra** avaliando-se o menor grau de pertinência (o produto também é uma opção) das entradas em cada conjunto nebuloso e efetua o cálculo definido na Equação 3 para obter a saída final. Os pesos das regras estão representados na Equação 3 pela variável w, enquanto que a variável F representa os valores obtidos pelo resultado da Equação 2 executada em cada regra ativada (TAKAGI e SUGENO 1985).

### Equação 3. Saída final do sistema nebuloso do tipo Sugeno

Utilizando-se um sistema nebuloso do tipo Takagi-Sugeno e um conjunto de dados de treinamento, é possível criar um sistema nebuloso capaz de extrair o conhecimento intrínseco dessa base de dados (conjunto de observações) através de um método automatizado denominado ANFIS (*Adaptive Neuro-Fuzzy Inference System*) (BARBALHO 2001). Os sistemas ANFIS são uma classe de redes adaptativas funcionalmente equivalentes a sistemas de inferência nebulosa que são capazes de representar o modelo Takagi-Sugeno através de um algoritmo de treinamento híbrido (JANG 1993).

O processo de treinamento torna o ANFIS mais sistemático e menos dependente do conhecimento do especialista. Com a finalidade de apresentar a arquitetura do ANFIS, a Figura 6 demonstra duas regras nebulosas SE-ENTÃO baseado no modelo Sugeno de primeira ordem.

Regra 1: SE (x é A1) E (y é B1) ENTÃO (F1 = p1x + q1y + r1)

Regra 2: SE (x é A2) E (y é B2) ENTÃO (F2 = p2x + q2y + r2)

### Figura 6. Modelo Sugeno de primeira ordem com duas regras SE-ENTAO

Nas regras da Figura 6, as incógnitas x e y são entradas,  $A_i$  e  $B_i$  são conjuntos nebulosos (rótulos),  $F_i$  são as saídas especificadas pela regra nebulosa e  $p_i$ ,  $q_i$  e  $r_i$  são os parâmetros determinados durante o processo de treinamento. A Figura 7 apresenta a arquitetura ANFIS usada para implementar as duas regras demonstradas na Figura 6.



Figura 7. Arquitetura ANFIS para as duas regras

A arquitetura da Figura 7 possui nós do tipo adaptativo (quadrado) e fixo (círculo), além de estar dividida em cinco camadas (C1 a C5). Na primeira camada (C1) todos os nós

são adaptativos e a saída destes nós é o grau de pertinência da respectiva entrada no dado conjunto ou rótulo nebuloso. Já a segunda camada (C2) possui apenas nós do tipo fixo e sua função é executar uma simples multiplicação entre os resultados da primeira camada. A terceira camada (C3) tem a responsabilidade de efetuar uma normalização nos resultados da camada anterior, ou seja, cada valor apurado na camada 2 é dividido pela soma de todos os valores da camada 2. Os resultados da camada 3, chamados de *ativações normalizadas*, são multiplicadas na camada 4 (C4) pelo polinômio de primeira ordem  $F_i$  (para um modelo Sugeno de primeira ordem). Por último, a saída final é apurada na camada 5 (C5) através de um somatório de todos os sinais de entrada.

Portanto, existem apenas duas camadas que apresentam nós adaptativos: a primeira e a quarta. Na primeira camada (C1) existem três parâmetros ajustáveis ( $a_i$ ,  $b_i$ ,  $c_i$ ) que são usados para definir os limites e o comportamento da função de pertinência. Esses parâmetros são chamados de *parâmetros de premissa*. A quarta camada (C4) também possui três parâmetros que podem ser alterados:  $p_i$ ,  $q_i$  e  $r_i$ . Esses parâmetros, conhecidos por *parâmetros de conseqüência*, refletem diretamente no resultado que será obtido por cada regra do sistema nebuloso.

O processo de treinamento consiste em ajustar os parâmetros de premissa e de conseqüência com o objetivo de minimizar a diferença entre o resultado do sistema e o valor esperado. O algoritmo de treinamento é dito híbrido, pois utiliza o método dos mínimos quadrados em conjunto com o método do gradiente descendente para otimizar a busca pelos parâmetros ajustáveis da rede adaptativa (JANG 1993).

As redes neurais (e o ANFIS se encaixa nesta classificação como uma rede neural adaptativa) possuem alguns critérios de parada no que tange a execução do treinamento. Em geral são utilizados como critérios de parada o número de épocas de treinamento (ciclos) e o erro quadrático médio (HAYKIN 2001). Em relação ao número de épocas, define-se um número máximo de ciclos de treinamento e coloca-se a rede para executar tantos ciclos quanto esse número máximo. Um número excessivo de ciclos pode levar a rede à perda do poder de generalização (*overfitting*), enquanto que um número pequeno pode culminar na perda de desempenho (*underfitting*). Já o critério de parada pelo erro consiste em encerrar o treinamento quando o valor desse erro for suficientemente pequeno (por exemplo, em torno de 0,01).

Ao final do treinamento, a rede adaptativa resultante irá representar exatamente um sistema nebuloso Sugeno completo, ou seja, as regras (com seus pesos) e os conjuntos

nebulosos (com suas posições no universo de discurso) já estarão definidos. Entretanto, é preciso fornecer alguns parâmetros para criação de uma rede adaptativa inicial como o (i) número de conjuntos nebulosos por variável de entrada, o (ii) tipo de função de pertinência que será usada nas variáveis de entrada e, por último, (iii) o tipo de função de pertinência que será usada na variável de saída. Diferentes parâmetros iniciais podem resultar em sistemas nebulosos que apresentem desempenho diferenciado. Dessa maneira, é imprescindível efetuar uma calibração, onde os parâmetros iniciais são variados a fim de gerar o sistema nebuloso mais adequado ao problema. Os detalhes do sistema nebuloso gerado neste trabalho são discutidos na seção 5.1.

#### 2.4 Predição de Séries Temporais

Uma série temporal pode ser definida como um conjunto de observações de variáveis quantitativas coletadas ao longo do tempo (DELURGIO 1998). Um exemplo de série temporal seria o conjunto de dados resultantes da observação do Índice Nacional de Preços ao Consumidor Amplo (IPCA) por um período de quatro anos.

As séries temporais podem apresentar algumas características particulares como **sazonalidade** e **estacionariedade**. Uma série apresenta sazonalidade quando exibe um comportamento que tende a se repetir a cada período de tempo, onde esse padrão de comportamento possivelmente se repetirá ao longo de vários anos. Já uma série é dita estacionária se suas propriedades estatísticas, como média e variância, não se alteram ao longo do tempo (MORETTIN e TOLOI 2006).

A Figura 8 apresenta um exemplo de série temporal não-estacionária. Trata-se de uma série composta pelo fechamento diário da bolsa de valores Dow Jones entre os anos de 1980 e 1990. Pode-se observar que sua média e variância não permanecem as mesmas à medida que o tempo avança.



Figura 8. Exemplo de série temporal não-estacionária

Já a Figura 9 apresenta uma série temporal com indícios de sazonalidade, ou seja, nesta série é possível observar um comportamento cíclico que se repete ao longo do tempo. Essa série mostra os totais mensais de passageiros em linhas aéreas internacionais nos EUA entre os anos de 1949 e 1960.



Figura 9. Exemplo de série temporal sazonal

A análise de séries temporais busca por padrões de comportamento, onde algumas de suas propriedades oferecem subsídio para realizar o que se conhece por predição ou previsão de séries temporais (MORETTIN e TOLOI 2006). A predição é o processo de tentar antecipar os valores subseqüentes baseando-se nos dados conhecidos ou passados (histórico). Com as informações oriundas da predição é possível realizar um melhor planejamento ou evitar que se alcance um estado indesejável (como a ocorrência de dano em uma estrutura civil, por exemplo).

De forma geral, pode-se definir predição de séries temporais como o desejo de obter o valor no horizonte h a partir da origem t conforme demonstrado na Figura 10. A variável h indica o **horizonte de previsão** que é definido como o número de pontos da série a serem previstos (MORETTIN e TOLOI 2006).

Existem diversos modelos para realizar a predição de séries temporais como, por exemplo, os métodos de Médias Móveis Simples (MMS) e Suavização Exponencial Simples (SES). O método MMS calcula a média das últimas *r* observações. O termo Média Móvel é utilizado, porque à medida que a próxima observação está disponível, a média das observações é recalculada, incluindo essa última observação no conjunto de observações e desprezando a observação mais antiga. Já o SES é uma média ponderada que atribui pesos maiores às observações mais recentes, onde esse peso é determinado por um parâmetro chamado por *constante de suavização* (FARIA *et al.* 2008). Esses métodos são considerados como métodos simples de previsão de séries temporais, não sendo adequados para problemas mais complexos (MORETTIN e TOLOI 2006).





No entanto, um modelo avançado para previsão de séries temporais que vem ganhando destaque e tem sido amplamente discutido é o ARMA (do inglês, *Autoregressive Moving Averages*) que também é conhecido como modelo Box e Jenkins, devido ao nome dos seus autores (George Box e Gwilym Jenkins) (MORETTIN e TOLOI 2006) (BOX *et al.* 1994). Esse modelo clássico possui certas características que o diferenciam dos demais métodos como, por exemplo, a mensuração probabilística do erro de previsão e uma metodologia

menos subjetiva para obtenção de modelos (FLORES 2009). Esse modelo pode ser entendido como a junção dos modelos individuais de auto-regressão (AR, do inglês *Autoregressive*) e de médias móveis (MA, do inglês *Moving averages*). Sua forma geral está descrita na Equação 4.

$$X_t = c + \varepsilon_t - \sum_{i=1}^p \varphi_i X_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i}$$

#### Equação 4. Modelo ARMA

As incógnitas  $\varphi \in \theta$  são coeficientes que deverão ser ajustados para refletir o comportamento da série temporal. Também com esse propósito o valor da constante c deve ser adequadamente escolhido. Já o *ruído branco*, denotado por  $\mathcal{E}_t$ , é a diferença entre o valor previsto e o valor observado em um dado momento t. Por fim, a variável  $X_t$  representa o valor da série temporal no instante t.

Cada somatório representa uma parte do modelo, sendo que o primeiro trata da parte de auto-regressão e o último da parte de médias móveis. A quantidade de termos de cada parte do modelo é determinada através dos parâmetros p e q, onde o primeiro indicará a quantidade de termos de auto-regressão e o segundo denotará a quantidade de termos usados na parte de médias móveis. Esses argumentos também são chamados de indicadores de ordem do modelo. Portanto, um modelo ARMA (1,2) poderá ser entendido como AR de ordem um e MA de ordem dois.

De forma geral, considera-se como o modelo ARMA mais adequado aquele que apresenta a característica de **parcimônia**, ou seja, aquele modelo que possui o menor número possível de parâmetros (minimiza  $p \in q$ ). Portanto, deve-se tentar adotar sempre um modelo parcimonioso ao realizar a análise de séries temporais (MORETTIN e TOLOI 2006).

Essa é apenas a definição básica do modelo ARMA. Existem diversas variações desse modelo como, por exemplo, o VARMA (*Vector Autoregressive Moving Averages*) para séries multivariadas, o SARMA (*Sazonal Autoregressive Moving Averages*) para séries com sazonalidade e o ARIMA (*Autoregressive Integrated Moving Averages*) que deve ser usado em casos onde a série apresenta indícios de não-estacionariedade. Portanto, é preciso avaliar cada caso para decidir se cabe ou não usar uma variação do modelo ARMA (MORETTIN e TOLOI 2006).

O método proposto por Box e Jenkins sistematiza alguns passos que devem ser executados para estimar o modelo ARMA mais adequado a uma determinada série temporal

(MAKRIDAKIS *et al.* 1998) (BOX *et al.* 1994). Esse método, descrito no fluxograma da Figura 11, é composto por 3 fases: **Identificação**, **Estimação e Teste**, e **Aplicação**.

A fase de **Identificação** é composta pelos passos de **Preparação dos Dados** e de **Seleção do Modelo**. No passo de Preparação dos Dados sugere-se uma visualização gráfica dos dados a fim de identificar algumas características da série temporal como não-estacionariedade e sazonalidade. Além de realizar essa visualização da série, pode-se usar outros recursos como a análise do correlograma, gerado a partir das Funções de Autocorrelação (FAC ou ACF, do inglês *Autocorrelation Function*) e Autocorrelação Parcial (FACP ou PACF, do inglês *Partial Autocorrelation Function*), e do periodograma (EHLERS 2009) (MAKRIDAKIS *et al.*1998).

O correlograma é um gráfico com os k primeiros coeficientes de Autocorrelação como função de k e é considerada uma poderosa ferramenta para identificar características estatísticas da série temporal, como a não-estacionariedade. Já o periodograma tem a finalidade de verificar a presença de características de sazonalidade (EHLERS 2009).

No segundo passo da fase de Identificação deve ser escolhida a variação do modelo (caso seja necessário) e a seleção de sua ordem. A variação é escolhida com base nas características observadas no passo anterior. Por exemplo, deve-se optar por uma variação ARIMA para o caso de uma série não-estacionária e por uma variação SARMA para uma série com indícios de sazonalidade.

Já a Seleção de Ordem do modelo é executada de acordo com critérios baseados em métodos automatizados. Como exemplo desses critérios pode-se citar o *Akaike Information Criterion* (AIC) (AKAIKE 1974), o *Schwarz Bayesian Criterion* (BIC) (SCHWARZ 1978) e o *Hannan–Quinn Information Criterion* (HQC) (HANNAN e QUINN 1979). O menor valor de cada critério denotará a melhor escolha de ordem para o modelo que está sendo construído. Um dos motivos de usar mais de um critério é a possibilidade de confirmar a ordem apontada por dois ou mais critérios. Vale lembrar que para alguns casos a análise dos correlogramas gerados a partir das FAC e FACP podem também auxiliar no processo de seleção da ordem do modelo (EHLERS 2009) (MAKRIDAKIS *et al.* 1998).

É importante enfatizar que durante essa fase de Identificação, mais de um modelo pode ser apontado como sendo um candidato a ser escolhido. Portanto, durante uma fase posterior, deve-se confrontar os modelos candidatos a fim de escolher o mais adequado.



Figura 11. Etapas para construção de modelos ARMA

Independente da variação ARMA utilizada é preciso definir os coeficientes ( $\varphi \in \theta$ ) e a constante *c* (caso seja utilizada) para que o modelo ARMA possa refletir o comportamento da série. Esse processo de estimação dos coeficientes é efetuado durante a fase de **Estimação e Testes**. No primeiro passo dessa fase, denominado **Estimação**, são aplicadas técnicas para definir automaticamente os coeficientes do modelo. Como exemplo, pode-se citar as técnicas de Máxima Verossimilhança (Exata ou Condicional) (BOX *et al.* 1994), o método dos Mínimos Quadrados e o método de Yule-Walker (BROCKWELL e DAVIS 2002).

O outro passo da etapa de **Estimação e Testes**, denominado **Diagnóstico**, tem a função de avaliar o modelo que fora estimado ou os modelos que foram considerados como sendo candidatos. Para isso podem ser utilizadas medidas de erro, como o Erro Médio e o Erro Quadrado Médio, além da análise de resíduos. Esses critérios têm a finalidade de tangibilizar o confronto realizado entre o modelo estimado (ou modelos estimados, caso mais de um tenha sido apontado como candidato) e os dados da série temporal com o intuito de auxiliar na decisão a respeito de um conjunto de modelos candidatos.

A análise de resíduos tem a finalidade de observar os resíduos gerados pelo modelo estimado. O **resíduo** é definido como a diferença entre o valor gerado pelo modelo e o valor real da série temporal em um dado momento *t*. Uma forma de verificar a precisão do modelo estimado é analisar os correlogramas dos resíduos e compará-los com os correlogramas da
série original. O modelo é considerado adequado nos casos em que esses dois correlogramas apresentem comportamento similar.

Por fim, o modelo construído está pronto para ser aplicado na última fase do método de Box e Jenkins, denominada fase de **Aplicação**. Nesta fase o modelo tem plenas condições de realizar previsões a cerca de valores futuros da série temporal.

Todos os passos anteriormente descritos são, em geral, executados com o auxílio de pacotes computacionais como o S-PLUS, MINITAB, SCA, EViews, STAMP e o ITSM 2000 (MORETTIN e TOLOI 2006). Existem outros *softwares* menos conhecidos, mas que podem ser boas opções para a análise de séries temporais, principalmente por se tratar de software gratuito. Como exemplo, pode-se citar o JMulti, TSW, AutoBox e o Gretl (GNU Regression, Econometrics and Time-series Library).

### **3** Trabalhos Relacionados

Este capítulo apresenta trabalhos relacionados sob diferentes aspectos com a nossa proposta. Primeiramente, são destacados trabalhos que realizam o processo de predição de danos em estruturas civis, fazendo uso de dados de vibração e métodos de predição. Em seguida são apresentados estudos que propõem métodos capazes de identificar e quantificar a influência das condições ambientais nas frequências naturais de estruturas civis. Por fim, são descritos trabalhos que utilizam RSSF como infra-estrutura básica de comunicação e sensoriamento para realizar, parcialmente ou em sua totalidade, o processo decisório de detecção de danos em estruturas civis.

Existem diversos trabalhos de predição de danos em estruturas em geral que utilizam métodos de previsão de dano baseados em modelos estatísticos. Entre eles destacamos Pham e Yang (PHAM e YANG 2010), Pham et al. (PHAM et al. 2010) e Garcia et al. (GARCIA et al. 2010). O trabalho de Pham e Yang (PHAM e YANG 2010) faz uso do modelo Autoregressivo Condicional Heterocedástico Generalizado (Generalized AutoRegressive Conditional Heteroskedasticity – GARCH) em conjunto com o modelo ARMA para estimar e predizer o estado de um equipamento (aplicado experimentalmente em um compressor de metano) baseado em dados de vibração. O trabalho aplica o modelo ARMA para predizer valores de ruído da máquina que está sendo monitorada, enquanto que o modelo GARCH é usado para predizer as condições futuras do equipamento. O trabalho de Pham et al. (PHAM et al. 2010) utiliza o modelo Auto-regressivo Não-linear com Entrada Exógena (Nonlinear Autoregressive with Exogenous Input - NARX) para realizar predições em longo prazo em equipamentos (também aplicado experimentalmente em um compressor de metano) a partir de dados de vibração. Neste trabalho, a vibração é considerada como sendo constituída por dois componentes distintos: dado determinístico e erro. O modelo NARX é usado para realizar a análise da parte determinística da vibração, enquanto que o modelo ARMA é aplicado para analisar a parte de erro. O trabalho de Garcia et al. (GARCIA et al. 2010) propôs um algoritmo para predizer danos em dispositivos de controle de ferrovias com base nas informações de corrente elétrica do equipamento. O trabalho em questão utiliza um modelo VARMA e um modelo de regressão harmônica, onde o modelo VARMA é empregado para avaliar uma sérite temporal composta por mais de uma variável e o modelo de regressão harmônica é usado para predizer os valores de corrente elétrica consumidos pelo dispositivo de controle de ferrovias. Em função das limitações computacionais dos dispositivos da RASSF, nosso trabalho utiliza apenas o modelo ARMA, e não um modelo híbrido, como utilizado nos trabalhos de Pham e Yang (PHAM e YANG 2010) e Pham *et al.* (PHAM *et al.* 2010). Não utilizamos o modelo VARMA, pois no nosso caso consideramos uma série temporal composta por apenas uma variável, ou seja, variação de frequências naturais.

Com relação à adoção de métodos capazes de identificar e quantificar a influência das condições ambientais nas frequências naturais de estruturas civis, destacamos os trabalhos de Liu e DeWolf (LIU e DEWOLF 2007), Xia et al. (XIA et al. 2006) e Moser e Moaveni (MOSER e MOAVENI 2011). Em cada um deles foram obtidas conclusões distintas sobre a influência das condições ambientais nas frequências naturais da estrutura, pelo fato de analisarem estruturas diferentes. Em função disso, em cada um dos trabalhos citados foram propostos métodos ou técnicas particulares para correlacionar essas medidas. Em Xia et al. (XIA et al. 2006), o estudo concluiu que as frequências naturais diminuem quando as medidas de temperatura e umidade aumentam ao avaliar um bloco de concreto disposto em um ambiente controlado (laboratório externo). Para identificar essa relação os autores construiram um modelo de regressão linear que relacionava as propriedades modais e os fatores ambientais. Já em Liu e DeWolf (LIU e DEWOLF 2007), foram efetuadas análise de dados de frequência natural de uma ponte, onde foi constatado que a relação entre as frequências naturais e a temperatura é basicamente linear e que os modos de frequência diminuem quando a temperatura sofre acréscimo. O estudo propôs um modelo de regressão linear para representar os três modos de frequência em função da temperatura. Por último, o trabalho desenvolvido por Moser e Moaveni (MOSER e MOAVENI 2011) avaliou a interferência ambiental exercida sobre as frequências naturais ao realizar experimentos em uma passarela para pedestres. O trabalho concluiu que as frequências naturais e a temperatura estavam fortemente correlacionadas e que essa relação era não-linear. Para modelar a variação de frequências modais diante das mudanças na temperatura, esse trabalho propôs um modelo polinomial estático de quarta ordem. Ao analisar esses trabalhos, concluiu-se que não seria factível aproveitar os métodos propostos por esses trabalhos, uma vez que as estruturas utilizadas nos estudos apresentam materiais e propriedades físicas diferenciadas. Por essa razão, neste trabalho utilizamos um método capaz de filtrar a influência das condições ambientais nas frequências naturais de uma estrutura qualquer, ou seja, o método não é dependente das propriedades físicas da estrutura. Isso é feito através de um sistema nebuloso gerado automaticamente pelo ANFIS. O ANFIS utiliza uma base de dados reais da estrutura para extrair a correlação entre a temperatura (grandeza física observada) e a vibração (frequências naturais).

Existem diversos trabalhos que fazem uso de RSSF para monitorar as condições de uma estrutura. Entre eles, ostrabalhos de Kim *et al.* (KIM *et al.* 2007), Swartz *et al.* (SWARTZ *et al.* 2008), Zonta *et al.* (ZONTA *et al.* 2009) e (REYER *et al.* 2011) usam a RSSF como infraestrutura de sensoreamento e comunicação: os dados sensoriados são transmitidos para um dispositivo central (o *sink*), onde um processo de detecção de dano é executado. Em Kim *et al.* (KIM *et al.* 2007) e Swartz *et al.* (SWARTZ *et al.* 2008) os nós sensores da RSSF realizam periodicamente a coleta e o encaminhamento de dados até o nó *sink.* Os nós da RSSF implementada em Zonta *et al.* (ZONTA *et al.* 2009) também realizam a coleta e envio de dados ao *sink*, mas com a particularidade de poderem receber comandos externos afim de reconfigurar parâmetros de monitoramento. Por fim, em Reyer *et al.* (REYER *et al.* 2011) os nós aplicam um algoritmo de compressão de dados com o objetivo de reduzir a quantidade de informação a ser enviada até o *sink.* 

Outros trabalhos, entre eles Hackmann et al. (HACKMANN et al. 2008), Bocca et al. (BOCCA et al. 2011), Dos Santos et al. (DOS SANTOS et al. 2012) e Lemos et al. (LEMOS et al. 2011) propõem o uso da RSSF não somente para efetuar sensoreamento e comunicação, mas também para realizar tarefas relacionadas ao processo de detecção de dano em estruturra civis. Em Hackmann et al. (HACKMANN et al. 2008), os nós da rede incorporaram parte da aplicação de detecção de dano ao executar um algoritmo parcialmente descentralizado que faz uso de uma abordagem denominada Damage Localization Assurance Criterion (DLAC). Bocca et al. (BOCCA et al. 2011), Dos Santos et al. (DOS SANTOS et al. 2012) e Lemos et al. (LEMOS et al. 2011) propuseram soluções capazes de executar todo o processo de SHM dentro da RSSF. Em Bocca et al. 2011 (BOCCA et al. 2011) a RSSF efetua todo o processo de detecção e localização de dano de forma distribuída através da aplicação do algoritmo de Goertzel, onde os nós da rede cooperam para calcular funções de transmissibilidade a fim de obter indicadores de dano da estrutura. Em Dos Santos et al. (DOS SANTOS et al. 2012), a RSSF executa um algoritmo descentralizado capaz de detectar, localizar e também determinar a extensão de dano em uma estrutura. Para isso, esse trabalho conta com uma RSSF hierárquica (clusters) e utiliza o mecanismo DLAC que também é usado no trabalho de Hackmann et al. (HACKMANN et al. 2008). O trabalho de Lemos et al. (LEMOS et al. 2011) é uma extensão do trabalho de Dos Santos et al. (DOS SANTOS et al. 2012), onde o principal diferencial está na identificação do dano diante da análise da frequência modal sob a influência de parâmetros ambientais, como a temperatura e umidade.

Assim como os trabalhos citados acima, nosso trabalho também utiliza a RSSF para executar o processo decisório, entretanto esses trabalhos realizam um processo de **detecção de danos**, enquanto que o nosso trabalho efetua um processo de **predição de danos**. O Delphos também efetua a correlação de variáveis ambientais, onde a temperatura é analisada para interpretar melhor o comportamento das frequências naturais a fim de aumentar a acurácia do processo de predição de dano. O sistema proposto utiliza os nós da RASSF para avaliar a estrutura sob diferentes ângulos de visão (cada nó sensore realiza a predição de dano com base na sua leitura local de vibração) com a finalidade de aumentar a confiabilidade do processo de predição. Por fim, o sistema utiliza também dispositivos atuadores para executar ações de controle no aerogerador para que não ocorram danos catastróficos.

Poucos trabalhos realizam a predição de danos especificamente em aerogeradores. Nos trabalhos de Kusiak e Li (KUSIAK e LI 2010) e Miguelanez e Lane (MIGUELANEZ e LANE 2010), algoritmos de mineração de dados são usados para predizer danos em aerogeradores. Ambos os trabalhos utilizam dados oriundos de um sistema de automação industrial que já vem pré-instalado em alguns tipos de aerogeradores. Cada um dos sistemas é capaz de coletar dados de monitoramento, executar algoritmos de predição de danos e emitir alertas em diversos níveis. Diferentemente do nosso trabalho, essas propostas possuem como pré-requisito o uso de um sistema adicional já instalado nos aerogeradores. Já o nosso trabalho realiza todo o processo de monitoramento, decisão quanto à anormalidade da estrutura e predição de danos sem necessitar de qualquer outro sistema.

### 4 Delphos: Sistema de Predição de Danos Neuro-Fuzzy para RASSF

A proposta do presente trabalho consiste de um sistema descentralizado, confiável e acurado que utiliza RASSF com a finalidade de predizer danos e atuar sobre a operação dos aerogeradores.

O processo de predição de danos descentralizado permite fornecer uma resposta mais ágil para que ações de controle sejam efetuadas no aerogerador. Outra vantagem quanto a execução descentralizada deste processo decisório de predição está relacionada a economia de energia dos nós da rede, já que cada nó transmite apenas um resultado e não todo o conjunto de dados coletados. Quanto a confiabilidade, o sistema utiliza as diferentes visões obtidas por cada um dos nós ao monitorar o aerogerador para decidir de forma confiável sobre o estado da estrutura. A presença destes nós também possibilita a execução de técnicas de tolerância a falhas, contribuindo também para o aumento da confiabilidade da resposta fornecida pelo sistema. Por fim, o sistema é considerado acurado, pois a influência da tempeartura exercida sobre a frequência natural é eliminada pelo sistema antes de executar o processo de predição. Sendo assim, o sistema utiliza dados não influenciados por interferências ambientais para fornecer um resultado final mais acurado.

Esse sistema, denominado **Delphos**, faz uso de dois mecanismos principais, a saber: Decisão de Anormalidade e Predição de Danos. O mecanismo de Decisão de Anormalidade é responsável por verificar se a estrutura não se encontra em um **estado de anormalidade** que é definido como o estado em que a estrutura não se apresenta totalmente saudável, mas ao mesmo tempo ainda não houve ocorrência de dano. Já o mecanismo de Predição de Dano tem a função de predizer quando um dano ocorrerá.

Neste capítulo, são descritos (i) a arquitetura lógica e física do sistema Delphos e (ii) a operação do sistema composta por suas fases de execução.

### 4.1 Arquitetura Lógica

A arquitetura lógica do Delphos consiste dos componentes: Gestor, Monitoramento, Tratamento de Dados, Filtro de Interferências Ambientais, Decisão de Anormalidade, Predição de Dano, Atuação e Alarme; e das bases de dados: Semânticas e Regras Difusas, Parâmetros de Monitoramento, Coeficientes, Série Temporal e Ações de Controle. Essas bases de dados criadas e populadas antes da inicialização do Delphos. A Figura 12 apresenta as interfaces que são oferecidas por cada componente. O Gestor é o componente central da arquitetura do Delphos e é responsável por gerenciar a operação dos demais componentes do sistema. O componente Gestor inicia cada etapa de execução solicitando a frequência natural filtrada a partir do componente de Monitoramento e envia essa informação ao componente de Decisão de Anormalidade a fim de verificar se a estrutura se encontra em um estado de anormalidade. Em caso positivo, o componente Gestor indica que o componente de Predição de Dano deve efetuar o processo de predição de danos usando o modelo ARMA. Em caso de iminência de dano, o componente Gestor contata os componentes Alarme e Ações de controle com o objetivo de, respectivamente, enviar um alarme até o sink e efetuar ações de controle na estrutura.

O componente de **Monitoramento** coordena as tarefas de coleta dos dados físicos do ambiente e da estrutura, fazendo a interface com as unidades de sensoriamento contidas em cada nó sensor. Para isso, o componente de Monitoramento utiliza as informações contidas na base de **Parâmetros de Monitoramento**, como a frequência de amostragem e o tempo de monitoramento das grandezas físicas. Esse componente é responsável por executar as leituras de temperatura e vibração e enviar os dados coletados para o componente de Tratamento de Dados e para o Filtro de Interferências Ambientais.



### Figura 12. Arquitetura lógica do sistema Delphos

O componente de **Tratamento de Dados** realiza o processamento dos dados de vibração a fim de extrair as frequências naturais da estrutura. Para isso, são executados os processos de FFT e a seleção dos picos de frequência através do método de *Curve Fitting* conforme descrito na seção 2.2.1. Esses procedimentos retornam as frequências relativas a cada modo de frequência natural da estrutura. Em alguns trabalhos, como em (FARRAR *et al.* 2003), destaca-se que o **primeiro modo** de frequência natural denota o **comportamento global da estrutura**, já que essa frequência apresenta o menor erro em sua determinação através da FFT. Como nosso foco está exatamente no comportamento global da estrutura, e com o objetivo de reduzir o custo de processamento em cada nó sensor, neste trabalho **usaremos apenas o primeiro modo de frequência natural**.

O componente **Filtro de Interferências Ambientais** faz uso de um sistema nebuloso para eliminar a influência de variáveis ambientais (neste trabalho considera-se apenas a influência da temperatura) na frequência natural extraída, dando origem a uma frequência natural filtrada. As informações do sistema nebuloso estão contidas na base de dados de Semântica e Regras Difusas.

O componente de **Decisão de Anormalidade** avalia se a estrutura se encontra em um estado de anormalidade. O estado de anormalidade é definido como a condição em que a estrutura não está saudável, mas ao mesmo tempo ainda não está comprometida por um dano. Para tal, esse componente executa duas tarefas. Inicialmente, é calculada a variação de frequências naturais ( $\Delta \omega$ ), conforme a Equação 1. Em seguida é verificado se  $\Delta \omega$  permanece dentro do intervalo de normalidade. Os valores desse intervalo de normalidade estão relacionados com as variações de frequência que estão dentro do intervalo de confiança de 95% quando a estrutura está em um estado saudável. Se esse for o caso, a estrutura ainda não se encontra em um estado de anormalidade e, portanto, não há razão para realizar a predição de dano.

Entretanto, caso a estrutura esteja em um estado de anormalidade, o componente de Predição de Dano é acionado pelo componente Gestor a fim de verificar se há iminência de dano. Para isso, o componente de Predição de Danos recebe a variação  $\Delta \omega$  do componente de Decisão de Anormalidade e utiliza esse dado para compor um histórico da condição física da estrutura a fim de realizar previsões a respeito de valores futuros de  $\Delta \omega$  usando o modelo ARMA. O componente de Predição de Danos realiza as seguintes tarefas: (i) usa os valores de  $\Delta \omega$  para compor a série temporal; (ii) calcula a previsão de valores de  $\Delta \omega$  através do modelo

ARMA; e (iii) informa se há iminência de dano. Uma "iminência de dano" é identificada quando os valores previstos de  $\Delta \omega$  ultrapassam o limite *T*. O limite T é particularmente determinado para cada estrutura e está relacionado com a tolerância de variação das frequências (DOS SANTOS *et al.* 2012).

Por fim, o componente de **Atuação** tem a função de receber informações sobre a iminência de dano, identificar a ação de controle mais apropriada (acessando a base de Ações de Controle) e enviar os comandos aos dispositivos atuadores. Já o componente de **Alarme** tem a função de informar a rede externa sobre a iminência de dano.

### 4.2 Arquitetura Física

Neste trabalho, considerou-se uma RASSF composta por três tipos de nós: (i) nós sensores, (ii) *sink* e (iii) atuador. Os **nós sensores** são usados para efetuar a coleta de dados e executar o processo decisório de predição de dano. O *sink* é responsável por receber alarmes gerados a partir da rede e transmiti-los até a rede externa. Por fim, o **atuador** tem a função de receber comandos oriundos da rede de sensores sem fio a fim de efetuar as ações de controle cabíveis ao dano previsto.

Os componentes de software descritos na seção 4.1 são implantados nos dispositivos físicos conforme descrito a seguir. Os nós sensores contêm todos os componentes de software ilustrados na Figura 12, exceto os componentes Atuação e Alarme. O componente Atuação e a base Ações de Controle são implantados no nó atuador, enquanto que o componente Alarme está localizado no *sink*.

### 4.3 Operação do Sistema

A operação do Delphos é composta por quatro fases distintas: (i) decisão de anormalidade, (ii) predição de dano, (iii) colaboração entre os nós da rede e (iv) reação. Na fase de **decisão de anormalidade**, o sistema verifica, a cada ciclo de monitoramento, se a estrutura se encontra em um estado de anormalidade. Na fase de **predição de dano**, o Delphos executa o procedimento de predição de dano nos casos em que a estrutura se encontre em estado de anormalidade. Na fase de **colaboração entre os nós da rede**, o sistema executa um processo de cooperação a fim de confirmar as previsões feitas por cada um dos nós da rede, aumentando a confiabilidade da predição de dano. Na fase de **reação**, o Delphos efetua as ações de controle apropriadas a fim de evitar o agravamento do dano e envia alarmes até a rede externa com a finalidade de informar sobre a predição de dano realizada e as ações que controle que foram efetuadas no ambiente.

A execução de todas essas fases é denominada **ciclo de execução** do Delphos. Portanto, esse ciclo compreende a execução sucessiva de cada uma das fases citadas anteriormente, onde cada fase é executada por um período fixo de tempo. A fim de manter o processamento de todos os nós no mesmo passo de execução, são implementados temporizadores internos que determinam o tempo que cada fase deve levar para completar sua execução.

Para isso, é executada uma fase de **configuração** antes da operação do Delphos. Nesta fase, todos os nós (sensores, *sink* e atuador) da rede são inicialmente sincronizados, onde este sincronismo é mantido durante toda a execução do sistema. Para executar esta sincronização podem ser utilizados protocolos de sincronização como o TPSN (do inglês *Timing-sync Protocol for Sensor Networks*) (SIVRIKAYA e YENER 2004).

Ao término dessa fase, o *sink* transmite uma mensagem do tipo INICIO\_EXECUCAO a fim de informar aos nós sensores que a execução do Delphos deve ser iniciada. As próximas subseções descrevem, em detalhes, cada uma das fases de operação do Delphos.

### 4.3.1 Fase de Decisão de Anormalidade

Na fase de **decisão de anormalidade** cada um dos nós sensores efetua as seguintes tarefas: (i) coletar as medidas de vibração e temperatura; (ii) extrair as frequências naturais da estrutura; (iii) submeter as frequências naturais ao filtro de interferências ambientais; (iv) calcular  $\Delta \omega$ ; e (iv) verificar se o valor  $\Delta \omega$  está dentro do intervalo de confiança de 95% que foi obtido quando a estrutura estava em um estado saudável. Essas tarefas são realizadas pelos componentes lógicos Monitoramento, Tratamento de Dados, Filtro de Interferências Ambientais e Decisão de Anormalidade.

A Figura 13 mostra o diagrama com a seqüência de ações executadas na fase de Decisão de Anormalidade. O componente Gestor solicita ao componente de Monitoramento que obtenha as frequências naturais filtradas através do comando (1) *ObterFreqNatFiltradas()*. Em seguida, o componente de Monitoramento efetua a coleta de temperatura (2) e vibração (3) através da execução dos comandos internos *ColetarTemp()* e *ColetarVibracao()*, respectivamente. De posse das medidas de temperatura e vibração, o componente de Monitoramento de Dados que execute o comando *ExtrairFreqNat(V)*, fornecendo como parâmetro a vibração coletada (4). A vibração é utilizada pelo componente de Tratamento de Dados para executar o processo de FFT (5) através do comando interno *ExecutarFFT(V)*. Em seguida, o resultado do comando anterior é passado ao comando interno *IdentificarFreqNat(FFT)* a fim de efetivamente identificar frequências naturais da estrutura (6) através do método de *Curve Fitting* (descrito na seção

2.2.1). As frequências naturais recém extraídas são devolvidas ao componente de Monitoramento para que esse solicite ao componente Filtro de Interferências Ambientais, através do comando *FiltrarFrequenciasNaturais*(T,FN) que execute o filtro capaz de eliminar a influência da temperatura nas frequências naturais (7).

Ao receber essa solicitação, o componente Filtro de Interferências Ambientais submete a temperatura (T) e as frequências naturais (FN) ao sistema nebuloso que efetivamente executa o filtro (8). Isto é feito com o auxílio do comando interno, denominado *ExecutarFIA(T,FN)*, o qual acessa a base de Semântica e Regras Difusas onde se encontram as informações para execução do sistema nebuloso. A frequência natural filtrada é devolvida ao componente de Monitoramento que a repassa ao componente Gestor em resposta à solicitação outrora efetuada através do comando *ObterFreqNatFiltrada()*.



Figura 13. Diagrama de seqüência da fase de Decisão de Anormalidade

Em seguida, o componente Gestor solicita ao componente de Decisão de Anormalidade que verifique se a estrutura se encontra em um estado de anormalidade (9). Para isso, o componente Gestor evoca o comando VerificarAnormalidade (FNFiltrada). A partir de então, o componente de Decisão de Anormalidade executa dois comandos internos, os quais acessam a base de Coeficientes para obter, respectivamente, a assinatura da estrutura e o primeiro de 95%. 0 comando intervalo de confiança interno, denominado *CalcVarFreqNat(Ass,FNFiltrada)* tem a finalidade de calcular a variação  $\Delta \omega$  (10). Após obter o coeficiente  $\Delta \omega$ , o componente de Decisão de Anormalidade executa o comando

interno *VerificarAnormalidade(VarFN,IC)* para verificar se valor  $\Delta \omega$  está dentro do intervalo de confiança de 95% (11). Em caso positivo, um indicativo de anormalidade (*Anormalidade*) é apropriadamente configurado e enviado ao componente Gestor, para que esse saiba que a estrutura se encontra em um estado de anormalidade. Apenas os nós sensores que identificam um estado de anormalidade passam em seguida a executar a fase de predição de dano. Já os nós que não identificaram anormalidade, aguardam o término do ciclo de execução para que voltem a executar essa mesma fase novamente.

### 4.3.2 Fase de Predição de Dano

Na fase de **predição de dano**, o nó sensor que identificou um estado de anormalidade efetua as seguintes tarefas: (i) alimentar séries temporais com o  $\Delta \omega$  apurado na etapa anterior (decisão de anormalidade); (ii) calcular valores futuros para o  $\Delta \omega$ ; e (iii) verificar se algum valor previsto ultrapassa o limite *T*. Para isso, são utilizados componentes lógicos Gestor e Predição de Danos.

Nesta fase (como ilustrado pelo diagrama de seqüência da Figura 14), o componente Gestor solicita ao componente de Predição de Danos que efetue a predição de danos a partir da  $\Delta \omega$  que foi recebida (13). Essa solicitação é feita através da evocação ao comando *ObterPredicaoDano(VarFN)*. Ao receber essa solicitação, o componente de Predição de Danos executa três comandos internos que culminarão na predição de dano para o aerogerador. O primeiro tem a função de armazenar a variação de frequência obtida através do procedimento *AlimentarSerieTemporal(VarFN)* (14). Esse comando acessa a base de Série Temporal e efetua o armazenamento do novo valor. Em seguida, a série temporal e o modelo ARMA são usados para calcular valores futuros de  $\Delta \omega$  (15) através da execução do comando *CalcularValoresFuturosVarFN()*. É exatamente neste ponto que o sistema faz a predição de valores futuros a partir de um histórico armazenado (série temporal).



Figura 14. Diagrama de seqüência da etapa de Predição de Danos

O último comando interno do componente de Predição de Danos, denominado *VerificarDanoIminente()*, acessa a base de Coeficientes, obtém o limite **T** e o compara com todos os valores produzidos pelo comando anterior (16). O sistema considera como um **dano previsto** os casos em que qualquer um dos valores futuros ultrapasse o limite **T**. Se esse for o caso, o componente Gestor é informado de quando o dano ocorrerá. Nesta situação, o Delphos executa a fase de reação, a qual consiste em efetuar ações de controle apropriadas e enviar um alarme sobre a iminência de dano até a rede externa.

### 4.3.3 Fase de Colaboração

Neste ponto do processamento, o Delphos executou as fases de decisão de anormalidade e predição de dano, onde cada um dos nós da rede verificou de forma isolada se há ou não iminência de dano para a estrutura monitorada. Antes da fase de reação, o Delphos executa uma fase de **colaboração**, onde os nós cooperam com o objetivo de aumentar a confiabilidade da predição de dano e fornecer um único resultado final ao *sink* e ao atuador. Esse mecanismo de colaboração permite aumentar a confiabilidade do processo de predição de dano, pois considera-se que os nós da rede observam o estado da pá do aerogerador sob diferentes perspectivas ou ângulos, contribuindo para obter uma visão global sobre o estado de toda a estrutura. Além disso, a redundância dos nós da rede permite executar mecanismos de tolerância a falhas a fim de tornar o sistema mais confiável diante da ocorrência de falhas nos nós da rede.

Portanto, os nós efetuam uma troca de informações entre si, indicando se foi feita ou não alguma predição de dano. A predição é dita como válida nos casos em que mais de um nó tenha chegado a conclusão de que há iminência de dano. Este critério (mínimo de dois nós para validar uma predição) está relacionado ao fato de que a ocorrência de dano pode ser apenas percebida em alguns pontos da pá do aerogerador. Portanto, essa abordagem permite que o sistema identifique a ocorrência de dano em pontos específicos ao longo de toda a estrutura, mesmo que esse dano não comprometa todo o restante da pá do aerogerador.

Outra abordagem que poderia ser adotada seria a utilização de um percentual de nós da rede em vez de um número fixo. No entanto, essa abordagem poderia diminuir a capacidade do sistema em identificar danos em pontos específicos, pois um mesmo percentual pode resultar em um número grande de nós para validar uma previsão.

Diante de um conjunto de previsões realizadas por vários nós, o Delphos enviará ao *sink* e ao atuador a menor previsão de dano, ou seja, aquela previsão em que o tempo de reação (diferença entre o momento atual e o momento em que o dano irá ocorrer) seja o mais curto.

Para realizar esse mecanismo de colaboração entre os nós (e consequente encaminhamento do resultado final ao *sink* e ao atuador), adota-se uma estratégia de fusão de dados incorporada ao próprio algoritmo de roteamento de mensagens usada pela RASSF. De forma geral, os nós encaminham seus resultados de predição para seus vizinhos e esses avaliam se a previsão recebida é menor do que a previsão feita localmente. Ao final, a menor previsão é entregue ao *sink* e ao atuador.

**Portanto,** esse processo de colaboração é executado por todos os nós sensores, onde cada um desses nós comunica-se apenas com outros dois nós, denominados vizinhos anterior e posterior. Dois nós sensores assumem papéis específicos neste procedimento: *start\_node* e *end\_node*, onde o primeiro tem a responsabilidade de iniciar o processo de cooperação e o segundo finaliza o processo ao verificar as previsões feitas pelos demais nós da rede. Os demais nós da rede são denominados simplesmente como *nodes*.

Para iniciar o processo de colaboração, o *start\_node* envia uma mensagem ao seu vizinho posterior para que esse reencaminhe ao seu próprio vizinho posterior até que a mensagem alcance o *end\_node*. Dessa forma, a mensagem é roteada por uma **rota estática** que tem início no *start\_node* e término no *end\_node*.

Uma das principais vantagens em usar essa rota estática está relacionada ao fato de que não há necessidade de todos os nós estarem ao alcance uns dos outros (ou ao alcance do *sink/*atuador), permitindo uma maior economia de energia, pois cada nó pode ajustar a

potência do sinal para comunicar-se apenas com os seus vizinhos anterior e posterior. Outra vantagem é que o protocolo de roteamento está embutido na própria aplicação da RASSF, não sendo necessário o uso de mensagens adicionais para manter uma rota dinâmica.

A mensagem trafegada através dessa rota estática é do tipo PREDICAO\_DANO e sempre tem seu **recebimento confirmado** pelo nó destinatário, ou seja, pelo vizinho posterior. Essa mensagem é composta por 2 campos, onde o primeiro (*NrPrevisoes*) é usado para contabilizar a quantidade de nós que realizaram a predição e o segundo (*Indicacao*) armazena a indicação (coleta futura) de quando o dano irá ocorrer. Todos os nós (inclusive os nós *start\_node* e *end\_node*) verificam se foi feita previsão de dano e, em caso positivo, incrementam o campo *NrPrevisoes* e substituem a indicação de dano (no campo *Indicacao*) caso a indicação feita pelo nó seja menor do que a indicação presente na mensagem. Entretanto, o nó *end\_node* realiza uma tarefa em particular que está relacionada a verificar se o campo *NrPrevisoes* é maior do que o número de previsões necessários para se considerar a previsão como sendo válida. Caso a predição seja considerada válida, o *end\_node* envia ao seu vizinho posterior que exerce necessariamente os papéis de *sink* e atuador.

O Algoritmo 1 apresenta o algoritmo distribuído responsável por executar todo esse processo de colaboração. Esse algoritmo está descrito conforme a notação proposta por Andrews (ANDREWS 1991). Nessa notação, os processos (nós, no contexto da RASSF) trocam informações através de **canais** de comunicação. Ademais, assume-se que a rede de comunicação é confiável, ou seja, todas as mensagens são entregues sem erro e duas mensagens de um mesmo processo (nó) origem são entregues na mesma ordem de envio.

#### Algoritmo 1: Algoritmo distribuído responsável por efetuar o processo de colaboração

# canal usado para receber mensagens do vizinho anterior **chan** *canal\_vizinho\_anterior*[1..*n*](tipo\_msg) # canal usado para enviar mensagens do vizinho posterior **chan** *canal\_vizinho\_posterior[1..n]*(tipo\_msg) # tipo\_msg é composto por nr\_previsoes (número de previsoes feitas) # e indicacao (menor indicacao de dano). var msg : (tipo\_msg) # indica se o nó fez uma previsão local de dano **var** *dano\_previsto* : **boolean** # se uma previsao foi feita, indica quando o dano vai ocorrer var indicacao local : int # numero minimo de previsoes locais para validar uma previsao de dano na estrutura var nr\_previsoes\_validar: int *#* variáveis auxiliares var msg\_recebida: boolean := false var i: int

start\_node::

msg := prepara\_msg(dano\_previsto, indicacao\_local)
send canal\_vizinho\_posterior[i](msg)

### node[i: 1..n]::

```
processar_msg_predicao()
if msg_recebida = true
    send canal_vizinho_posterior[i](msg)
else
```

```
msg := prepara_msg(dano_previsto, indicacao_local)
send canal_vizinho_posterior[i](msg)
```

## fi

```
end_node::
```

msg := prepara\_msg(dano\_previsto, indicacao\_local)
send canal\_vizinho\_posterior[i](msg)

```
fi
```

É importante enfatizar que todos os nós participam desse processo de colaboração, mesmo que um determinado nó não tenha realizado nenhuma predição de dano. Durante esse processo pode haver algum nó que esteja indisponível e acabe afetando o roteamento de mensagens através da rota estática. Neste caso, o nó que enviou uma mensagem e não recebeu confirmação de seu vizinho posterior ao repetir três vezes este procedimento, irá aumentar sua potência de sinal de rádio a fim de alcançar o próximo vizinho. Outro ponto a ser mencionado é que os nós aguardam por um tempo determinado (*timeout*) para que uma mensagem seja recebida, onde cada nó possui um tempo diferente de expiração. Se ocorrer um timeout, o nó inicia por conta própria todo o processo de colaboração, assumindo temporariamente a denominação *start\_node*. Os nós possuem um tempo diferente de expiração, pois em caso de *timeout*, apenas um nó deverá assumir temporariamente o papel de *start\_node* por vez, enquanto os outros ainda devem ficar aguardando pelo recebimento da mensagem. Se os nós tivessem o mesmo tempo de timeout, todos iriam iniciar ao mesmo tempo o processo como *start\_node*, no caso de não receber nenhuma mensagem.

É importante destacar que essa topologia fixa (plana e linear) adotada neste mecanismo de colaboração é adequada ao formato das pás dos aerogeradores, já que essa estrutura apresenta uma forma retilínea que se mantêm por toda a sua extensão.

### 4.3.4 Fase de Reação

Executada a fase de colaboração, o Delphos passa a efetuar a fase de **reação**, caso o sistema tenha enviado um resultado final ao *sink* e ao atuador. Nesta fase, o nó *sink* envia um alarme para a rede externa e o atuador realiza ações de controle no ambiente a fim de evitar a ocorrência do dano previsto. Os componentes lógicos usados nesta fase são o Gestor, Atuação e Alarme.

A Figura 15 mostra o diagrama com a seqüência de ações executadas na fase de Reação. O componente Gestor solicita ao componente de Atuação que execute ações controle adequadas a fim de impedir a ocorrência de dano ou seu agravamento. Essa solicitação é feita através do comando *ExecAcoesControle(PredicaoDano)*, onde são passadas informações inerentes ao dano previsto através do parâmetro *PredicaoDano* (17).

Então, o componente Atuação executa o comando *IdentAçãoControle(PredicaoDano)* com o objetivo de identificar a ação de controle que esteja mais adequada ao dano previsto. Para isso, o componente Atuação acessa a base de Ações de Controle através do comando interno *IdentAçãoControle(PredicaoDano)* (18). Após verificar a ação de controle mais adequada, o componente Atuação, através do comando *AcionarAtuadores(AcaoControle)*, efetivamente aciona os atuadores para que esses dispositivos executem uma ação de controle no ambiente (19).



Figura 15. Diagrama de seqüência da fase de Reação.

Ao completar esse ciclo, o componente de Atuação informa ao componente Gestor qual foi a ação de controle executada no ambiente. De posse dessa informação (*AçãoControle*) e da predição de dano efetuada (*PredicaoDano*), o componente Gestor executa o comando *CriarAlarme*(*PredicaoDano*,*AcaoControle*) a fim de criar uma nova informação denominada *Alarme* (20). Em seguida, o componente Gestor solicita ao componente Alarme que envie um alarme a rede externa. Isso é feito ao se executar o comando *AlarmarIminenciaDano*(*Alarme*) (21). Ao receber essa solicitação, o componente Alarme executa o comando interno *AlarmarRedeExterna*(*Alarme*) para que a rede externa seja devidamente avisada quanto ao dano previsto e as ações de controle que foram efetuadas no ambiente. Enfim, o componente Alarme indica ao componente Gestor se o Alarme foi ou não enviado com sucesso.

### 5 Etapas de Pré-implantação do Delphos

Ao executar as duas fases de pré-implantação, o Delphos levará em conta a influência ambiental exercida sobre as frequências naturais. No entanto, pode-se optar para que o Delphos não leve em conta a questão da interferência ambiental. Para isso, basta efetuar apenas a segunda etapa de pré-implantação.

Os itens subsequentes descrevem os processos responsáveis por treinar o sistema nebuloso e estimar o modelo ARMA. Vale ressaltar que todas as etapas foram executadas em um computador central e não na RSSF. O processo de treinamento do ANFIS foi executado através do Matlab (KURIAN *et al.* 2006), e a estimação do modelo ARMA foi efetuada através do GNU Regression, Econometrics and Time-series Library (Gretl) (SHUKLA e JHARKHARIA 2011).

### 5.1 Treinamento do ANFIS

O ANFIS, conforme já mencionado, é utilizado para efetuar a criação do sistema nebuloso que desempenha o papel de Filtro de Interferências Ambientais. O processo de criação desse sistema nebuloso consiste em realizar um procedimento de treinamento, onde são passadas informações de entrada relacionadas com a saída desejada. Para realizar esse treinamento, foi criada uma base denominada **Base de Dados de Treinamento do ANFIS**, onde estão relacionados valores de temperatura, frequência natural influenciada pela temperatura (valores originais de frequência natural) e valores de frequência natural sem a influência da temperatura (**frequência natural filtrada**).

Antes de gerar o sistema nebuloso definitivo, é preciso efetuar uma variação sistemática dos parâmetros do ANFIS a fim de determinar o conjunto de parâmetros que resultam no sistema nebuloso mais adequado ao problema (que apresente o menor erro de treinamento). Os parâmetros, conforme já mencionado, são: (i) número de conjuntos nebulosos (rótulo) por variável de entrada, (ii) tipo de função de pertinência que será usada nas variáveis de entrada e (iii) tipo de função de pertinência que será usada na variável de saída.

O processo de calibração do ANFIS utilizou dois critérios de parada no que tange a execução do treinamento: o número de épocas de treinamento (ciclos) e o erro quadrático médio. Nesse trabalho levou-se em conta como critério de parada um erro suficientemente pequeno (em torno de 0,000001) em conjunto com um número máximo de épocas de treinamento. Testes preliminares demonstraram que um número de épocas igual a 10 era

suficiente para se alcançar um erro quadrático médio satisfatório. A variação desses três parâmetros permitiu obter um total de 56 configurações diferentes para esse sistema nebuloso.

A Tabela 1 apresenta as dez primeiras configurações de parâmetros do ANFIS que apresentaram os menores erros quadráticos médios para um número de épocas igual a dez (10) e um erro quadrático médio em torno de 0,000001.

Número Rótulos Variável Temp.	Número Rótulos Variável Freq.	Função de Pertinência Variável Entrada	Função de Pertinência Variável Saída	Erro
3	3	Pi-Shaped	Linear	0,000001223945920
3	3	Trapezoidal	Linear	0,000001383552562
3	3	Product of two sigmoid Linear		0,000001423556266
3	3	Difference between two sigmoidal	Linear	0,000001430142369
5	3	Pi-Shaped	Linear	0,000001495273391
3	3	Two-sided Gaussian	Linear	0,000001569159673
5	3	Difference between two sigmoidal	Linear	0,000001676435759
5	3	Product of two sigmoid	Linear	0,000001689430245
5	3	Two-sided Gaussian	Linear	0,000001708942451
5	3	Trapezoidal	Linear	0,000001718828823

Tabela 1. Configurações de parâmetros que apresentaram menores erros

Os resultados descritos na Tabela 1 demonstram que os dez menores erros foram alcançados pelo ANFIS quando esse usou a função de saída **Linear** (e não a função de saída **Constante**). Outro ponto a ser mencionado é que os quatro menores erros foram alcançados pelo ANFIS quando esse determinou como três a quantidade de rótulos de ambas as variáveis de entrada (temperatura e frequência). Portanto, ao analisar os resultados foi possível determinar o conjunto de parâmetros de treinamento que apresentou o menor erro quadrático médio, ou seja, um erro em torno de 122 x  $10^{-6}$ . Diante dessa análise, foi escolhido um sistema nebulosos com **três rótulos** (conjuntos nebulosos) por variável de entrada, a função de pertinência de entrada **Pi-Shaped** e a função de pertinência de saída **Linear**.

### 5.2 Estimação do Modelo ARMA

O modelo estatístico ARMA, conforme já mencionado, é utilizado para previsão de séries temporais de forma a inferir sobre valores futuros dessa mesma série. O ARMA acompanha o comportamento da série temporal, utilizando dados históricos, para ser capaz de predizer valores futuros.

No contexto desse trabalho, o modelo ARMA é utilizado para observar o estado da estrutura ao longo do tempo a fim de predizer quando a estrutura irá se encontrar em um estado de dano. Para isso, o modelo ARMA acompanha e realiza previsões a partir da variação de frequência natural que é o valor absoluto da subtração entre a frequência natural obtida no momento t e a frequência natural coletada no início do monitoramento (assinatura saudável da estrutura) conforme descrito na Equação 1.

Para realizar a estimação do modelo ARMA é preciso usar uma série temporal que apresente características aproximadas do que será encontrado na série a ser prevista. A essa série denomina-se **Evolução de Dano**. As próximas subseções apresentam a definição da Evolução de Dano e o processo de estimação do modelo ARMA.

### 5.2.1 Definição de Evolução de Dano

Uma Evolução de Dano consiste de valores de variação de frequência (livre da influência da temperatura) que evoluem de um estado normal para um estado de dano. Sendo assim, pode-se criar diferentes Evoluções de Dano para representar tipos diferentes situações de ocorrência de dano. Portanto, este trabalho propõe diferentes perfis de Evolução de Dano: Linear, Côncavo Suave, Côncavo Acentuado e Convexo.

O perfil Linear representa as situações onde o estado do aerogerador vem sofrendo desgaste constante ao longo do tempo, mas sem apresentar a ocorrência de dano brusca. Um exemplo desse tipo de perfil são os casos em que o desgaste do aerogerador se dá por conta de sua carga operacional e não por fatores externos como ocorre com as tempestades.

O perfil Côncavo Suave está relacionado aos casos em que o estado da pá do aerogerador permanece inalterado por certo tempo, mas é acometido de um crescimento exponencial a partir de um determinado ponto. Esse perfil, assim como o Linear, também exemplifica uma situação em que o desgaste é operacional, mas com o diferencial de apresentar uma evolução levemente mais acentuada do que a Linear.

O perfil Côncavo Acentuado está ligado às circunstâncias em que o estado do aerogerador permanece inalterado por boa parte do tempo, sendo que no final do período sofre de um dano brusco. Esse dano pode ser causado por fatores externos como pássaros ou ventos fortes oriundos de tempestades.

Por fim, o perfil Convexo é aquele em que o aerogerador apresenta, logo no início do período, uma grande variação em seu estado, mas esse estado permanece em crescimento constante a partir desse evento inicial. Assim como no perfil Côncavo Acentuado, o perfil

Convexo também está relacionado à evolução brusca causada por fatores externos. No entanto, a principal diferença é que, no perfil Convexo, a pá do aerogerador é acometida por esse fator externo no início de sua operação.

Considera-se neste trabalho a Evolução de Dano como tendo perfil linear, representando as situações reais onde o estado da pá sofre desgaste constante ao longo do tempo. É importante enfatizar que esse perfil linear de Evolução de Dano não leva em conta a ocorrência brusca de dano, como acontece nos casos em que a pá é acometida por circunstâncias extremas (por exemplo, em tempestades com ventos acima de 70 km/h). Definida a Evolução de Dano, a próxima subseção apresenta o processo de estimação do modelo ARMA.

### 5.2.2 Processo de Estimação do Modelo ARMA

A estimação do modelo ARMA segue o método proposto por Box e Jenkins (MAKRIDAKIS *et al.* 1998) conforme descrito na seção 2.4, onde são executados cinco passos (divididos em três fases) com o objetivo de escolher o modelo ARMA mais adequado. Todos esses passos foram executados com o auxílio do pacote estatístico GRETL (*Gnu Regression, Econometrics and Time-series Library*) que é livre e está sob a licença GPL (*Gnu Public License*) (SHUKLA e JHARKHARIA 2011).

A primeira fase, denominada **Identificação**, contempla a execução dos dois primeiros passos do método. No primeiro passo (**Preparação dos Dados**), os dados foram visualmente analisados a fim de identificar a necessidade de usar uma variação do modelo ARMA (primeiro passo do método). Além de a série temporal ter sido visualmente avaliada, foram verificados os correlogramas gerados a partir das Funções de Autocorrelação (FAC) e Autocorrelação Parcial (FACP) a fim de identificar características de estacionariedade e sazonalidade (conceitos descritos na seção 2.4). Tanto a análise visual quanto a FAC e a FACP revelaram que a Evolução de Dano é uma série temporal não–estacionária conforme apresentado nos correlogramas da Figura 16.

Pode-se observar no correlograma da Figura 16 gerado a partir da FAC (sigla ACF no gráfico), que os valores decaem muito lentamente, indicando **a presença de não-estacionariedade** na série temporal (EHLERS 2009).

Conforme mencionado na seção 2.4, em algumas situações é possível obter uma indicação de ordem do modelo ao se avaliar o correlograma gerado a partir de uma FACP. Esse é o caso da série temporal de Evolução de Dano, visto que o correlograma da Figura 16 gerado a partir da FACP

(sigla PACF no gráfico) apresenta a primeira defasagem com um valor significantemente diferente de zero (fora do intervalo de confiança de 95% que está delimitado no gráfico por linhas contiguas paralelas). Esse comportamento indica adequação da série a um modelo Auto-regressivo de ordem 1 (MORETTIN e TOLOI 2006).



Figura 16. Correlogramas das Funções de Autocorrelação (ACF) e Autocorrelação Parcial (PACF)

Neste caso, onde a série é não-estacionária, é preciso adotar uma variação do ARMA denominada ARMA integrado ou **ARIMA** (do inglês, *Autoregressive Integrated Moving Averages*). O modelo ARIMA é capaz de ser aplicado diretamente em séries temporais não-estacionárias, sem a necessidade de realizar alterações nos dados originais. Isto é possível, pois o modelo ARIMA efetua um cálculo de diferenciação (subtrair o valor atual pelo valor anterior) diretamente na série temporal a fim de torná-la estacionária. Sendo assim, é preciso determinar uma terceira ordem do modelo (além da ordem de auto-regressão e de médias móveis) denominada **ordem de diferenciação**.

A ordem de diferenciação determina a quantidade de vezes que o modelo deverá realizar uma diferenciação na série. Geralmente obtêm-se uma série estacionária ao se aplicar uma primeira diferenciação na série original (EHLERS 2009). A fim de constatar se apenas a aplicação da primeira diferenciação é suficiente para tornar a série estacionária, foi avaliado



novamente o correlograma gerado pelas FAC e FACP a partir da série diferenciada. A Figura 17 ilustra esses correlogramas.

Figura 17. Correlogramas das Funções de Autocorrelação (ACF) e Autocorrelação Parcial (PACF) para a primeira diferenciação da série

Observar-se nos correlogramas da Figura 17 que os valores não sofrem mais o decaimento lento observado na Figura 16. Esse comportamento indica que apenas a primeira diferenciação já é suficiente para tornar a série estacionária. Portanto, o modelo ARIMA a ser adotado deve ter uma ordem de diferenciação igual a 1.

Identificada a variação do modelo a ser usada, pode-se partir para o segundo passo (**Seleção do Modelo**), também relacionado a primeira fase do método de Box e Jenkins, que corresponde a seleção da ordem do modelo. Para tal, foram avaliados modelos ARMA (variando-se de 1 até 5 para ambas as partes AR e MA) de acordo com os critérios AIC (AKAIKE 1974), BIC (SCHWARZ 1978) e HQC (HANNAN e QUINN 1979). Os resultados estão descritos na Tabela 2.

A Tabela 2 não apresenta todos os 25 modelos, pois alguns não atingiram o critério de convergência do processo de estimação. No entanto, diante dos modelos que foram corretamente estimados, deve-se considerar como mais adequado o modelo que apresentou os menores valores para os critérios AIC, BIC e HQC conforme descrito na seção 2.4. O modelo

que se encaixa neste critério é ARMA(1,1), pois esse apresentou os menores valores para os três critérios, sendo -1704.759, -1693.093 e -1700.121 para os critérios AIC, BIC e HQC, respectivamente. Esse resultado confirma a afirmação de que o modelo adequado deve ser o parcimonioso, ou seja, aquele que apresenta o menor número de parâmetros. Outro ponto a ser ressaltado, é que a escolha pelo ARMA(1,1) confirma a percepção inicial levantada pelo correlograma da FACP, onde a série temporal seria adequadamente ajustada por um modelo Auto-regressivo de ordem 1.

Ordem		Critérios				
AR	MA	AIC	BIC	HQC		
1	1	-1704,759	-1693,093	-1700,121		
1	2	-1702,938	-1687,383	-1696,754		
3	2	-1703,031	-1679,731	-1693,765		
1	3	-1701,471	-1682,026	-1693,74		
1	4	-1701,445	-1678,112	-1692,168		
1	5	-1700,353	-1673,131	-1689,531		
3	1	-1697,191	-1677,774	-1689,47		
2	4	-1699,657	-1672,454	-1688,841		
4	5	-1702,274	-1663,469	-1686,841		
4	1	-1692,743	-1669,459	-1683,483		
5	3	-1688,193	-1653,293	-1674,312		
5	4	-1686,701	-1647,924	-1671,278		
5	5	-1687,559	-1644,904	-1670,593		
5	2	-1676,494	-1645,472	-1664,155		
5	1	-1667,723	-1640,579	-1656,927		

Tabela 2. Resultados dos critérios AIC, BIC e HQC

A fase seguinte, denominada **Estimação e Testes**, contribui com o terceiro e quarto passos do método de Box e Jenkins. O terceiro passo (**Estimação**) versa sobre a estimação dos coeficientes  $\boldsymbol{\varphi} \in \boldsymbol{\theta}$  para que o modelo consiga refletir o comportamento da série. Para isso, foi usado o método da *Máxima Verossimilhança Condicional* (BOX *et al.* 1994) que resultou na estimação dos coeficientes  $\boldsymbol{\varphi} \in \boldsymbol{\theta}$ , como sendo os valores 0,996866 e -0,938784, respectivamente. A Equação 5 apresenta o modelo ARIMA adotado.

# $X_t = (X_{t-1} - X_{t-2}) * 0,996866 + X_{t-1} + \varepsilon_{t-1} * -0,938784$ Equação 5. Modelo ARIMA estimado

O quarto passo do método (**Diagnóstico**), também pertencente a segunda fase, tem a função de avaliar o modelo que fora estimado. Conforme descrito na seção 2.4, os correlogramas da série original e dos resíduos do modelo estimado devem ter comportamento similar para que o modelo estimado seja considerado adequado. Portanto, a Figura 18 permite

comprovar que os correlogramas dos resíduos são similares aos correlogramas gerados a partir da série original (apresentados na Figura 17).



Figura 18. Correlogramas dos resíduos do modelo estimado

A última fase do método de Box e Jenkins, denominada **Aplicação**, determina que seja executado o quinto e último passo do método (**Previsão**). Esse passo apenas informa que o modelo ARMA está pronto para ser usado para realizar previsões conforme os coeficientes e ordem que foram estimados e testados.

É importante destacar que um segundo modelo ARMA foi estimado com a finalidade de ser usado pelo sistema em caso de não ser efetuada a primeira etapa de pré-implantação (ANFIS), ou seja, caso o sistema não leve em conta a influência das variáveis ambientais nas frequências naturais. Esse segundo modelo foi estimado a partir de uma Evolução de Dano com influência da temperatura, usando o mesmo método descrito anteriormente, ou seja, o método proposto por Box e Jenkins (MAKRIDAKIS *et al.* 1998). O modelo resultante está descrito na Equação 6.

 $X_t = (X_{t-1} - X_{t-2}) * -0,280764 + X_{t-1} + \varepsilon_{t-1} * -0,517440$ 

Equação 6. Modelo ARIMA (sob influência da temperatura)

### 6 Experimentos Realizados com o Delphos

Esta seção descreve os experimentos realizados neste trabalho e apresenta uma comparação entre o desempenho do Delphos em termos de acerto de predição e de outro sistema de predição de dano da literatura.

Foram efetuados experimentos para coleta de dados de vibração e experimentos com o Delphos utilizando um simulador e sensores reais. Os experimentos para coleta de dados de vibração permitiram obter dados reais de frequências naturais para que o Delphos pudesse ser testado com dados reais da pá de um aerogerador. Os experimentos simulados tiveram como objetivo (i) avaliar a eficiência do sistema em termos de acerto de predição, considerando ou não interferência ambiental, (ii) avaliar а 0 ganho da descentralização em termos de tempo e energia, e (iii) analisar o impacto do Delphos na RASSF em termos de tempo de vida da rede e consumo de memória RAM e ROM. Por fim, os experimentos usando sensores reais tiveram a finalidade de validar os experimentos simulados de eficiência através de experimentos realizados em uma plataforma real de sensores.

Mais especificamente, os experimentos simulados de eficiência tiveram a finalidade de verificar o desempenho do Delphos em realizar predições corretas a fim de comprovar frequência que influência da temperatura realmente compromete a acurácia do processo de predição de dano. Ademais, ambos os experimentos simulados de eficiência consistem em primeiro executar a calibração dos parâmetros do Delphos e, em seguida, analisar a eficiência do sistema de acordo com os parâmetros escolhidos na calibração.

Os experimentos simulados para avaliar o ganho da descentralização tiveram a finalidade de constatar que o sistema fornece uma **resposta mais ágil** ao executar o processo descentralizado de predição de dano, além de comprovar que há uma economia de energia dos nós sensores ao utilizar essa abordagem descentralizada. Portanto, são avaliados o maior consumo de energia dentre os nós da rede e o tempo de resposta fornecido pelo sistema.

### 6.1 Limitações do Ambiente do Experimento de Coleta de Dados de Vibração

Antes de apresentar a descrição e os resultados do experimento usado para coletar dados de vibração da pá de um aerogerador, destacamos algumas limitações relacionadas ao ambiente desses experimentos e como cada uma dessas limitações foi superada.

### 6.1.1 Inserção Artificial de Dano

Ao realizar a coleta de dados reais de vibração, foi preciso utilizar um método de inserção artificial de dano, pois não era possível causar danos reais na pá do aerogerador.

Portanto, foi utilizado o método de variação artificial de massa que é um método similar ao que foi utilizado em (CLAYTON *et al.* 2006). De acordo com esse método, é possível simular a inserção de dano ao adicionar massa a estrutura, sem ter a necessidade de danificar realmente a estrutura que está sendo analisada. Sendo assim, durante os experimentos de coleta de dados de vibração, foi adicionada gradativamente massa a estrutura, sendo efetuada uma coleta de dados a cada acréscimo de massa. Em cada experimento de coleta, a estrutura da pá apresentava um dano cuja gravidade foi associada respectivamente a um dos seguintes pesos: 0, 100, 250, 500, 750, 1000, 1250, 1750 e 2000 gramas.

### 6.1.2 Simulação da Influência da Temperatura sobre as Frequências Naturais Coletadas

Ao realizar os experimentos de coleta de dados de vibração, não dispúnhamos de um ambiente controlado, como uma câmara climática, para variar sistematicamente a temperatura a fim de identificar a influência causada por essa variável ambiental nas frequências naturais da pá do aerogerador. Portanto, foi preciso buscar na literatura informações que pudessem oferecer plenas condições de causar influência da temperatura nas frequências naturais da pá do aerogerador.

Dessa forma, a partir dos resultados apresentados nos dois trabalhos encontrados na literatura (GRIFFITH *et al.* 2006) e (XIA *et al.* 2010) foi possível estimar uma função que relaciona a influência da temperatura nas frequências naturais da pá de um aerogerador.

Os resultados obtidos no trabalho de (GRIFFITH *et al.* 2006) mostraram que, em média, a frequência natural diminuiu 0.078 hertz quando o valor da temperatura aumentou de 1 grau para 11 graus (variação de temperatura de dez graus Celsius). Os autores em (XIA *et al.* 2010) mostraram que a influência da temperatura nas frequências naturais segue um comportamento linear. Tomando como base os resultados de ambos os trabalhos, (XIA *et al.* 2010) e (GRIFFITH *et al.* 2006), calculamos a influência da temperatura nas frequências naturais segue um comportamento ou sem presença de dano fazendo uso de uma regressão linear.

A Equação 7 apresenta a função da regressão linear de influência da temperatura sobre as frequências naturais, onde F representa a frequência que será influenciada pelo valor de temperatura da variável T. Como resultado, a equação fornece F' que representa a frequência alterada pela influência da temperatura. O valor constante 26 está relacionado com a

temperatura usada como referência quanto a influência na frequência natural foi considerada nula. Já a constante 0,078 tem relação com a variação de frequência natural observada a cada 10 graus Celsius de variação de temperatura.

$$F' = (T - 26) * -\left(\frac{0,078}{10}\right) + F$$

### Equação 7. Influência da temperatura na frequência natural

A partir da definição da função da regressão linear de influência da temperatura sobre as frequências naturais, é preciso determinar quais serão os valores de temperatura que serão considerados nesse trabalho. Os valores de temperatura foram escolhidos com base na sensibilidade da placa de sensoriamento MTS400. Essa placa de sensoriamento é usada na plataforma MICAz para obter dados de umidade, temperatura, luminosidade e aceleração. Segundo informações da empresa que comercializa a placa de sensoriamento MTS400, o sensor é capaz de observar variações de temperatura entre o intervalo -10 e 60 graus Celsius (MEMSIC MICAZ 2012).

### 6.1.3 Simulação de Evolução de Dano Real

Como não era possível realizar um grande número variações de massa na pá do aerogerador, foi necessário criar uma maneira de simular diferentes evoluções de dano real. Para simular diferentes evoluções de dano é necessário utilizar os dados reais coletados e derivar uma função que relacione gravidade de dano e frequência natural.

Uma maneira de derivar essa função é utilizar técnicas de regressão linear, quadrática ou cúbica. As funções estimadas a partir dessas regressões são comparadas quanto ao coeficiente de determinação ajustado (R<sup>2</sup> - adj) a fim de identificar a função que obteve mais sucesso ao tentar se ajustar aos pontos apresentados (SEBER 1977). Valores próximos de 100% significam que há uma forte correlação entre a função estimada e os pontos apresentados.

### 6.2 Experimentos Realizados para a Coleta de Dados de Vibração

Os experimentos descritos nesta seção usaram dados reais de frequência natural da pá de um aerogerador, modelo Notus 112/138 da empresa Enersud (ENERSUD, 2012).

Para realizar a análise modal foi escolhido o uso de um martelo de impulsos dentre os possíveis métodos de excitação (FARRAR *et al.*, 2003), para introduzir uma excitação no sistema que evidencie os modos de vibração. A escolha desse método de excitação tem como vantagens a não necessidade de se fixar um equipamento de excitação e a possibilidade de

controlar a geração de um sinal (COUTO 1995). Foi usado um acelerômetro para adquirir medidas de aceleração (vibração) em um ponto da superfície da estrutura.

Os dados de frequência natural foram coletados diretamente da pá de um aerogerador instalada em um ambiente controlado no Laboratório de Redes e Multimídia (LabNet) do Instituto Tércio Pacitti de Aplicações e Pesquisas Computacionais (iNCE) da Universidade Federal do Rio de Janeiro (UFRJ). Para realizar essa coleta de dados de frequência, foi usada a plataforma *Imote2* acoplada à placa de sensoriamento ITS400 (MEMSIC IMOTE2 2012), a qual possui sensores de vibração (acelerômetro), temperatura, umidade e luminosidade. O *Imote2* foi conectado a um computador convencional a fim de armazenar as medidas de vibração coletadas da estrutura da pá.

Neste trabalho foram realizados nove (9) experimentos de coleta de dados. Nesses experimentos não foi considerada a influência da temperatura na frequência de vibração da pá. Em cada experimento de coleta, a estrutura da pá apresentava um dano cuja gravidade foi associada respectivamente a um dos seguintes pesos: 0, 100, 250, 500, 750, 1000, 1250, 1750 e 2000 gramas. Cada um dos dados de vibração coletados foi convertido do domínio de tempo para o domínio de frequência através da aplicação do método de FFT conforme mencionado no item 2.2.1. Em todos os experimentos foram efetuadas 30 coletas dos dados de vibração (aceleração), considerando-se intervalo de confiança de 95%.

A análise dos espectros de frequência revelou a presença de três modos de frequências naturais. Entretanto, conforme já dito na seção 4.1, usaremos apenas o **primeiro modo** de frequência natural, já que esse denota o **comportamento global da estrutura.** É importante dizer que a gravidade de dano correspondente a 0 gramas representa nenhum acréscimo de massa à estrutura da pá do aerogerador, ou seja, a estrutura está saudável. Portanto, a frequência obtida quando a estrutura está saudável é considerada como a **assinatura saudável da estrutura** conforme mencionado na seção 2.2.1. A Tabela 3 apresenta as frequências obtidas (juntamente com os valores do intervalo de confiança de 95%) de acordo com cada acréscimo de massa efetuado na estrutura. Esses resultados foram armazenados na **Base de Coleta**.

Gravidade de Dano (g) Média (hz) Desvio Padrão L. Inf. (hz) L. Sup. (hz) 20,08 20,16 0 20,12 0,11 100 0,12 19,54 19,50 19,59 250 18,90 18,94 0,11 18,86 500 18,39 0,39 18,25 18,53

Tabela 3. Frequências obtidas no experimento de coleta de dados de vibração

750	17,56	0,50	17,38	17,74
1000	16,55	0,22	16,48	16,63
1250	15,93	0,13	15,88	15,97
1500	13,00	1,01	12,64	13,36
1750	12,51	0,00	12,51	12,51
2000	12,51	0,00	12,51	12,51

### 6.3 Definição da Base de Dados de Experimentos

A partir dos dados de frequência natural obtidos no experimento para coleta de dados de vibração foi possível definir uma base de dados para realizar os experimentos simulados e usando sensores reais. Esta base de dados permitiu avaliar a capacidade do Delphos de prever dano em diversas situações, ou seja, o sistema deve ser posto a prova em diversas situações de acordo com diferentes Evoluções de Dano (amostras). Por isso, esta base de dados de experimento é composta por um conjunto de situações diferenciadas, considerando a estrutura com e sem a presença de dano.

Uma situação com presença de dano está relacionada com o conceito de "Evolução de Dano", o qual é caracterizado pela variação de frequências naturais ( $\Delta \omega$ ) que evoluem de zero até um valor que excede o limite **T**. Já uma situação sem presença de dano está relacionada com o conceito de "Evolução sem Dano", o qual é caracterizado por uma seqüência de valores aleatórios de variação de frequência que estão dentro do intervalo que é considerado normal para o estado da estrutura. Neste trabalho, considerou-se como variação normal o intervalo de confiança de 95% obtido quando a estrutura esteve em um estado saudável. A Figura 19 exemplifica duas curvas de evolução, sendo uma Evolução de Dano e outra Evolução sem Dano.



Figura 19. Exemplos de Evolução de Dano e sem Dano

Para armazenar as evoluções de dano e sem dano, foi criada uma base de dados denominada **Base de Experimentos**. Cada evolução (com ou sem dano) está relacionada a um ano de coletas (sendo uma coleta por dia). A Base de Experimentos contém 100 evoluções, sendo 40 evoluções destinadas para **efetuar a calibração do Delphos** e outras 60 evoluções disponíveis **para os experimentos de eficiência**. Das 40 evoluções para calibração, 20 são evoluções sem dano e 20 são evoluções com presença de dano. Em relação as 60 evoluções para os demais experimentos, 30 são evoluções com presença de dano e 30 são evoluções sem presença de dano.

Apesar da quantidade de evoluções serem diferentes, ambos os experimentos utilizam a mesma quantidade de evoluções, isto é, 40 evoluções. A quantidade de evoluções para a calibração difere da quantidade de evoluções para os experimentos de eficiência, pois nesses últimos é variada a distribuição de amostras de evolução. Portanto, são realizados experimentos em que considera-se 75% de evoluções sem dano e 25% de evoluções com presença de dano, ou seja, perfazendo um total de 30 evoluções sem dano e 10 evoluções com presença de dano.

O número total de 40 evoluções é suficiente para cobrir a vida útil de um aerogerador que é de aproximadamente 20 anos (caso do modelo Northern Power® 100) (NORTHERN 2012), já que uma evolução dura aproximadamente 1 ano. É importante mencionar que a ordem das evoluções submetida aos simuladores foi aleatória.

### 6.4 Cenário dos Experimentos

Para os experimentos realizados com o Delphos foram considerados cenários onde os seguintes parâmetros foram variados: (i) número de nós sensores, (ii) número de nós defeituosos e (iii) distribuição de amostras de Evolução com ou sem dano.

Os experimentos simulados de eficiência (considerando ou não a interferência ambiental) usaram cenários onde todos esses parâmetros foram variados, enquanto que os experimentos de impacto na RASSF (especificamente o experimento de avaliação de tempo de vida da rede) consideraram apenas cenários nos quais apenas o número de nós defeituosos e o número de nós sensores foram variados. Por fim, os experimentos realizados com a plataforma real de sensores variaram apenas o número de nós defeituosos. Os experimentos de calibração efetuados em cada experimento de eficiência não consideraram nenhum dos parâmetros acima, pois o objetivo era verificar o funcionamento do sistema (frente à variação de parâmetros do Delphos) de forma isolada e sem nenhuma influência adicional.

O número de **nós sensores** foi variado com a finalidade de avaliar o desempenho do sistema em termos de acertos de predição quando a RASSF é composta por um maior número de nós sensores. Essa avaliação foi feita, pois espera-se empregar um número maior de sensores para realizar o monitoramento nas pás de um aerogerador. Essa afirmação deriva do fato de que as pás devem sofrer um aumento significativo de tamanho, já que uma pá mais longa (e leve) tende a apresentar um melhor desempenho ao gerar energia (SWARTZ et al. 2008). Nesses experimentos foram considerados três diferentes cenários de RASSF compostos por seis, doze e dezoito nós sensores e um nó adicional exercendo ambos os papéis de *sink* e atuador. Em todos esses cenários os nós sensores foram distribuídos na superfície da pá de um aerogerador que mede em torno de 15 metros. A distância entre cada um dos nós foi de 2.5, 1.25 e 1 metro para os cenários de seis, doze e dezoito sensores, respectivamente. A Figura 20 ilustra o cenário de RASSF composto por seis nós sensores.

Nesses experimentos, o Delphos foi testado levando em conta um modelo de falhas a fim de verificar a sua eficiência em termos de acertos de predição quando há nós na rede apresentando falhas em seu funcionamento. Para isso, é considerada a existência de **nós defeituosos** que apresentam um funcionamento incorreto durante a operação do sistema devido a **erros de imprecisão** no acelerômetro ou no sensor de temperatura. Com a finalidade de simular esse comportamento de falha, alguns nós tiveram o seu código propositalmente alterado para refletir a ocorrência de erros de imprecisão nas leituras dos sensores de vibração

e temperatura. Nesses experimentos, o número de nós defeituosos variaram entre 0 e 4, de um em um.



Figura 20. Cenário de RASSF contendo seis nós sensores

A distribuição de amostras está relacionada ao percentual de amostras de Evolução com e sem presença de dano que são usadas em cada rodada de simulação, e tem a finalidade de avaliar se diferentes distribuições afetam ou não o desempenho da solução em termos de realizar predições corretas. A distribuição de amostras foi variada entre 50% com dano e 50% sem dano, 25% com dano e 75% sem dano e, por fim, 75% com dano e 25% sem dano. É interessante ressaltar que a distribuição de amostras de Evolução determina a quantidade de situações (Evoluções) que serão utilizadas em uma determinada rodada de simulação. Portanto, considerando uma distribuição de 50% com dano e 50% sem dano, pode-se afirmar que a simulação será efetuada com 20 Evoluções com dano e 20 Evoluções sem dano, para um total de 40 Evoluções avaliadas durante cada simulação.

### 6.5 Descrição das Métricas

Os experimentos para avaliar o tempo de vida da rede usaram a métrica definida como **tempo de vida da rede**. Como existem diferentes definições para tempo de vida de RASSF, neste trabalho, definimos como sendo o tempo decorrido desde o início de execução do sistema (rede ligada) até o momento em que a rede não seja mais capaz de efetuar sua função principal. A RASSF considerada tem a função principal de realizar a predição de danos, que só pode ser feita com no mínimo 2 nós, devido ao processo de colaboração descrito na seção 4.3.3.

Os experimentos para avaliar o ganho da descentralização utilizaram as métricas de **tempo de resposta** e **consumo de energia médio**. O tempo de resposta é definido como o

tempo decorrido entre o início da execução do sistema e a chegada de uma mensagem ao atuador, indicando que uma ação de controle deve ser executada. O consumo de energia médio é obtido ao calcular a média dos consumos apresentados por todos os nós sensores da rede.

Já os experimentos de eficiência (simulados e usando a plataforma real de sensores) usaram as seguintes métricas: falsos positivos (FP), falsos negativos (FN), verdadeiros positivos (VP), verdadeiros negativos (VN). Os experimentos de calibração, que são executados antes dos experimentos de eficiência, usaram algumas métricas adicionais: sensibilidade, especificidade e acurácia. Todas essas métricas são definidas a seguir.

É considerado como um **verdadeiro positivo** os casos em que o sistema prevê um dano e esse dano realmente ocorre no momento apontado pelo sistema, considerando a margem de erro (parâmetro a ser definido na seção 6.7.1). Já um **falso positivo** ocorre nos casos em que o sistema prevê a ocorrência de um dano e esse dano não ocorre. É considerado como **verdadeiro negativo** a situação em que o sistema não prevê um dano e o dano realmente não ocorre. Já o **falso negativo** é observado nos casos em que o dano não é previsto, mas ocorre.

Utilizando as métricas anteriormente descritas, é possível derivar outros tipos de medidas que permitem traçar curvas ROC (*Receiver Operating Characteristics*) (SALFNER *et al.* 2010). As métricas são a especificidade, sensibilidade e acurácia. A **especificidade** é definida como a razão entre os verdadeiros negativos e a soma entre os falsos positivos e os verdadeiros negativos, e é usada para calcular a proporção de verdadeiros negativos que são corretamente identificados pelo sistema. Em outras palavras, a especificidade demonstra a habilidade do sistema na tarefa de realizar a predição de dano. A Equação 8 apresenta a fórmula usada para calcular a **especificidade**.

# $Especificidade = \frac{VN}{VN + FP}$

### Equação 8. Cálculo da métrica da Especificidade

Já a Equação 9 define a fórmula utilizada para computar a **sensibilidade** que é a razão entre os verdadeiros positivos e a soma entre os falsos negativos e os verdadeiros positivos, e é usada para calcular a proporção de verdadeiros positivos que são corretamente identificados pelo sistema. Portanto, a sensibilidade permite verificar a habilidade do sistema em identificar uma condição normal, ou seja, sem que haja dano iminente.

$$Sensibilidade = \frac{VP}{VP + FN}$$

### Equação 9. Cálculo da métrica de Sensibilidade

Por fim, a Equação 10 apresenta o cálculo que permite identificar a **acurácia** do sistema. Essa métrica é definida como a razão entre a soma dos verdadeiros negativos e verdadeiros positivos, e a soma entre todas as outras métricas (VP, VN, FP, FN). A acurácia é usada para calcular a proporção de verdadeiros, tanto positivos ou negativos, diante do total de situações avaliadas.

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN}$$

### Equação 10. Cálculo da métrica de Acurácia

### 6.6 Configuração do Ambiente dos Experimentos

Em todos os experimentos realizados com o Delphos, a RASSF foi composta por sensores MICAz. A plataforma MICAz possui 4kB de memória RAM, 128 kB de memória *flash* para armazenamento de programas e 512 kB para armazenamento de dados. Essa plataforma é alimentada por duas baterias AA (1202 mAh) que fornecem aproximadamente 16000 Joules de energia (KRÄMER e GERALDY 2006).

O Delphos foi implementado usando o ambiente de desenvolvimento TinyOS (LEVIS e GAY 2009), versão 2.1.1, e a linguagem de programação NesC (LEVIS e GAY 2009). O TinyOS fornece uma série de componentes de software, incluindo componentes que implementam a pilha de protocolos de comunicação para RAASF. Os experimentos simulados utilizaram o simulador AVRORA (ALBEROLA e PESCH 2009).

Já os experimentos com sensores reais foram efetuados em um ambiente controlado, dentro do Laboratório de Redes sem Fio (LabNet) do Programa de Pós-Graduação em Informática da UFRJ. Um mesmo nó foi utilizado para executar os papéis de *sink* e atuador, estando acoplado a um PC equipado com um processador Intel Core 2 Duo 2.80GHz e 4 GB de RAM. Esse nó atuador foi programado para acionar seus LEDS a fim de indicar que uma ação de controle foi executada.

O Delphos foi implementado como oito novos componentes do TinyOS. Os componentes GestorC, MonitoramentoC, TratamentoDadosC, FiltroInterferenciasAmbientaisC, DecisaoAnormalidadeC, PredicaoDanoC, AtuacaoC, and AlarmeC implementam as funções dos componentes Gestor, Monitoramento, Tratamento de Dados, Filtro de Interferências Ambientais, Decisão de Anormalidade, Predicao de Dano, Atuação e Alarme, respectivamente.

A entrega ordenada de mensagens, que é um pré-requisito do processo de colaboração
descrito na seção 4.3.3, foi garantida através do protocolo de confirmação de mensagens disponível nativamente no TinyOS. Portanto, para implementar essa confirmação de mensagens no Delphos foi utilizada a interface PacketAcknowledgements do componente do AMSenderC do TinyOS.

Os nós sensores foram identificados por identificadores NODE\_ID iniciando em 1, onde o NODE\_ID 0 foi associado ao nó *sink*/atuador. O *start\_nod*e foi identificado com o maior NODE\_ID relativo a cada cenário de RASSF e o *end\_node* foi identificado com o NODE\_ID igual a 1. O vizinho anterior de nó foi identificado como sendo o seu NODE\_ID menos 1 e o vizinho posterior foi identificado como sendo o seu NODE\_ID mais 1.

# 6.7 Experimentos de Eficiência do Delphos Considerando a Interferência Ambiental (Experimento A)

Nesta seção são apresentados experimentos simulados de eficiência efetuados com o Delphos, quando esse **considerou** a interferência ambiental exercida sobre as frequências naturais (denominado Experimento A).

Para isso, foram executados dois experimentos, onde o primeiro teve a finalidade de calibrar os parâmetros do sistema a fim de encontrar o conjunto de parâmetros que minimize os falsos negativos e positivos, e o segundo experimento utilizou os parâmetros selecionados no experimento de calibração para efetivamente testar a eficiência do Delphos.

#### 6.7.1 Calibração do Delphos para o Experimento A

Essa seção apresenta o experimento de calibração do Delphos que visa identificar os valores adequados para os parâmetros do sistema com o objetivo de alcançar o menor número possível de respostas falsas dadas pelo Delphos. Os parâmetros incluem: **Horizonte de Previsão** (HP) e **Margem de Erro** (ME). O HP é definido como o número de pontos a serem previstos a partir do último ponto conhecido da série temporal. No contexto do Delphos, cada coleta de dados efetuada pode ser entendida como um ponto da série temporal. Portanto, o número de HP está associado à quantidade de valores de coletas futuras que serão previstos. A partir desses valores de coletas futuras, o Delphos indica apenas a coleta em que o dano irá ocorrer (a coleta futura que ultrapassa o limite T). A ME é usada para determinar o intervalo de coletas em que o dano deverá ocorrer. Em outras palavras, se o dano foi previsto para ocorrer na coleta de número 100 e a ME é igual a 3, o Delphos irá indicar que o dano ocorrerá no intervalo de coletas de 97 a 103.

O experimento de calibração foi composto por três diferentes cenários. Nos cenários 1, 2 e 3, foi fixado o valor de ME, respectivamente, em 2, 3 e 4, enquanto foram variados os valores de HP de 3 até 10, incrementando de 1 em 1. Testes preliminares demonstraram que o Delphos não apresenta bons resultados para valores de HP maiores que 10 (VP menor que 18%), pois o ARIMA é adequado para previsões em curto prazo (MORETTIN E TOLLOI 2006). Os valores de ME maiores que 4 são inviáveis pois tornam a previsão muito imprecisa. Os testes mostraram também que o Delphos não apresenta bons resultados para valores de ME menores que 2 (VP inferior a 40%), porque o modelo ARMA apresenta uma tendência futura e não valores exatos. Não foram considerados os resultados quando a ME foi igual ao HP (marcados com "X" na Tabela 4), pois nestes casos o tempo de reação seria nulo. Os resultados estão descritos na Tabela 4. Vale lembrar que a soma de VP e VN totaliza 100% dos casos avaliados (50% VN e 50% VP), já que nesta etapa de calibração foi usada a distribuição de amostras de Evolução igual a 50% com dano e 50% sem dano.

De forma geral, observa-se que o sistema alcança ótimos resultados de VN para quase todos os valores de HP e ME, enquanto que a quantidade de VP decai à medida que o HP aumenta. Esse comportamento tem relação com o modelo ARIMA e com a Evolução sem presença de dano ilustrada na Figura 19. O modelo ARIMA realiza a previsão de valores futuros de acordo com a tendência da série temporal que está sendo modelada. A tendência da série temporal de Evolução sem presença de dano (ilustrada na Figura 19) é de permanecer dentro do intervalo de confiança de 95% para o estado saudável da estrutura, ou seja, os valores de variação de frequência não se aproximam do limite T. Sendo assim, o sistema inclina-se a realizar previsões que não se aproximam do limite T e, por esse motivo, tem menos chances de apontar existência de um dano quando a estrutura está em um estado saudável.

Cenário	ME	Met.	Horizonte de Previsão							
Contaile			3	4	5	6	7	8	9	10
1	2	VP	47%	47%	47%	42%	37%	25%	20%	18%
		VN	50%	50%	50%	50%	50%	50%	50%	48%
2	3	VP	Х	50%	50%	48%	45%	40%	32%	30%
		VN	Х	50%	50%	50%	50%	50%	50%	48%
3	4	VP	Х	Х	50%	50%	50%	47%	42%	43%
		VN	Х	Х	50%	50%	50%	50%	50%	48%

Tabela 4. Resultados da calibração para o Experimento A

Outra observação a ser feita nos resultados na Tabela 4 é que o sistema alcança valores mais altos de verdadeiros (soma de verdadeiros positivos e negativos) de acordo com o aumento dos valores do parâmetro ME. No entanto, o emprego de valores mais altos de ME implicam em uma resposta de previsão menos exata, ou seja, um valor de margem de erro grande pode tornar a previsão imprecisa, pois não será possível identificar o real intervalo de tempo em que o dano poderá ocorrer. Do contrário, constata-se que o sistema alcança valores mais altos de verdadeiros quando o HP é inferior a 6, confirmando-se o que fora dito sobre a eficiência em curto prazo do modelo ARIMA (MORETTIN e TOLLOI 2006).





Figura 21. Curvas ROC para Margem de Erro igual a 2

Portanto, é preciso encontrar os valores de HP e ME em que Delphos apresente um bom desempenho em termo de acertos de predição e, ao mesmo tempo, não torne inviável sua aplicação devido a inexatidão de sua resposta de previsão. Para isso, utilizamos as métricas de especificidade, sensibilidade e acurácia considerando a Margem de Erro igual 2. As curvas ROC resultantes estão apresentadas na Figura 21.

As curvas ROC ilustradas na Figura 21 mostram que o sistema apresenta uma especificidade constante para todos os valores de HP. No entanto, a sensibilidade e a acurácia diminuem à medida que os valores de HP aumentam. Esse comportamento também é observado nas curvas ROC para uma Margem de Erro igual a 3, conforme ilustrado na Figura 22. Esse comportamento é esperado, porque um alto valor de HP faz com que a previsão se torne mais imprecisa.





A partir da análise dos resultados, optou-se pelo menor valor de ME, a fim de garantir uma maior precisão nos resultados e por um maior valor de HP (relacionado ao valor de ME escolhido) para alcançar um maior tempo de reação. Dessa forma, foram escolhidos o HP igual a 6 e a ME igual a 2. Em outras palavras, o Delphos consegue predizer se o dano irá ocorrer até 6 coletas futuras e o dano poderá ocorrer nas coletas 4,5,6,7,8, onde, neste trabalho, cada coleta futura representa 1 dia.

## 6.7.2 Experimento de Avaliação de Eficiência do Delphos (Experimento A)

Essa seção descreve os resultados obtidos no Experimento A que tem a finalidade de verificar a eficiência do Delphos em termos de acertos de predição de dano ao levar em conta a influência sofrida pelas frequências naturais diante das variáveis ambientais. Nesse experimento o Delphos usou o modelo ARIMA descrito na Equação 5, e foi implantado seguindo as duas fases de pré-implantação descritas no capítulo 5. Os parâmetros do sistema utilizados neste experimento foram os parâmetros identificados na seção anterior, ou seja, Horizonte de Previsão igual a 6 e Margem de Erro igual a 2.

A Tabela 5 apresenta os resultados obtidos quando o número de sensores foi fixado em 6 (as demais topologias são apresentadas em seguida). Nesta tabela estão descritas as quantidade de FP, VP, FN e VN para cada uma das distribuições de amostras de Evolução (50% com dano e 50% sem dano, 25% com dano e 75% sem dano, e 75% com dano e 25% sem dano) e do número de nós defeituosos (variando de 0 a 4, de 1 em 1).

#### Tabela 5. Resultados do Experimento A para RASSF composta por 6 sensores

Distribuição	Nós Defeituosos								
Distribulção	Métricas	0	1	2	3	4			
	FN	0,00%	0,00%	0,00%	0,00%	0,00%			
	FP	0,00%	0,00%	0,00%	0,00%	0,00%			
50%-50%	VP	50,00%	50,00%	50,00%	50,00%	50,00%			
	VN	50,00%	50,00%	50,00%	50,00%	50,00%			
	FN	0,00%	0,00%	0,00%	0,00%	0,00%			
250/ 750/	FP	0,00%	0,00%	0,00%	0,00%	0,00%			
2370-7370	VP	25,00%	25,00%	25,00%	25,00%	25,00%			
	VN	75,00%	75,00%	75,00%	75,00%	75,00%			
	FN	0,00%	0,00%	0,00%	0,00%	0,00%			
750/ 250/	FP	2,50%	2,50%	2,50%	2,50%	2,50%			
1370-2370	VP	72,50%	72,50%	72,50%	72,50%	72,50%			
	VN	25,00%	25,00%	25,00%	25,00%	25,00%			

Avaliando-se os resultados descritos na Tabela 5, pode-se constatar que o sistema apresenta um bom desempenho no que tange ao número total de verdadeiros (soma de verdadeiros positivos e verdadeiros negativos) quando o número de nós defeituosos foi igual a zero (sem qualquer anormalidade presente na rede). O sistema conseguiu alcançar um total de 100% de verdadeiros para as distribuições 50% com dano e 50% sem dano, e 25% com dano e 75% sem dano, e um total de verdadeiros igual a 97,5% para a distribuição de amostras de 75% com dano e 25% sem dano.

Observa-se também na Tabela 5 que o Delphos, em relação aos falsos, está mais suscetível a falsos positivos, visto que há um maior número de ocorrências de falsos positivos do que de falsos negativos. Esses resultados realmente confirmam a percepção exposta na seção 6.7.1, em que o modelo ARIMA e a Evolução sem presença de dano contribuem para que o Delphos apresente ótimos resultados quando se está avaliando Evoluções sem presença de dano.

Os dados contidos no gráfico da Figura 23 reforçam ainda mais essa afirmação. Esse gráfico apresenta a quantidade de verdadeiros (soma de verdadeiros positivos e verdadeiros negativos) alcançados pelo sistema Delphos ao variar o número de nós defeituosos na RASSF composta por seis sensores para todas as três distribuições de amostras (50% com dano e 50% sem dano, 25% com dano e 75% sem dano, e 75% com dano e 25% sem dano).



Figura 23. Total de verdadeiros para número de sensores igual a 6

Observa-se no gráfico da Figura 23 que realmente o sistema está mais suscetível a falsos positivos do que falsos negativos, pois o Delphos alcançou um menor número de verdadeiros quando os testes foram realizados com a distribuição de amostras (75% com dano e 25% sem dano) que apresenta maiores chances de ocorrer falsos positivos. Isso acontece, pois nesta distribuição é encontrado um maior número de Evoluções com presença de dano (75% das 40 Evoluções testadas) que podem ocasionar falsos positivos. Por fim, verifica-se que o desempenho do sistema se apresenta de maneira menos variável quando os testes foram realizados com a distribuição de 25% com dano e 75% sem dano, já que essa possui apenas 25% de Evoluções que podem ocasionar falsos positivos.

Enfim, esses resultados demonstram que o Delphos está mais suscetível a emitir falsos positivos do que falsos negativos e, em se tratando de predição de danos, esse comportamento é aceitável, pois é preferível avisar muito antecipadamente que um dano irá ocorrer do que não alarmar a iminência de um dano e esse acabar ocorrendo sem qualquer aviso prévio.

Ainda no gráfico da Figura 23 verifica-se que o desempenho do sistema em termos de acertos de predição (total de verdadeiros) se mantém constante a medida que o número de nós defeituosos aumenta. Esse comportamento é explicado devido ao processo de colaboração descrito na seção 4.3.3, onde os nós trocam informações entre si a fim de validarem uma previsão feita pela rede.

O gráfico ilustrado na Figura 24 permite visualizar a acurácia do sistema em termos de acerto de predição para todas as três topologias de RASSF (seis, doze e dezoito sensores). Neste gráfico é apresentado o total de verdadeiros (soma de verdadeiros positivos e

verdadeiros negativos) alcançados pelo sistema Delphos ao variar o número de nós defeituosos na RASSF para as distribuições de amostras de Evolução iguais a 75% com dano e 25% sem dano.





Observa-se no gráfico da Figura 24 que o desempenho do sistema não é afetado de acordo com a topologia da rede. Esse comportamento tem relação com o processo de colaboração dos nós sensores, pois o algoritmo distribuído garante que os nós se comuniquem apenas com seus vizinhos anterior e posterior, não sendo influenciado pela quantidade total de nós da rede. Outro ponto a ser mencionado é que esse algoritmo distribuído possui mecanismos como confirmação de mensagens e verificação de *timeout* que permitem manter a confiabilidade do processo de predição mesmo com o aumento do número de nós.

Em resumo, o Delphos apresenta bons resultados em termos de acertos de predição para todas as distribuições de amostras e independentemente do número de nós defeituosos testados. O sistema também apresenta um maior número de falsos positivos do que de falsos negativos devido ao emprego do modelo ARIMA, sendo considerado um comportamento adequado ao problema em questão. Outro ponto é que o aumento no número de nós sensores da RASSF não influencia o desempenho do sistema em termos de acertos de predição, pois o mecanismo de colaboração proposto garante que os nós comuniquem-se apenas com seus vizinhos anterior e posterior.

# 6.8 Experimentos de Eficiência Não Considerando a Interferência Ambiental (Experimento B)

Nesta seção são apresentados experimentos de eficiência efetuados com o Delphos, quando esse **não considerou** a interferência ambiental exercida sobre as frequências naturais.

Para isso, foram executados dois experimentos, onde o primeiro teve a finalidade de calibrar os parâmetros do sistema a fim de encontrar o conjunto de parâmetros que minimize os falsos negativos e positivos, e o segundo experimento utilizou os parâmetros selecionados no experimento de calibração para efetivamente testar a eficiência do Delphos.

#### 6.8.1 Calibração do Delphos para o Experimento B

A partir dos resultados obtidos no experimento de Calibração para o Experimento A, foi possível identificar um intervalo prévio de valores de HP e ME em que o sistema apresenta resultados mais adequados, ou seja, um maior número de verdadeiros positivos e negativos. Portanto, neste experimento de Calibração a Margem de Erro foi fixada em 2, enquanto que os valores de HP foram variados entre 3 e 10, de 1 em 1. A Tabela 6 apresenta os resultados desse experimento de calibração para o Experimento B.

Tabela 6. Resultados da calibração para o Experimento B

Met	Horizonte de Previsão								
moti	3	4	5	6	7	8	9	10	
VP	3%	3%	3%	3%	3%	2%	2%	2%	
VN	50%	50%	50%	50%	50%	50%	50%	50%	

Os resultados demonstram que o melhor desempenho (maior número de verdadeiros) foi obtido quando o horizonte de previsão foi inferior a 8. Apesar de apresentar um resultado menos eficiente, o comportamento (em termos de acertos de predição) do sistema verificado nesse experimento de calibração para o Experimento B, é bastante similar ao que foi verificado na calibração feita para o Experimento A, ou seja, em ambos os experimentos de calibração o sistema apresenta um maior número de verdadeiros quando o HP é inferior a 6 ou 7. Como afirmado na seção 6.7.1, esse comportamento tem relação com o modelo ARIMA que é adequado apenas para previsões em curto prazo.

Avaliando os resultados descritos na Tabela 6, foi possível identificar o melhor valor de HP a ser usado nos experimentos de calibração, ou seja, buscou-se pelo maior valor de HP que apresentou o maior número de verdadeiros. Portanto, optou-se pelo HP igual a 7 e ME igual a 2.

## 6.8.2 Experimento de Avaliação de Eficiência do Delphos (Experimento B)

Nessa seção são apresentados os resultados do Experimento B que tem a finalidade de verificar a eficiência do Delphos em termos de acertos de predição de dano **ao não levar em conta** a influência sofrida pelas frequências naturais diante da variação da temperatura. Neste experimento o Delphos usou o modelo ARIMA descrito na Equação 6 e foi implantado ao se efetuar apenas a última fase de pré-implantação descrita no capítulo 5, ou seja, o filtro de interferências ambientais não foi empregado neste experimento. Os parâmetros do sistema utilizados neste experimento foram os parâmetros identificados na seção anterior, ou seja, Horizonte de Previsão igual a 7 e Margem de Erro igual a 2. Os resultados desse experimento de eficiência estão descritos a seguir.

	Dictribuição	Nós Defeituosos							
	Distribulção	Métricas	0	1	2	3	4		
		FN	0,00%	0,00%	0,00%	0,00%	0,00%		
		FP	42,50%	42,50%	42,50%	42,50%	42,50%		
	20/0-20/0	VP	7,50%	7,50%	7,50%	7,50%	7,50%		
		VN	50,00%	50,00%	50,00%	50,00%	50,00%		
		FN	0,00%	0,00%	0,00%	0,00%	0,00%		
	25% 75%	FP	20,00%	20,00%	20,00%	20,00%	20,00%		
	23/0-73/0	VP	5,00%	5,00%	5,00%	5,00%	5,00%		
		VN	75,00%	75,00%	75,00%	75,00%	75,00%		
		FN	0,00%	0,00%	0,00%	0,00%	0,00%		
	750/ 750/	FP	62,50%	62,50%	62,50%	62,50%	62,50%		
	13/0-2370	VP	12,50%	12,50%	12,50%	12,50%	12,50%		
		VN	25,00%	25,00%	25,00%	25,00%	25,00%		

Tabela 7. Resultados do Experimento B para RASSF composta por 6 sensores

A Tabela 7 apresenta os resultados obtidos neste Experimento B quando o número de sensores foi fixado em 6. Nesta tabela estão descritas as quantidade de FP, VP, FN e VN para cada uma das distribuições de amostras de Evolução (50% com dano e 50% sem dano, 25% com dano e 75% sem dano, e 75% com dano e 25% sem dano) e do número de nós defeituosos (variando de 0 a 4, de 1 em 1).

Avaliando-se os resultados descritos na Tabela 7, pode-se verificar que o Delphos não apresenta um bom desempenho no que diz respeito ao número total de verdadeiros (soma de verdadeiros positivos e verdadeiros negativos), pois o sistema conseguiu alcançar um total de 57,5% de verdadeiros para a distribuição 50% com dano e 50% sem dano, 80% de verdadeiros para 25% com dano e 75% sem dano, e 37,5% para 75% com dano e 25% sem dano. Esse baixo número de verdadeiros está relacionado à influência da temperatura exercida

sobre as frequências naturais, onde o processo de predição de dano tem sua eficiência prejudicada diante das pequenas variações presentes na curva de variação de frequências.

O gráfico da Figura 25 permite observar melhor a relação entre o total de verdadeiros e cada uma das distribuições de amostras de Evolução. Portanto, esse gráfico apresenta a quantidade de verdadeiros (soma de verdadeiros positivos e verdadeiros negativos) alcançados pelo sistema para a topologia de seis sensores. Neste gráfico são apresentadas três curvas relacionadas a distribuição de amostras de Evolução, variando de acordo com o número de nós defeituosos.



Figura 25. Total de verdadeiros para número de sensores igual a 6

Pode-se observar neste gráfico da Figura 25 que o total de verdadeiros permanece estacionado em um patamar para cada uma das distribuições de amostras. Isso ocorre, pois o sistema apresenta um número de FP quase sempre próximo do total de FP possível. Por exemplo, o Delphos alcança um total de FP igual a 42,5% para distribuição 50% com dano e 50% sem dano, onde era possível alcançar, no máximo, 50% de FP, ou seja, o sistema apresentou um resultado ruim para quase todas as possíveis ocorrências em que poderiam resultar em FP (42,5% de um total de 50%). Esse comportamento se confirma ao avaliar as outras distribuições, onde o sistema alcançou um total de FP para as distribuições 25% com dano e 75% sem dano, e 75% com dano e 25% sem dano igual a 20% (dos 25% possíveis) e 62,5% (dos 75% possíveis), respectivamente.

Não foram apresentados os resultados das demais topologias, pois, assim como no Experimento A, observou-se que o número de nós sensores não influencia o desempenho do processo de predição de danos.

Em resumo, os resultados desse Experimento B permitiram constatar que o Delphos não apresentou um bom desempenho (relacionado ao total de verdadeiros) para nenhuma das distribuições de amostras de Evolução. Pode-se observar especialmente, que o sistema alcançou um número muito alto de FP, quase sempre se aproximando do total de FP que seria possível atingir.

# 6.9 Comparação Entre os Experimentos de Eficiência A e B

Nesta seção são comparados os resultados de ambos os experimentos de eficiência, A e B. Portanto, o gráfico da Figura 26 apresenta uma comparação dos resultados obtidos através dos experimentos de eficiência para a topologia de 6 sensores e a distribuição de amostras de 50% com dano e 50% sem dano. Neste gráfico estão apresentadas duas curvas que relacionam a quantidade de nós defeituosos e o total de verdadeiros alcançados pelo sistema, para cada um dos dois experimentos.





O desempenho do Delphos em termos de acertos de predição no Experimento A é muito superior ao desempenho alcançado no Experimento B. No Experimento A, o Delphos atingiu 100% de verdadeiros para a quantidade de nós defeituosos igual a 0 e 1, enquanto que no Experimento B, o Delphos alcançou valores em torno de 60% de verdadeiros para o mesmo número de nós defeituosos.

Esses resultados demonstram que o processo de predição de dano usando o modelo ARIMA realmente é afetado pela influência da temperatura. Portanto, confirma-se a hipótese de que eliminar a interferência ambiental das frequências naturais garante uma maior acurácia em termos de acerto de predição do processo de predição de danos em aerogeradores.

Isso ocorre, pois a série temporal composta pelas frequências sob influência da temperatura é mais difícil de ser modelada através do ARIMA, já que essa curva apresenta variações ao longo de um curto intervalo de tempo. No entanto, a série temporal composta por valores de frequência livres da influência da temperatura é uma curva mais suave e essa atenuação permite realizar uma previsão mais confiável a cerca de valores futuros.

## 6.10 Experimentos para Avaliar o Ganho da Descentralização

Essa seção apresenta os experimentos efetuados para avaliar o ganho de executar o processo decisório de predição de danos de forma descentralizada em uma RASSF em termos de tempo de resposta e consumo de energia.

Para isso, foi concebida uma versão centralizada do Delphos, onde o sensor apenas coleta as informações de vibração e temperatura, identifica a frequência natural e repassa-a juntamente com a informação de temperatura ao atuador. É importante mencionar que na versão descentralizada do Delphos, foram considerados o processo de colaboração e a confirmação de mensagens.

Nos experimentos descritos nessa seção (versão centralizada e descentralizada) foram variados o número de nós sensores entre 6, 12 e 18, com o acréscimo de um nó exercendo ambos os papéis de sink e atuador. Esses experimentos utilizaram uma Evolução de Dano aleatoriamente escolhida da Base de Experimentos.

Em ambos os experimentos, o tempo de resposta do Delphos em realizar a atuação no aerogerador foi contabilizado da mesma maneira. Esse tempo de resposta é computado durante o ciclo de execução em que o dano foi previsto e é calculado como sendo o tempo decorrido desde o início da coleta de dados realizada pelos nós sensores até o momento em que o atuador recebe uma indicação para que uma ação de controle seja efetuada.

O gráfico da Figura 27 apresenta o tempo de resposta em segundos relacionado ao tempo gasto pelo Delphos para atuar em caso de predição de dano.





Os resultados mostram que a versão descentralizada do Delphos alcança um menor tempo de resposta para realizar a atuação no aerogerador. Essa diferença no tempo de resposta da versão centralizada está relacionada ao fato de que o sink precisa realizar todo o processo de predição de dano para cada uma das mensagens que são recebidas, ou seja, o sink mantem um série temporal para cada nó sensor da rede. A partir de cada predição efetuada, o sink aguarda pela realização de duas indicações de dano para só depois acionar o atuador. Sendo assim, o tempo de processamento total da predição de dano acaba se tornando seqüencial, pois o sink precisa processar seqüencialmente cada uma das mensagens recebidas. Já na abordagem distribuída, os nós executam o processo de predição de dano de forma paralela e somente aguardam para realizar uma colaboração acerca do resultado final obtido por cada nó. Enfim, confirma-se a hipótese de que a versão descentralizada do Delphos fornece uma resposta mais ágil, já que o processo decisório de predição de danos é executado dentro da RASSF por todos os nós da rede.

O gráfico da Figura 28 apresenta o consumo de energia (em joules) médio dos nós da rede ao utilizar as versões centralizada e descentralizada do Delphos variando o número de nós sensores (6, 12 e 18 sensores).





Os resultados apresentados na Figura 28 mostram que o consumo de energia médio dos nós da rede é maior quando utilizada uma versão centralizada do Delphos, pois os nós precisam aumentar sua potência de sinal de rádio para que as mensagens consigam alcançar o nó atuador. Portanto, na versão descentralizada do Delphos é observado um menor consumo de energia, pois cada nó precisa estar ao alcance apenas dos seus vizinhos posterior e anterior. Sendo assim, pode-se comprovar a hipótese de que a versão descentralizada do Delphos realmente contribui para que os nós da rede gastem menos energia.

# 6.11 Experimentos de Impacto do Delphos na RASSF

Essa seção apresenta os experimentos efetuados com o Delphos a fim de identificar o impacto causado pelo sistema nos recursos da RASSF. Para isso, avaliou-se a quantidade de memória utilizada pelo Delphos e o tempo de vida da RASSF de acordo com o uso ou não de confirmação de mensagens e o emprego ou não do processo de colaboração descrito na seção 4.3.3. O experimento realizado para avaliar o tempo de vida da rede permitiu quantificar a variação no tempo de vida da rede a medida que os recursos de colaboração e confirmação de mensagens são empregados. Já o experimento de consumo de memória permitiu verificar o quanto de memória RAM e memória ROM são consumidos pelo sistema ao ser implantado em um dispositivo MICAz.

# 6.11.1 Avaliação da Quantidade de Memória Utilizada pelo Delphos

O gráfico da Figura 29 apresenta o percentual de consumo de memória RAM e ROM (*flash*) de acordo com o uso ou não de confirmação de mensagens e o emprego ou não do processo de cooperação.





Percebe-se que o maior consumo de memória ficou por conta do emprego da cooperação em conjunto com a confirmação de mensagens, totalizando 31,76% de RAM e 26,36% de memória ROM. Esse resultado é esperado, pois o emprego da cooperação e da confirmação de mensagens utiliza outros componentes e código adicional que não são contemplados nas configurações sem confirmação e sem o emprego da cooperação.

Pode-se observar também que os valores de consumo de memória (tanto RAM quanto ROM) para todos os experimentos estão bem próximos, apesar de ocorrer uma ligeira diminuição a medida que os recursos não são utilizados, ou seja, o consumo de memória diminui a medida que a cooperação e a confirmação não são utilizadas.

Avaliando-se individualmente o maior valor de consumo de memória (Cooperação e Confirmação), pode-se constatar que o sistema consumiu uma quantidade moderada de memória, pois ainda estão disponíveis quase 70% de espaço tanto para a memória RAM quanto para a ROM. Vale lembrar que o espaço de armazenamento de dados não foi utilizado e se encontra totalmente disponível.

O elemento que mais contribui para o consumo de memória foi a base de semântica do sistema nebuloso Takagi-Sugeno. Isso pode ser comprovado ao se desativar temporariamente esse sistema nebuloso e avaliar o consumo de memória. Os resultados demonstraram que o sistema nebuloso Takagi-Sugeno consome em torno de 24,14% de memória RAM e 22,48 % de memória RAM do total consumido pelo sistema.

#### 6.11.2 Experimentos para Avaliação do Tempo de Vida da Rede

Foram realizados quatro experimentos simulados a fim de verificar o tempo de vida da RASSF. A simulação desses quatro experimentos tem a finalidade de verificar o tempo de vida da RASSF diante do uso ou não de confirmação de mensagens e do emprego ou não do processo de colaboração descrito na seção 4.3.3. Essa avaliação permite identificar se há alteração no tempo de vida da rede ao se utilizar a confirmação de mensagens e o processo de colaboração que permitem aumentar a confiabilidade do sistema de predição. Cada um dos quatro experimentos foi executado em diferentes topologias de rede (6, 12 e 18 sensores) a fim de investigar se o número de nós tem influência no tempo de vida da RASSF para qualquer uma das quatro configurações apresentadas.

Para efetuar esses experimentos, foi usada uma Evolução de Dano aleatoriamente escolhida da Base de Dados de Experimentos. Optou-se por uma Evolução de Dano (e não por uma Evolução sem Dano), pois ao avaliá-la, o Delphos executará todas as fases do ciclo de execução (Decisão de Anormalidade, Predição de Dano, Colaboração e Reação), permitindo estimar e analisar o tempo de vida da rede diante do funcionamento completo do sistema.

Considerou-se a energia consumida para efetuar a coleta de dados do acelerômetro através de uma placa MTS400 (0,0037 joules). Ademais, o período entre os ciclos de execução foi de 10 segundos (representando 1 dia), onde esse intervalo de tempo foi escolhido por ser suficientemente adequado para completar um ciclo de execução. A fim de manter o tempo de simulação curto, os ciclos de execução foram sucessivamente efetuados, ou seja, não foram considerados intervalos de tempo entre cada um dos ciclos de execução. É importante enfatizar que em um ambiente real, os nós sensores devem permanecer no estado *Power Save Mode* entre cada ciclo de execução, a fim de reduzir o consumo de energia da rede.

Ao efetuar os experimentos foi possível obter a energia consumida em cada ciclo de execução. A partir desse consumo de energia por ciclo de execução, foi estimado o tempo de vida total da rede, levando em conta a energia total disponível para uma plataforma MICAz

usando 2 baterias AA que provêm em torno de 16000 Joules (KRÄMER e GERALDY 2006) de energia. Para calcular o tempo de vida da RASSF (em dias), foi considerado que a CPU dos nós sensores permaneceram no estado Power Save Mode em cada ciclo de execução. Estima-se que neste estado um nó MICAz consome em torno de 37,4946 Joules de energia por dia (KRÄMER e GERALDY 2006). Portanto, o tempo de vida da RASSF foi estimado ao se dividir 16000 joules (total de energia do MICAz) pela soma entre 37,4946 (consumo de energia no estado Power Save Mode) e o consumo de energia por cada ciclo de execução. Por fim, o valor resultante foi somando ao valor de 0,0037 relacionado ao consumo de energia da leitura do acelerômetro.

A Figura 30 apresenta o tempo de vida da rede para as quatro configurações (com ou sem confirmação, e com ou sem colaboração) de acordo com os três cenários de topologia (seis, doze e dezoito sensores).

Observa-se no gráfico que o processo de colaboração diminui o tempo de vida da rede, pois o algoritmo distribuído (descrito na seção 4.3.3) determina que todos os nós transmitam uma mensagem em cada ciclo de execução, mesmo que não ocorra previsão de dano feita por todos (ou algum) nó. Sem o processo de colaboração, os nós enviam mensagens diretamente ao *sink*/atuador apenas quando uma predição de dano é realizada. Portanto, espera-se realmente que ocorra uma diminuição do tempo de vida da rede ao executar o processo de colaboração proposto.

Todavia, o tempo de vida da rede sem a colaboração foi estimado em torno de 425 dias, enquanto que o tempo de vida da rede com a colaboração foi estimado em 420 dias, ou seja, o emprego da colaboração reduziu em apenas 5 dias a vida útil da rede. Esse pequeno aumento no consumo de energia se deve a redução da potência de sinal de cada um dos nós, visto que cada nó precisa apenas comunicar-se com os seus vizinhos anterior e posterior.



Figura 30. Tempo de vida da RASSF

O gráfico também demonstra que a confirmação de mensagens não influencia o cálculo da vida útil da rede, apesar de apresentar uma diminuição mínima no tempo de vida da rede. Outra questão é que o número de nós não apresentou relação com a vida útil da rede, porque os nós não se comunicam com todos os outros nós da rede, mas apenas com os seus dois vizinhos imediatos (anterior e posterior).

Em resumo, o acréscimo no número de nós não indica alteração da vida útil da rede, pois cada nó tem a função de receber uma mensagem de seu vizinho anterior e repassá-la apenas ao seu vizinho posterior. Esse comportamento do Delphos permite que seja utilizado um maior número de sensores para cobrir uma maior área de monitoramento, sem que haja prejuízo ao tempo de vida total da rede.

# 6.12 Experimentos para Avaliação da Eficiência do Delphos usando Sensores Reais

Os experimentos com sensores reais tiveram a finalidade de validar os resultados obtidos nos experimentos de eficiência simulados. Nesse experimento, o Delphos usou o modelo ARIMA descrito na Equação 5, e foi implantado seguindo as duas fases de préimplantação descritas no capítulo 5.

Assim como no experimento de eficiência A, o sistema foi configurado com o Horizonte de Previsão igual a 6 e a Margem de Erro igual a 2. Foram usados 6 dispositivos MICAz executando o papel de nós sensores e mais um dispositivo adicional exercendo ambos os papeis de *sink* e atuador. O número de nós defeituosos foi variado de 0 a 4, de 1 em 1. Foram utilizadas 10 Evoluções aleatórias, sendo 5 Evoluções de Dano e 5 Evoluções sem Dano.

O gráfico da Figura 31 exibe um comparativo entre os resultados obtidos no Experimento A (distribuição 50% com dano e 50% sem dano, e topologia igual a 6 sensores) e os resultados alcançados pelo Delphos nesse experimento com sensores reais.



Figura 31. Comparativo entre os resultados do experimento usando sensores reais com e do experimento de eficiência A.

Os resultados obtidos foram de 100% de verdadeiros para a quantidade de nós defeituosos igual a 0, 1, 2, 3 e 4. Pode-se perceber que, em ambos os experimentos, a acurácia do sistema em termos de acerto de predição se mantém constante a medida que o número de nós defeituosos aumenta. O gráfico da Figura 31 também permite constatar que os resultados em ambos os experimentos são similares. Portanto, esse experimento usando sensores reais, valida os experimentos simulados de eficiência que foram realizados com o Delphos.

# 6.13 Comparação entre os Resultados de Eficiência do Delphos e de Outro Sistema

Essa seção apresenta um comparativo entre os resultados de eficiência do Delphos em termos de acertos de predição e os resultados alcançados por um sistema da literatura. O sistema em questão foi proposto por Kusiak e Li (KUSIAK e LI 2010) e tem a finalidade de predizer danos em aerogeradores, utilizando algoritmos de mineração de dados.

O sistema proposto por Kusiak e Li (KUSIAK e LI 2010) obtém dados de um Sistema de Supervisão e Aquisição de Dados (SCADA, do inglês *Supervisory Control and Data Aquisition*). Os sistemas SCADA tem a função de monitorar e supervisionar as variáveis e os dispositivos de sistemas de controle conectados através de componentes de software específicos. Em outras palavras, os sistemas SCADA permitem monitorar e controlar, parcialmente ou em sua totalidade, um processo industrial.

No contexto do trabalho de Kusiak e Li (KUSIAK e LI 2010), o sistema SCADA tem a função de monitorar o aerogerador quanto aos parâmetros de vibração, temperatura, vento e conversão de energia a fim de indicar se um aerogerador está funcionando corretamente. Para isso, o sistema SCADA utiliza os dados monitorados para fornecer informações de estado do aerogerador, como indicações de baixa voltagem ou problemas em componentes eletrônicos e mecânicos do aerogerador.

O sistema proposto por Kusiak e Li (KUSIAK e LI 2010) recebe como entrada as informações de estado do aerogerador fornecidas pelo SCADA com a finalidade de fornecer uma predição de quando o aerogerador irá alcançar um estado de dano.

Quanto ao cenário utilizado neste experimento, nós adotamos uma RASSF composta por 6 nós sensores, com 1 sensor adicional exercendo ambos os papéis de sink e atuador. Não foi considerado nenhum nó defeituoso e a distribuição de amostras de evolução foi fixada em 75% com dano e 25% sem dano. Essa distribuição foi escolhida, pois o trabalho de Kusiak e Li (KUSIAK e LI 2010) utiliza uma distribuição de amostras em que a quantidade de situações com dano é maior do que a quantidade de situações sem dano.

O trabalho de Kusiak e Li (KUSIAK e LI 2010) também utiliza as mesmas métricas de acertos de predição consideradas nesse trabalho para avaliar o desempenho de sua solução, ou seja, são utilizadas as métricas de especificidade, sensibilidade e acurácia. O comparativo entre o sistema de Kusiak e Li (KUSIAK e LI 2010) e o Delphos estão descritos na Figura 32.



Figura 32. Comparativo entre o Delphos e o sistema de Kusiak e Li (KUSIAK e LI 2010)

Dentre as três métricas, a sensiblidade é aquela em que os resultados do Delphos e do sistema de Kusiak e Li (KUSIAK e LI 2010) mais se aproximam (96,67% para o Delphos e 86,34% para o sistema de Kusiak e Li (KUSIAK e LI 2010)). Essa métrica de sensibilidade é usada para computar a proporção de predições corretas feitas quando o aerogerador apresenta dano, ou seja, essa métrica afere o comportamento do sistema em prever um dano quando ele realmente existe. Os resultados de ambos os trabalhos não são tão dissonantes, pois os sistemas de predição de dano buscam em primeiro lugar identificar corretamente quando um dano irá ocorrer quando esse realmente existe.

No entanto, a maior discrepância de resultados fica por conta da métrica de especificidade que é usada para calcular a proporção de predições corretas feitas quando o aerogerador não apresenta dano. O Delphos alcança 100% de especificidade, enquanto que o sistema de Kusiak e Li (KUSIAK e LI 2010) alcança apenas 64,43%. Como explicado anteriormente, o Delphos apresenta um bom resultado quanto a especificidade, pois o modelo ARMA acompanha o comportamento da série de Evolução sem Dano e esta série não ultrapassa o limite de anormalidade.

# 7 Conclusões

Esse trabalho propôs um sistema de predição de danos descentralizado, denominado Delphos, que faz uso de RASSF com a finalidade de predizer danos em aerogeradores e executar ações de controle para evitar danos catastróficos.

Para realizar a predição de dano, o sistema utiliza um modelo estatístico para previsão de séries temporais, denominado modelo Auto-regressivo e de Médias Móveis (ARMA, *Autoregressive Moving Averages*). Esse modelo permite conhecer o padrão gerador da série temporal a fim de realizar previsões de valores futuros para essa mesma série. No contexto desse trabalho, o ARMA acompanha a série temporal de Evolução de Dano que é composta por valores de variação de frequência que evoluem de zero até um estado de dano. A partir da análise dessa evolução, o ARMA é empregado para identificar o momento em que valores futuros de variação de frequência ultrapassarão o limite considerado saudável.

Antes de efetuar esse processo de predição de valores futuros de variação de frequência, O Delphos realiza um filtro nas frequências naturais da estrutura a fim de eliminar a influência causada pela temperatura e aumentar a confiabilidade do processo de predição. Esse filtro é realizado, pois a frequência natural pode sofrer variações ao ser influenciada pela temperatura, onde essa variação pode prejudicar a análise da série temporal a partir do ARMA. Para realizar esse filtro, é empregado um sistema nebuloso gerado através do ANFIS (*Adaptive Neuro-Fuzzy Inference System*) que é uma rede neural adaptativa equivalente a um sistema nebuloso do tipo Takagi-Sugeno.

Para gerar esse sistema nebuloso, foi preciso empregar um algoritmo híbrido de treinamento em conjunto com uma base de dados que relaciona temperatura e frequências naturais. Como resultado deste treinamento, tem-se um sistema nebuloso capaz de eliminar a influência causada pela temperatura nas frequências naturais, permitindo que o processo de predição de danos avalie uma frequência filtrada, ou seja, sem uma interferência ambiental.

Adicionalmente, o sistema executa uma fase de colaboração, onde é utilizada a redundância de nós da rede com o objetivo de observar a estrutura sob diferentes perspectivas. Este processo de colaboração permite aumentar a confiabilidade da predição de dano e fornecer um único resultado final ao *sink* e ao atuador.

Foram realizados diversos experimentos com sistema proposto a fim de comprovar sua eficiência em termos de acertos de predição de dano, além de avaliar o impacto da solução

proposta em termos de recursos da RASSF, como o tempo de vida da rede e o consumo de memória.

Nos experimentos de eficiência simulados foi avaliado o desempenho do Delphos em termos de acerto de predição de dano ao se variar o número de nós sensores, o número de nós defeituosos e a distribuição de amostras de Evolução. Foram feitos dois experimentos de eficiência, onde o primeiro leva em conta a interferência da temperatura sobre as frequências naturais, enquanto que o segundo não leva em conta esta interferência. Os resultados demonstraram que o sistema apresentou um bom desempenho em termos de acerto de predição quando a interferência ambiental foi levada em conta, ou seja, o Delphos alcançou um total de 100% de verdadeiros (soma de verdadeiros positivos e negativos). Esses experimentos de eficiência também mostraram que o número de nós sensores não afeta o desempenho do Delphos em termos de acerto de predição, permitindo que o sistema seja empregado em estruturas maiores, onde há necessidade de se empregar um maior número de sensores.

Já os resultados do experimento de eficiência quando a temperatura não foi levada em conta, mostraram que o Delphos não apresentou um bom desempenho em termos de acerto de predição. Em resumo, o Delphos não conseguiu ultrapassar a marca de 70% de verdadeiros para qualquer uma das variações realizadas testadas. Esse resultado está relacionado às pequenas variações da curva de variação de frequência quando esta está influenciada pela temperatura. Esse padrão de comportamento da curva de variação de frequências acaba prejudicando a previsão de valores futuros realizada pelo ARMA, pois as variações em pequeno espaço de tempo dificultam a análise da série temporal.

Os experimentos de ganho da descentralização mostraram que o a versão descentralizada do Delphos permite alcançar um menor tempo de resposta e um menor consumo de energia dos nós sensores. O menor tempo de resposta está relacionado ao distribuição do processamento por todos os nós da rede e o menor consumo de energia tem relação com diminuição do nível de sinal dos sensores, já que cada nó precisa alcançar apenas os seus vizinhos posterior e anterior.

Os experimentos de impacto na RASSF permitiram analisar o sistema quanto ao tempo de vida da rede e ao consumo de memória ao se utilizar ou não a confirmação de mensagens e ao empregar ou não o processo de colaboração proposto. Os resultados demonstraram que a utilização da confirmação de mensagens em conjunto com o emprego do processo de colaboração proposto não afetam significativamente o tempo de vida da rede e o consumo de memória RAM e ROM (para um dispositivo MICAz). Enfim, os resultados permitiram concluir que o tempo de vida da rede ao se utilizar o Delphos ficou em torno de 425 dias e o consumo de memória não ultrapassou os 30%.

Por fim, foi efetuado um comparativo entre o Delphos e o sistema de Kusiak e Li (KUSIAK e LI 2010), onde pode-se observar que os resultados de ambos os trabalhos para métrica de sensibilidade se assemelham. Isso acontece, pois os dois sistemas buscam prioritariamente identificar corretamente a ocorrência de dano. No entanto, o Delphos apresenta um melhor resultado para a métrica de especificidade, pois o modelo ARMA tende a alcançar um bom resultado quanto ao tratamento de casos onde não há dano.

Como lições aprendidas durante a execução deste trabalho pode-se destacar que a maior dificuldade de implementação do Delphos ficou por conta do sistema nebuloso Takagi-Sugeno, pois era preciso criar uma máquina de inferência nebulosa que fosse capaz de tratar quaisquer conjunto de regras e conjuntos nebulosos. Quanto aos experimentos, a maior dificuldade encontrada estava relacionada a coleta de dados de vibração, pois foi necessário obter uma pá real de um aerogerador, fixá-la de maneira adequada e coletar apropriadamente os dados de vibração através de um acelerômetro.

#### 7.1 Trabalhos Futuros

Quanto aos trabalhos futuros, podem avaliados outros perfis de Evolução de Dano, como os que foram citados na seção 5.2.1. Desta forma, pode-se avaliar o comportamento do Delphos em termos de acerto de predição em outros tipos de situações que podem culminar na ocorrência de dano como, por exemplo, a avaliação do perfil exponencial que permite lidar com a ocorrência de circunstâncias extremas (como o choque de pássaros nas pás do aerogerador).

Outro ponto que pode ser verificado é a melhoria da etapa de coleta de dados reais da pá do aerogerador usando uma câmara climática. Nesta câmara climática pode-se efetuar os experimentos de coleta de dados de vibração com o controle de temperatura, permitindo fixar a temperatura e obter as frequências naturais correspondentes. Esses experimentos permitiriam compreender ainda melhor a influência das interferências ambientais nas frequências naturais de uma estrutura.

O filtro de interferências ambientais considerou apenas a temperatura como um fator que exerce uma influência sobre as frequências naturais. No entanto, alguns trabalhos afirmam que a umidade e outros fatores externos (como a velocidade do vento) também exercem influência sobre as frequências naturais. Sendo assim, pode-se evoluir o filtro de interferências ambientais para que este considere também a influência da umidade e de outros fatores externos como a velocidade dos ventos.

O processo de predição de danos foi feito utilizando o modelo ARIMA (variação do ARMA). Pode-se investigar o emprego de outros métodos estatísticos como o NARX e GARCH a fim de verificar o desempenho do sistema em termos de acertos de predição. Poderia ser verificado também se esses outros métodos estatísticos requerem menos uso de recursos como processamento e memória, a fim de obter uma economia ainda maior de energia dos nós sensores.

No processo de colaboração proposto foi considerado um número mínimo de sensores (dois) para validar uma predição feita pelos nós da rede. Pode-se variar esse número a fim de verificar se o sistema apresenta melhores resultados na presença de nós defeituosos.

Os nós defeituosos foram inseridos nos experimentos para verificar o funcionamento do Delphos diante da disseminação de informações incorretas. Todavia, seria interessante avaliar o funcionamento do sistema diante de outros tipos de falhas, como a indisponibilidade temporária de nós. Outra opção seria considerar um modelo de falhas mais robusto, onde são tratadas falhas bizantinas, por exemplo.

O Delphos é um sistema de predição de danos concebido para atuar no cenários de aerogeradores. Entretanto, o sistema poderia ser generalizado para que pudesse ser capaz de realizar a predição de danos em outros tipos de estruturas. Portanto, outras etapas de préimplantação poderiam ser sugeridas para adaptar o sistema a um cenário diferente.

# 8 Referências

- AKAIKE, H. (1974). "A new look at the statistical model identification". Automatic Control, IEEE Transactions em Dezembro de 1974, edição 6, páginas 716 – 723 e ISSN 0018-9286.
- AKYILDIZ, F. I. e VURAN, M. C. (2010). "Wireless Sensor Networks". John Wiley & Sons Ltd. ISBN: 978-0-470-03061-3.
- ALBEROLA, R. e PESCH, D. (2008). "AvroraZ: extending Avrora with an IEEE 802.15.4 compliant radio chip model", Proceedings of the 3rd ACM workshop on Performance monitoring and measurement of heterogeneous wireless and wired networks, Vancouver, páginas 43-50.
- ANDREWS, G. R. (1991). "Paradigms for process interaction in distributed programs". ACM Computing Surveys, Vol. 23, No. 1, Março.
- BARBALHO, V. M. DE S. (2001). "Sistemas baseados em conhecimento e lógica difusa para simulação do processo chuva-vazão". IX, 94 p., 29,7 cm (COPPE/UFRJ, D.Sc., Engenharia Civil, 2001) Tese - Universidade Federal do Rio de Janeiro, COPPE.
- BOCCA, M.; TOIVOLA, J.; ERIKSSON, LASSE M.; HOLLMÉN, J. e KOIVO, H. (2011). "Structural Health Monitoring in Wireless Sensor Networks by the Embedded Goertzel Algorithm". 978-0-7695-4361-1/11 © 2011 IEEE DOI 10.1109/ICCPS.2011.19.
- BOX, G.; JENKINS, G. M. e Renseil, G. (1994). "Time Series Analysis: Forecasting & Control". ISBN: 978-0130607744. Editora: Prentice Hall, Terceira Edição.
- BROCKWELL, PETER J. e DAVIS, RICHARD A. (2002). "Introduction to time series and forecasting". Segunda edição. ISBN 0-387-95351-5. Springer.
- CIANG, C. C.; Lee, J. e Bang, H. (2008). "Structural health monitoring for a wind turbine system: a review of damage detection methods". Meas. Sci. Technol. 19 122001 (20pp).
- CLAYTON, E. H.; QIAN, Y.; ORJIH, O.; DYKE, S.; MITA, A. e LU, C. (2006). "Off-the-Shelf Modal Analysis: Structural Health Monitoring with Motes," Proceedings of the 24th International Modal Analysis Conference (IMAC XXIV), St. Louis, Missouri, Janeiro 31-Fevereiro 3.
- COUTO, PEDRO M. T. (1995). "Caracterização Experimental do Comportamento Dinâmico de Sistemas Estruturais". Dissertação para Mestrado em Estruturas de Engenharia Civil, Setembro de 1995. Universidade do Porto.
- DELICATO, F. (2005). "Middleware Baseado em Serviços para Redes de Sensores sem Fio", Tese de Doutorado, Universidade Federal do Rio de Janeiro, Julho.
- DELURGIO, S. A. (1998). Forecasting principles and applications. Primeira edição. Singapore: McGraw-Hill. 802p.
- DOS SANTOS, I. L.; PIRMEZ, L.; LEMOS, É. T.; DELICATO, F. C.; PINTO, L. A. V.; SOUZA, J. N. E ZOMAYA, A. Y. (2012). "A localized algorithm for Structural Health Monitoring using wireless sensor networks". Information Fusion, Disponível em 16 de Fevereiro de 2012, ISSN 1566-2535, 10.1016/j.inffus.2012.02.002.
- EHLERS, R. S. (2009). "Análise de Séries Temporais". Departamento de Estatística, Universidade Federal do Paraná. Disponível em http://www.icmc.usp.br/ ehlers/stemp/stemp.pdf. Acessado em Março de 2012.
- ENERSUD. (2012). "Enersud". Disponível em <u>http://enersud.com.br/</u>. Acessado em Janeiro de 2012.

- FARIA, E. L.; ALBUQUERQUE, M. P.; ALFONSO, J. L. G e CAVALCANTE, J. T. P. (2008). "Previsão de Séries Temporais utilizando Métodos Estatísticos". Centro Brasileiro de Pesquisas Físicas. Nota técnica: CBPF-NT-003.
- FARRAR, C. R. e WORDEN, K. (2007). "An introduction to structural health monitoring"., 303-315 365 2007 Phil. Trans. R. Soc. A. doi: 10.1098/rsta.2006.1928.
- FARRAR, C. R.; SOHN, H.; HEMEZ, F. E CZARNECKI, J. (2003). "A Review of Structural Health Monitoring Literature: 1996-2001".
- FLORES, J. H. F. (2009). "Comparação de Modelos MLP/RNA e Modelos Box-Jenkins em Séries Temporais Não-Lineares". Dissertação de Mestrado, Universidade Federal do Rio Grande do Sul.
- GARCIA, F. P.; PEDREGAL, D. J. E ROBERTS, C. (2010). "Time series methods applied to failure prediction and detection". Reliability Engineering and System Safety 95 698–703A.
- GETACHEW, MEKONNEN E. e MITIKU, DANNA N. (2011). "Data Processing Algorithms in Wireless Sensor Networks for Structural Health Monitoring". Master of Science Thesis. Stockholm, Sweden 2011. TRITA-BKN. Tese de Mestrado 335. ISSN 1103-4297. ISRN KTH/BKN/EX-335-SE.
- GRIFFITH, D. T.; CASIAS, M.; SMITH, G.; PAQUETTE, J. E SIMMERMACHER, T. W. (2006). "Experimental Uncertainty Quantification of a Class of Wind Turbine Blades". IMAC-XXIV: Conference & Exposition on Structural Dynamics.
- HACKMANN, G.; SUN, F.; CASTANEDA, N.; LU, C. E DYKE, S. (2008). "A Holistic Approach to Decentralized Structural Damage Localization Using Wireless Sensor Networks". 29th IEEE Real-time Systems Symposium.
- HANNAN, E. J. e QUINN, B. G. (1979). "The Determination of the Order of an Autoregression". Journal of the Royal Statistical Society, B, 41, 190–195.
- HAYKIN, S. (2001). "Redes Neurais Princípios e Prática". Editora Bookman, segunda edição.
- HIGGS, P.A.; PARKIN, R.M.; JACKSON, M.R.; al-HABAIBEH, A.; ZORRIASSATINE, F. e COY, J. (2004). "A survey on condition monitoring systems in industry". Proceedings of: ESDA. 7th Biennial ASME Conference Engineering Systems Design and Analysis.
- JANG, R. J. (1993). "ANFIS: Adaptive-Network-Based Fuzzy Inference System". IEEE Trans. on Systems, Man and Cybernetics, volume 23, número 3, páginas 665-685.
- JARDINE, A. K. S; LIN, D. E BANJEVIC, D. (2006). "A review on machinery diagnostics and prognostics implementing condition-based maintenance". Mechanical Systems and Signal Processing 20 1483–1510.
- KIM, S.; PAKZAD, S.; CULLER, D.; DEMMEL, J.; FENVES, G.; GLASER, S. E TURON, M. (2007). "Health Monitoring of Civil Infrastructures Using Wireless Sensor Networks". PSN'07, Abril 25-27, Cambridge, Massachusetts, USA.
- KOSKO, B. (1994). "Fuzzy Thinking: The New Science of Fuzzy Logic". Hyperion, ISBN: 978-0786880218.
- KRÄMER, M. e GERALDY, A. (2006). "Energy Measurements for MicaZ Node". Disponível em http://vs.informatik.uni-kl.de/. Acessado em Janeiro de 2012.

- KURIAN, C. P.; GEORGE, V. I.; BHAT, J. e AITHAL, R. S. (2006). "Anfis Model For The Time Series Prediction Of Interior Daylight Illuminance". AIML Journal, Volume (6), Edição (3), Setembro.
- KUSIAK, A e LI, W. (2010). "The prediction and diagnosis of wind turbine faults". Renewable Energy, doi:10.1016/j. renene.2010.05.014.
- LEMOS, É. T.; DOS SANTOS, I. L.; PIRMEZ, L.; DELICATO, F. C.; ROSSETTO, S. e DE SOUZA, N. (2011). "Algoritmo Distribuído para Detecção de Dano em Aerogeradores utilizando Redes de Atuadores e Sensores Sem Fio". Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos, Campo Grande.
- LEVIS, P. e GAY, D. (2009). "TinyOS Programming", Cambridge University Press, Cambridge.
- LIU, C. e DEWOLF, J. (2007). "Effect of Temperature on Modal Variability of a Curved Concrete Bridge under Ambient Loads". Journal of Structural Engineering, Vol. 133, No. 12, Dezembro, páginas 1742-1751, (doi 10.1061/(ASCE)0733-9445(2007)133:12(1742)).
- MAKRIDAKIS, S.; WHEELWRIGHT, S. e HYNDMAN, R. (1998). "Forecasting: Methods and Applications". Wiley, 1998, Terceira edição.
- MARCUS, B. (2002). "Condition Based Maintenance on Rail Vehicles Possibilities for a more effective maintenance strategy". Department of Innovation, Design and Product Development. August. Technical Report. Marladern University.
- MEMSIC MICAZ (2012). "Memsic Corporation", http://www.memsic.com/products/wireless-sensor-networks/sensor-boards.html. Acessado em Janeiro de 2012.
- MEMSIC IMOTE2 (2012). "Memsic Corporation" http://www.memsic.com/support/documentation/wireless-sensor-networks/category/7datasheets.html. Acessado em Janeiro de 2012.
- MIGUELANEZ, E. e LANE, D. (2010). "Predictive Diagnosis for Offshore Wind Turbines using Holistic Condition Monitoring". OCEANS, páginas 1-7, ISBN: 978-1-4244-4332-1 DOI 10.1109/OCEANS.2010.5664584.
- MORATORI, P. B.; CRUZ, A. J. O.; FERREIRA, E. B.; PEDRO, M. V.; MANHAES, L. M. B.; DE ANDRADE, L. C. V. e LIMA, C. (2005). "Analysis of the performance of a Fuzzy Controller developed to guide a simulated robot", Proceedings of the IEEE 3<sup>rd</sup>. International Conference on Computational Cybernetics (ICCC).
- MORETTIN, P. A. e TOLOI, C. M. C. (2006). "Análise de Séries Temporais". Editora Edgard Blucher. Segunda edição. ISBN: 8521203896.
- MOSER, P. e MOAVENI, B. (2011). "Environmental Effects on the Identified Natural Frequencies of the Dowling Hall Footbridge". Mechanical Systems and Signal Processing, in press.
- MOSTARDINHA, A. (2006). "Uma abordagem baseada em Lógica Nebulosa para a Seleção de Protocolos de Disseminação de Dados em Redes de Sensores sem Fio". Dissertação de Mestrado, Universidade Federal do Rio de Janeiro, Março.
- NORTHERN. (2012). "Northern Power® 100 Wind Turbine General Specifications". Dispnível em http://www.northernpower.com/. Acessado em Janeiro 2012.
- PHAM, H. e YANG, B. (2010). "Estimation and forecasting of machine health condition using ARMA/GARCH model". Mechanical Systems and Signal Processing 24 546–558.

- PHAM, H. T.; TRAN, V. T. e YANG, B. (2010). "A hybrid of nonlinear autoregressive model with exogenous input and autoregressive moving average model for long-term machine state forecasting". Expert Systems with Applications 37 3310–3317.
- REYER, M.; HURLEBAUS, S.; MANDER, J. E OZBULUT, O. (2011). "Design of a Wireless Sensor Network for Structural Health Monitoring of Bridges". 2011 Fifth International Conference on Sensing Technology. 978-1-4577-0167-2/11 IEEE.
- SALAWU, O. S. (1997). "Detection of structural damage through changes in frequency: a review". Engineering Structures, volume 19, número 9, páginas 718-723.
- SALFNER, F.; LENK, M. e MALEK, M. (2010). "A Survey of Online Failure Prediction Methods". ACM Computing Surveys (CSUR), volume 43, edição 3, número 10.
- SCHWARZ, G. (1978). "Estimating the Dimension of a Model". Ann. Statist. Volume 6, número 2, 461-464.
- SEBER, G. A. F. (1977). "Linear regression analysis". New York : Wiley, ISBN: 9780471019671.
- SIVRIKAYA, F. e YENER, B. (2004). "Time Synchronization in Sensor Networks: A Survey". Network, IEEE, volume 18, edição 4, páginas 45 50.
- SHUKLA, M. e JHARKHARIA, S. (2011). "Applicability of ARIMA Models in Wholesale Vegetable Market: An Investigation". Proceedings of the 2011 International Conference on Industrial Engineering and Operations Management. Kuala Lumpur, Malaysia, Janeiro 22 – 24.
- SWARTZ, A. R.; LYNCH, J. P.; SWEETMAN, B.; ROLFES, R. e ZERBST, S. (2008). "Structural Monitoring of Wind Turbines using Wireless Sensor Networks". Proceedings of the ESF-NSF Workshop on Sensor Networks for Civil Infrastructure Systems, Cambridge.
- TAKAGI, T. e SUGENO, M. (1985). "Fuzzy Identification of Systems and Its Applications to Modeling and Control." IEEE Transactions on Systems, Man, and Cybernetics SMC-15(1): 116-132.
- TIAN, Y. e EKICI, E. (2007). "Cross-Layer Collaborative In-Network Processing in Multihop Wireless Sensor Networks". IEEE transactions on mobile computing, vol. 6, número 3, março.
- WALFORD, C. e ROBERTS, D. (2006). "Condition Monitoring of Wind Turbines: Technology Overview, Seeded-Fault Testing, and Cost-Benefit Analysis". EPRI, Palo Alto, CA: 2006. 1010419.
- XIA, Y.; HAO, H.; ZANARDO, G. e DEEKS, A. (2006). "Long term vibration monitoring of a rc slab: Temperature and humidity effect", Engineering Structures 28 (3), páginas 441–452.
- YICK, J.; MUKHERJEE, B. e GHOSAL, D. (2008). "Wireless sensor network survey", Computer Networks, número 52, páginas 2292-2330.
- ZADEH, LOFTI A. (1965). "Fuzzy sets". Information and Control. 1965; 8: 338–353.
- ZHAO, J.; XU, L. e LIU, L. (2007). "Equipment Fault Forecasting Based on ARMA Model". Mechatronics and Automation. ICMA.
- ZONTA, D.; POZZI, M.; WU, H.; ZANON, P.; CERIOTTI, M.; MOTTOLA, L.; PICCO, G. P.; MURPHY, A. L. E GUNA, S. (2009). "Real-Time Health Monitoring of Historic

Buildings with Wireless Sensor Networks". In: 7th International Workshop on Structural Health Monitoring (IWSHM).