

UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA



RAMON BEZERRA DE SOUZA

**AVALIAÇÃO DE MODELOS DE INTELIGÊNCIA
ARTIFICIAL PARA PREVISÃO DA VELOCIDADE
DE VENTO EM CURTO PRAZO**

Recife, Agosto de 2014.

UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**AVALIAÇÃO DE MODELOS DE INTELIGÊNCIA
ARTIFICIAL PARA PREVISÃO DA VELOCIDADE
DE VENTO EM CURTO PRAZO**

por

RAMON BEZERRA DE SOUZA

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Elétrica da
Universidade Federal de Pernambuco como parte dos requisitos para a obtenção do grau de
Mestre em Engenharia Elétrica.

ORIENTADOR: RONALDO RIBEIRO BARBOSA AQUINO, D.Sc.

COORIENTADOR: OTONI NÓBREGA NETO, D.Sc.

Recife, Agosto de 2014.

© Ramon Bezerra de Souza, 2014

Catálogo na fonte
Bibliotecária Valdicéa Alves, CRB-4 / 1260

- S721a Souza. Ramon Bezerra de.
Avaliação de modelos de inteligência artificial para previsão da velocidade de vento em curto prazo / Ramon Bezerra de Souza - Recife: O Autor, 2014. 96folhas, Il.; Abr.; e Simb;. e Tabs.
- Orientador: Prof. D.Sc. Ronaldo Ribeiro Barbosa Aquino.
Coorientador: Prof. D.Sc. Otoni Nóbrega Neto.
- Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Elétrica, 2014.
Inclui Referências.
1. Engenharia Elétrica. 2. Previsão de ventos. 3. Redes neurais artificiais. 4. Análise de séries temporais. 5 Inteligência artificial. 6. Sistemas Neuro-Fuzzy. I. Aquino, Ronaldo Ribeiro Barbosa (Orientador). II. Nóbrega Neto, Otoni. (Coorientador). III. Título.

UFPE

621.3 CDD (22. ed.)

BCTG/2015 - 154



Universidade Federal de Pernambuco

Pós-Graduação em Engenharia Elétrica

PARECER DA COMISSÃO EXAMINADORA DE DEFESA DE
DISSERTAÇÃO DO MESTRADO ACADÊMICO DE

RAMON BEZERRA DE SOUZA

TÍTULO

***“AVALIAÇÃO DE MODELOS DE INTELIGÊNCIA ARTIFICIAL
PARA PREVISÃO DA VELOCIDADE DE VENTO EM CURTO PRAZO”***

A comissão examinadora composta pelos professores: RONALDO RIBEIRO BARBOSA DE AQUINO, DEE/UFPE, OTONI NÓBREGA NETO, DEE/UFPE, MANOEL AFONSO DE CARVALHO JÚNIOR, DEE/UFPE e BENEMAR ALENCAR DE SOUZA, DEE/UFPE, sob a presidência do primeiro, consideram o candidato **RAMON BEZERRA DE SOUZA** **APROVADO.**

Recife, 29 de agosto de 2014.

CECILIO JOSÉ LINS PIMENTEL
Coordenador do PPGE

RONALDO RIBEIRO BARBOSA DE AQUINO
Orientador e Membro Titular Interno

BENEMAR ALENCAR DE SOUZA
Membro Titular Externo

OTONI NÓBREGA NETO
Coorientador e Membro Titular Externo

MANOEL AFONSO DE CARVALHO JÚNIOR
Membro Titular Interno

Dedico este trabalho a todas as pessoas que são injustiçadas e desencorajadas a sempre buscar o seus sonhos e objetivos, mesmo que às vezes a caminhada seja longa e a desolação assombre o seu coração.

AGRADECIMENTOS

Agradeço à Deus por todas as graças concedidas a mim e a minha família, mesmo em momentos de dificuldade e sempre que o desânimo me rodeava, o Senhor nunca me abandonou e me concedeu sabedoria para ter paciência, batalhar em busca dos objetivos e ser uma pessoa disposta a ajudar.

Aos meus pais Romivaldo e Maria José por toda dedicação, atenção e carinho que sempre me foi dado. Ao meu irmão por sempre estar ao meu lado.

À minha esposa Viviane pela amizade, paciência e compreensão nos momentos em que mais precisei de sua ajuda.

Aos meus primos, tios e tias pela contribuição valiosa.

Ao Prof. Ronaldo pela oportunidade de fazer o mestrado sob sua orientação, é algo que sempre serei grato e que só poderei recompensar ajudando o próximo, agradeço pela paciência, sabedoria, compreensão e amizade. Agradeço à Prof^a. Aida pela oportunidade de ensinar e propagar o conhecimento e também pelo incentivo.

Ao Prof. Otoni pelo empenho, sabedoria e amizade que foi conquistada ao longo do desenvolvimento deste trabalho.

Ao prof. Afonso e a Prof^a Milde pela disposição em ensinar e transmitir o conhecimento com clareza.

As ótimas amigas conquistadas no LDSP, Ândria, Christiany, Guilherme, Isadora, Jonata, Jussara, Luciana, Regina, Rodrigo e Valdete, responsáveis por diversos momentos de descontração.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de estudos.

Enfim, a todos aqueles que diretamente ou indiretamente contribuíram para que este caminho pudesse ser finalizado.

*“Toda a nossa ciência,
Comparada com a realidade,
é primitiva e infantil – e,
no entanto, é a coisa mais
preciosa que temos”.*

(Albert Einstein)

Resumo da Dissertação apresentada à UFPE como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica.

AVALIAÇÃO DE MODELOS DE INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DA VELOCIDADE DE VENTO EM CURTO PRAZO

Ramon Bezerra de Souza

Agosto/2014

Orientador: Ronaldo Ribeiro Barbosa Aquino, D.Sc.

Coorientador: Otoni Nóbrega Neto, D.Sc.

Área de Concentração: Processamento de Energia.

Palavras-chave: Previsão de Ventos, Redes Neurais Artificiais, Análise de Séries Temporais, Inteligência Artificial, Sistemas Neuro-Fuzzy, Reservoir Computing.

Número de Páginas: 112.

RESUMO: O Brasil apresenta um amplo potencial eólico a ser explorado, atualmente, observa-se a grande expansão desta fonte de geração, principalmente no nordeste do Brasil, onde os ventos apresentam uma importante característica de complementaridade em relação às vazões do rio São Francisco. Porém, devido à incerteza associada à potência disponível, o aprimoramento das ferramentas de previsão de curto prazo representa um fator determinante para a operação do sistema, contribuindo para facilitar a comercialização de energia elétrica, o controle dos parques eólicos e fornecer uma estimativa futura para determinada localidade. Este trabalho é uma contribuição aos modelos de previsão de velocidades médias horárias dos ventos, para o horizonte de previsão de uma a quatro horas, utilizando as Redes Neurais Artificiais, sistemas *Neuro-Fuzzy* e o Reservoir Computing como métodos de inteligência artificial e as variáveis velocidade média do vento, umidade do ar, radiação solar e temperatura como entradas dos modelos de previsão. Os resultados obtidos para as previsões com alguns modelos propostos, revelaram ganhos da ordem de 50 % quando comparados com o modelo de referência, ratificando a eficiência dos modelos desenvolvidos.

Abstract of Dissertation presented to UFPE as a partial fulfillment of the requirements for the degree of Master in Electrical Engineering.

EVALUATION OF ARTIFICIAL INTELLIGENCE MODELS TO FORECASTING WIND SPEED IN SHORT-TERM

Ramon Bezerra de Souza

Agosto/2014

Supervisor: Prof. Ronaldo Ribeiro Barbosa de Aquino, D. Sc.

CoSupervisor: Prof. Otoni Nóbrega Neto, D. Sc.

Area of Concentration: Energy Processing.

Keywords: Wind Forecasting, Artificial Neural Networks, Time Series Analysis, Wind Energy, Artificial Intelligence, Neuro-Fuzzy System, Reservoir Computing

Number of Pages: 112.

RESUMO: Brazil has a large wind potential to be exploited, currently, there is a great expansion of this source of generation, primarily in northeastern Brazil, where winds have an important feature of complementarity with the flows San Francisco River. However, due to the uncertainty associated with the available power, the improvement in short-term forecasting tools is a key factor for system operation, helping to facilitate the sale of electricity, control of wind farms and provide an estimate for future Local determined. This work is a contribution to the average speeds hourly forecast models of the winds, to the forecasting horizon of one to four hours, using the Artificial Neural Networks, Neuro-Fuzzy systems and Reservoir Computing as methods of artificial intelligence and speed variables average wind, humidity, solar radiation and temperature as inputs for forecasting models. The results obtained for predictions with some proposed models, showed gains of about 50% compared to the reference model, confirming the efficiency of the developed models.

Sumário

TÍTULO.....	vi
AGRADECIMENTOS	v
LISTA DE FIGURAS	xiii
LISTA DE TABELAS	xvi
LISTA DE SÍMBOLOS E ABREVEATURAS	xvii
CAPÍTULO 1	1
1. INTRODUÇÃO.....	1
1.1 Considerações Iniciais	1
1.2 Objetivos.....	2
1.3 Organização do Texto.....	3
CAPÍTULO 2	4
2. POTENCIAL EÓLICO E REVISÃO BIBLIOGRÁFICA.....	4
2.1 Potencial Eólico	4
2.2 Potencial Eólico da Região Nordeste do Brasil	5
2.3 Produção de Energia Eólica.....	9
2.4 Revisão Bibliográfica.....	12
CAPÍTULO 3	14
3. INTELIGÊNCIA ARTIFICIAL.....	14
3.1 Redes Neurais	14
3.1.1 Modelo de Neurônio Artificial	15
3.1.2 Função de Ativação	16
3.1.3 Topologia de Rede Neural Artificial	18
3.1.4 O algoritmo Backpropagation	19
3.2 Sistemas <i>Neuro - Fuzzy</i>	21
3.2.1 Lógica <i>Fuzzy</i>	22

3.2.2	Sistema de Inferência <i>Mamdani</i>	23
3.2.3	Sistema de Inferência Takagi – Sugeno	25
3.2.4	ANFIS.....	26
3.3	Echo State Networks.....	29
CAPÍTULO 4		31
4. INDICADORES DE DESEMPENHO DA PREVISÃO		31
4.1	Série Temporal.....	31
4.2	Coeficiente de Correlação e Autocorrelação	31
4.3	Comparação com o Método da Persistência	33
4.4	Comparação pelos Erros de Previsão.....	33
4.5	Critérios para Comparação dos Modelos.....	34
CAPÍTULO 5		35
5. ELABORAÇÃO DOS MODELOS DE PREVISÃO DE VENTO.....		35
5.1	Bases de Dados	35
5.1.1	Séries Históricas do INMET	35
5.1.2	Séries Históricas de Marés e Fases da Lua.....	36
5.2	Localização dos Postos de Medição	36
5.2.1	Localização das estações automáticas do INMET	36
5.2.2	Localização das estações automáticas do DHN	37
5.3	Estatística Descritiva.....	37
5.3.1	Séries de Velocidades Médias Horárias	37
5.3.2	Séries de Temperaturas Médias Horárias	40
5.3.3	Séries de Umidades Médias Horárias.....	41
5.3.4	Séries de Radiação Solar Média Horária.....	43
5.3.5	Tábua de Marés	44
5.4	Descrição dos Modelos de Previsão de Velocidade de Vento.....	46
5.4.1	Modelo [1]	47

5.4.2	Modelo [2]	48
5.4.3	Modelo [3]	49
5.4.4	Modelo [4]	49
5.4.5	Modelo [5]	50
5.4.6	Modelo [6]	51
5.4.7	Modelo [7]	52
5.4.8	Modelo [8]	53
5.4.9	Modelo [9]	53
5.4.10	Modelo [10]	54
5.5	Escolha dos Melhores Modelos	54
5.6	Procedimentos para o Treinamento e Ajustes dos Melhores Modelos Utilizando RNA, ANFIS e ESN	56
5.6.1	Treinamento dos Modelos Utilizando RNA	57
5.6.2	Treinamento dos Modelos Utilizando o ANFIS	58
5.6.3	Treinamento dos Modelos Utilizando o ESN	59
CAPÍTULO 6		61
6.	PREVISÕES E COMPARAÇÕES ENTRE OS MODELOS DE PREVISÃO ...	61
6.1	Previsões de Velocidades para o Sítio de NATAL	61
6.1.1	Previsões Utilizando RNA	61
6.1.2	Previsões Utilizando ANFIS	62
6.1.3	Previsões Utilizando ESN	64
6.1.4	Comparações Entre os Métodos de IA para o Sítio de NATAL	65
6.2	Previsões de Velocidades Para o Sítio de MACAU	66
6.2.1	Previsões Utilizando RNA	66
6.2.2	Previsões Utilizando ANFIS	67
6.2.3	Previsões Utilizando ESN	68
6.2.4	Comparações Entre os Métodos de IA para o Sítio de MACAU	70

6.3	Previsões de Velocidades Para o Sítio de PETROLINA	70
6.3.1	Previsões Utilizando RNA	70
6.3.2	Previsões Utilizando ANFIS	72
6.3.3	Previsões Utilizando ESN	73
6.3.4	Comparações Entre os Métodos de IA para o Sítio de PETROLINA.....	74
6.4	Previsões de Velocidades Para o Sítio de OURICURI.....	75
6.4.1	Previsões Utilizando RNA	75
6.4.2	Previsões Utilizando ANFIS	76
6.4.3	Previsões Utilizando ESN	78
6.4.4	Comparações Entre os Métodos de IA para o Sítio de OURICURI.....	79
6.5	Previsões de Velocidades Para o Sítio de MOSSORÓ.....	80
6.5.1	Previsões Utilizando RNA	80
6.5.2	Previsões Utilizando ANFIS	81
6.5.3	Previsões Utilizando ESN	82
6.5.4	Comparações Entre os Métodos de IA para o Sítio de MOSSORÓ.....	83
CAPÍTULO 7		84
7.	CONCLUSÕES E PROPOSTAS PARA TRABALHOS FUTUROS	84
7.1	Conclusões	84
7.2	Propostas Para Trabalhos Futuros.....	85
APÊNDICE A		86
A.1	– Coeficientes de Autocorrelações de Velocidade de Vento	86
A.2	– Correlação entre Velocidade de Vento e Temperatura	87
A.3	– Correlação entre Velocidade de Vento e umidade do Ar	88
A.4	– Correlação entre Velocidade de Vento e Radiação Solar	89
A.5	– Correlação entre Velocidade de Vento e altura de marés	90
REFERÊNCIAS		91

LISTA DE FIGURAS

Figura 2.1 – Potencial eólico mundial instalado até o ano de 2013.	4
Figura 2.2 – Distribuição geral dos ventos.	5
Figura 2.3 – Complementaridade entre geração hidrelétrica e eólica no nordeste do Brasil.	8
Figura 2.4 – Principais componentes de um aerogerador.....	9
Figura 3.1 – Modelo de um Neurônio Artificial.	15
Figura 3.2 – Gráfico de exemplo de uma função Sigmóide Logística	17
Figura 3.3 – Gráfico de exemplo de uma função Tangente Hiperbólica.....	18
Figura 3.4 – Rede alimentada adiante com três camadas de neurônios.	19
Figura 3.5 – Exemplo de funções de pertinência.	22
Figura 3.6 – Exemplo de funções de pertinência.	22
Figura 3.7 – Fluxograma conceitual do sistema <i>fuzzy</i>	23
Figura 3.8 – Arquitetura da rede <i>neuro - fuzzy</i> ANFIS.	26
Figura 3.9 – Fluxograma conceitual do ANFIS	28
Figura 3.10 – Estrutura de uma rede ESN	29
Figura 5.1 – Histograma da velocidade do vento de Petrolina, Macau, Natal, Mossoró e Ouricuri.....	38
Figura 5.2 – Comportamento sazonal da velocidade média mensal do vento para Ouricuri e Petrolina.	39
Figura 5.3 - Histograma da temperatura de Petrolina, Macau, Natal, Mossoró e Ouricuri.	41
Figura 5.4 – Histograma da umidade relativa do ar para Petrolina, Macau, Natal, Mossoró e Ouricuri.....	42
Figura 5.5 - Histograma da radiação solar para Petrolina, Macau, Natal, Mossoró e Ouricuri.....	44
Figura 5.6 – Intervalo de 48 h para a série de maré de Macau.....	44
Figura 5.7 – Interpolação senoidal para Macau.....	45
Figura 5.8 – Histograma das alturas das marés para Macau e Natal.....	46
Figura 5.9 – Esquema de entrada e saída do modelo [1].....	47
Figura 5.10 – Esquema de entrada e saída do modelo [2].....	48
Figura 5.11 – Esquema de entrada e saída do modelo [3].....	49

Figura 5.12 – esquema de entrada e saída do modelo [4].	50
Figura 5.13 – Esquema de entrada e saída do modelo [5].	51
Figura 5.14 – Gráfico das funções $\sin(t)$ e $\cos(t)$.	51
Figura 5.15 – Esquema de entrada e saída do modelo [6].	52
Figura 5.16 – Esquema de entrada e saída do modelo [7].	52
Figura 5.17 – Esquema de entrada e saída do modelo [8].	53
Figura 5.18 – Esquema de entrada e saída do modelo [9].	53
Figura 5.19 – Esquema de entrada e saída do modelo [10].	54
Figura 5.20 – Raios para os sítios de Petrolina e Ouricuri.	59
Figura 6.1 – MAE das previsões de velocidade em Natal utilizando RNA.	61
Figura 6.2 – Ganho das previsões de velocidade em Natal utilizando RNA.	62
Figura 6.3 – MAE das previsões de velocidade em Natal utilizando ANFIS.	63
Figura 6.4 – Ganho das previsões de velocidade em Natal utilizando ANFIS.	63
Figura 6.5 – MAE das previsões de velocidade em Natal utilizando ESN.	64
Figura 6.6 – Ganho das previsões de velocidade em Natal utilizando ESN.	65
Figura 6.7 – MAE do experimento [2] e experimento [10] para Natal.	65
Figura 6.8 – MAE das previsões de velocidade em Macau utilizando RNA.	66
Figura 6.9 – Ganho das previsões de velocidade em Macau utilizando RNA.	67
Figura 6.10 – MAE das previsões de velocidade em Macau utilizando ANFIS.	67
Figura 6.11 – Ganho das previsões de velocidade em Macau utilizando ANFIS.	68
Figura 6.12 – MAE das previsões de velocidade em Macau utilizando ESN.	69
Figura 6.13 – Ganho das previsões de velocidade em Macau utilizando ESN.	69
Figura 6.14 – MAE do experimento [2] e experimento [10] para o sítio de Macau.	70
Figura 6.15 – MAE das previsões de velocidade em Petrolina utilizando RNA.	71
Figura 6.16 – Ganho das previsões de velocidade em Petrolina utilizando RNA.	71
Figura 6.17 – MAE das previsões de velocidade em Petrolina utilizando ANFIS.	72
Figura 6.18 – Ganho das previsões de velocidade em Petrolina utilizando ANFIS.	72
Figura 6.19 – MAE das previsões de velocidade em Petrolina utilizando ESN.	73
Figura 6.20 – Ganho das previsões de velocidade em Petrolina utilizando ESN.	74
Figura 6.21 – MAE do experimento [2] e experimento [10] para o sítio de Petrolina.	75
Figura 6.22 – MAE das previsões de velocidade em Ouricuri utilizando RNA.	75
Figura 6.23 – Ganho das previsões de velocidade em Ouricuri utilizando RNA.	76
Figura 6.24 – MAE das previsões de velocidade em Ouricuri utilizando ANFIS.	77

Figura 6.25 – Ganho das previsões de velocidade em Ouricuri utilizando ANFIS.	77
Figura 6.26 – MAE das previsões de velocidade em Ouricuri utilizando ESN.	78
Figura 6.27 – Ganho das previsões de velocidade em Ouricuri utilizando ESN.	79
Figura 6.28 – MAE do experimento [2] e experimento [10] para o sítio de Ouricuri.....	79
Figura 6.29 – MAE das previsões de velocidade em Mossoró utilizando RNA.....	80
Figura 6.30 – Ganho das previsões de velocidade em Mossoró utilizando RNA.....	81
Figura 6.31 – MAE das previsões de velocidade em Mossoró utilizando ANFIS.....	81
Figura 6.32 – Ganho das previsões de velocidade em Mossoró utilizando ANFIS.....	82
Figura 6.33 – MAE das previsões de velocidade em Mossoró utilizando ESN.....	82
Figura 6.34 – Ganho das previsões de velocidade em Mossoró utilizando ESN.....	83
Figura 6.35 – MAE do experimento [2] e experimento [10] para o sítio de Mossoró.	83
Figura A.1 – Coeficiente de autocorrelação.....	86
Figura A.2 – Coeficiente de correlação entre velocidade de vento e temperatura.	87
Figura A.3 – Coeficiente de correlação entre velocidade de vento e umidade do ar.	88
Figura A.4 – Coeficiente de correlação entre velocidade de vento e radiação solar.....	89
Figura A.5 – Correlação entre velocidade de vento e altura de maré.....	90

LISTA DE TABELAS

Tabela 4.1 – Interpretação do coeficiente de correlação e autocorrelação.	32
Tabela 5.1 – Base de dados de vento utilizada para o desenvolvimento dos modelos de previsão.....	37
Tabela 5.2 – Estatísticas da séries de velocidade de Petrolina, Macau, Natal, Mossoró e Ouricuri.....	38
Tabela 5.3 – Estatísticas da séries de temperatura de Petrolina, Macau, Natal, Mossoró e Ouricuri.....	40
Tabela 5.4 – Estatísticas das séries de umidade do ar para Petrolina, Macau, Natal, Mossoró e Ouricuri.....	41
Tabela 5.5 – Estatísticas das séries de radiação solar para Petrolina, Macau, Natal, Mossoró e Ouricuri.....	43
Tabela 5.6 – Estatísticas das séries de marés de Macau e Natal.	45
Tabela 5.7 – Relações dos modelos elaborados para cada sítio.	47
Tabela 5.8 – Representação das fases da lua em formato decimal.	49
Tabela 5.9 – Representação das fases da lua em formato binário.	50
Tabela 5.10 – Representação das fases da lua em seno e cosseno.	52
Tabela 5.11 – Valores médios do MAE.	55
Tabela 5.12 – Modelos que serão simulados com a RNA, ESN e ANFIS.	56
Tabela 5.13 – Número de neurônios na camada oculta.	58
Tabela 5.14 – Parâmetros de treinamento do ESN para Natal.	60
Tabela 5.15 – Parâmetros de treinamento do ESN para Petrolina.....	60

LISTA DE SÍMBOLOS E ABREVEATURAS

A	Área da seção transversal varrida pelo rotor
a	Parâmetro de inclinação da função sigmóide
A_j	Variáveis linguísticas de entrada
B_i	Variáveis linguísticas de saída
b_K	Bias
C_P	Coefficiente de potência do rotor
$D^{(k)}$	Coefficiente de disparo
d_j	Saída desejada
DHN	Diretoria de Hidrografia e Navegação
e_J	Erro na saída do neurônio
E	Energia cinética
$f()$	Função de ativação do reservóir
F.L.B	Fase da lua em Código Binário
F.L.C.S	Fase da lua em Código cos(t) e sen(t)
F.L.D	Fase da lua em Código Decimal
f^{out}	Função de ativação da camada de saída
h_1	Altura da medição velocidade conhecida
h_2	Altura pretendida para velocidade estimada
IA	Inteligência artificial
H_m	Elevação do local
m	Massa de ar
PROINFA	Programa de Incentivo às Fontes Alternativas de Energia Elétrica
P_{mec}	Potência mecânica
SIN	Sistema Interligado Nacional
T	Temperatura ambiente
u_K	Saída do combinador linear
$u(n)$	Entrada no tempo n
v	Velocidade do vento
$v(t)$	Velocidade média do vento no instante t
$\hat{v}(t + 1)$	Velocidade média do vento prevista no instante t + 1

\overline{v}	Velocidade média do vento
v_0	Velocidade na altura conhecida
$v(h)$	Velocidade na altura h
y_k, y_j	Sinal de saída do neurônio
v_k, v_j	Campo local induzido
W	Conexões do reservoir
W^{in}	Conexões da camada de entrada para o reservoir
W^{back}	Conexões da camada de saída para o reservoir
W^{bias}	Conexões bias para o reservoir
$W^{biasout}$	Conexões bias para camada de saída
W^{inout}	Conexões da camada de entrada para camada de saída
W^{out}	Conexões do reservoir para camada de saída
W^{outout}	Conexões da camada de saída para camada de saída
$W_{kj}, w_{ji}(n)$	Pesos sinápticos
x_j	Sinal de entrada
$x_{máx}$	Maior valor corresponde ao vetor em que se encontra o dado a ser normalizado
x_{min}	Menor valor corresponde ao vetor em que se encontra o dado a ser normalizado
$x(n)$	Estado o reservoir no tempo n
$\tilde{x}(t)$	Valor normalizado correspondente ao instante t
$x(t)$	Valor real do dado corresponde ao instante t
$y(n)$	Saída no tempo n
α	Coefficiente que depende da natureza do terreno
η	Taxa de aprendizagem
$\varepsilon(n)$	Energia total do erro
μ_{A_i}	Função de pertinência
ρ	Densidade do ar
$\varphi(\cdot)$	Função de ativação

CAPÍTULO 1

1. INTRODUÇÃO

No presente capítulo são feitas as considerações iniciais e uma breve descrição da organização do texto. Também é apresentada a contribuição desta dissertação.

1.1 Considerações Iniciais

A energia eólica provém do aquecimento não uniforme da superfície terrestre pelos raios solares e pelo movimento de rotação da terra, causando o movimento das massas de ar, dando origem aos ventos (PAVINATTO, 2005). É uma fonte que apresenta baixos índices de poluição, devido a não lançar durante a geração, gases poluentes na atmosfera.

Com o desenvolvimento de novas linhas de pesquisa e equipamentos, os custos de instalação e produção de energia elétrica a partir do vento tem se tornado bastante atrativo, colocando a energia eólica como forte concorrente em relação às fontes de geração térmica, devido a possibilidade da transmissão de energia elétrica produzida em decorrência dos ventos em grandes blocos.

Com a criação do programa PROINFA, em 2002, o governo teve como intuito promover a diversificação da matriz energética nacional, buscando alternativas para aumentar a segurança no abastecimento de energia. De todas as fontes alternativas exploradas, a energia eólica se apresenta como mais promissora (PROINFA, 2002). Atualmente a potência eólica instalada no parque gerador nacional é da ordem de 3752 MW, ou seja, 2,88 % de toda capacidade disponível do SIN. Além disto, dos 148 projetos em execução atualmente, cerca de 68 % destes projetos, correspondem a novos projetos de geração eólica, o que vai propiciar ao parque gerador nacional o incremento de 2670 MW nos próximos anos (ANEEL, 2014).

Porém, devido às características estocásticas do vento, a geração eólica possui certas desvantagens quando comparadas com outras fontes de energia elétrica. A energia elétrica gerada por usinas eólicas é variável, tornando-a menos confiável quando comparada com as fontes de energia tradicionais (LEITE, 2005).

Devido à incerteza associada à potência disponível, o aprimoramento das ferramentas de previsão de curto prazo representa um fator determinante para a operação do sistema. A

previsão eficaz dos ventos pode contribuir para facilitar a comercialização de energia elétrica, contribuir para os sistemas de controle dos parques eólicos e fornecer uma estimativa futura para determinada localidade.

Vários modelos são utilizados para previsão de vento (GIEBEL et al., 2003; MILIGAN et al., 2003), e com o advento dos métodos de inteligência artificial aplicados em diversas áreas de previsões, sua utilização foi disseminada também na área de previsão de ventos (FERREIRA et al., 2008; COSTA et al., 2008; KARINIOTAKIS et al., 1996). Os métodos de inteligência artificial se caracterizam pela robustez e capacidade de generalização do aprendizado durante o treinamento.

O Brasil apresenta um amplo potencial eólico a ser explorado, e o desenvolvimento de ferramentas de previsão de vento é de fundamental importância para que se tenha um sistema confiável e eficiente.

1.2 Objetivos

Esta dissertação tem como objetivo o desenvolvimento e a avaliação de modelos de previsão de velocidade de vento, utilizando as Redes Neurais Artificiais (RNA), ANFIS e o *Reservoir Computing* como métodos de inteligência artificial.

Os modelos realizam a previsão de velocidade de vento para os passos de previsão de uma até quatro horas, nos quais as entradas podem ser uma ou mais variáveis. As variáveis considerada neste texto são as seguintes: velocidade média horária dos ventos, altura das marés, temperatura instantânea, umidade relativa do ar e nível de radiação solar.

Espera-se contribuir com esta dissertação, para o desenvolvimento de uma ferramenta computacional confiável e eficiente para previsão de velocidade de vento. Foram escolhidos os estados de Pernambuco e Rio Grande do Norte para avaliação dos sítios eólicos, devido às características de complementaridade entre a vazão do Rio São Francisco e a velocidade do vento no nordeste do Brasil. É importante destacar que a região nordeste tem um amplo potencial eólico a ser explorado, da ordem 75 GW, inserindo-a como uma região estratégica do ponto de vista de geração de energia elétrica por meio de fontes alternativas.

1.3 Organização do Texto

Esta dissertação foi composta de sete capítulos, o primeiro deles é a introdução, e os demais serão descritos a seguir:

- **Potencial Eólico e Revisão Bibliográfica:** neste capítulo é apresentada uma descrição sobre o potencial eólico do nordeste do Brasil, assim como uma breve revisão bibliográfica sobre alguns modelos de previsão de vento.
- **Métodos de Inteligência Artificial:** o capítulo apresenta os métodos de inteligência artificial utilizados para o desenvolvimento dos modelos de previsão de velocidade de vento.
- **Avaliação dos Modelos:** este capítulo descreve a metodologia utilizada para avaliação dos modelos de previsão.
- **Elaboração dos Modelos de Previsão:** Este capítulo descreve a base de dados utilizada para o desenvolvimento dos modelos, bem como o desenvolvimento dos modelos.
- **Previsões e Comparações Entre os Modelos:** Este capítulo são apresentados os resultados das simulações obtidas e as análises comparativas entre os modelos.
- **Conclusões e Trabalhos Futuros:** São apresentadas as conclusões e as propostas de trabalhos futuros para que se possa dar continuidade às pesquisas nesse contexto.

CAPÍTULO 2

2. POTENCIAL EÓLICO E REVISÃO BIBLIOGRÁFICA

2.1 Potencial Eólico

Segundo (GWEC, 2014) o potencial eólico mundial instalado até o ano de 2013 era da ordem de 318 GW, apenas cinco países (China, Estados Unidos, Alemanha, Espanha e Índia) são detentores de 72,2 %, (ver Figura 2.1), de todo potencial eólico mundial. Mesmo com esse expressivo crescimento, de 35,3% em 2013, é possível notar que houve uma retração quando comparado com o crescimento do ano anterior, 45,2 %. Até o ano de 2013 o Brasil era responsável por cerca de 1,07 % de toda potência eólica instalada no mundo, destacando-se entre os sete países do mundo que mais incrementaram o seu parque gerador eólico no ano de 2013.

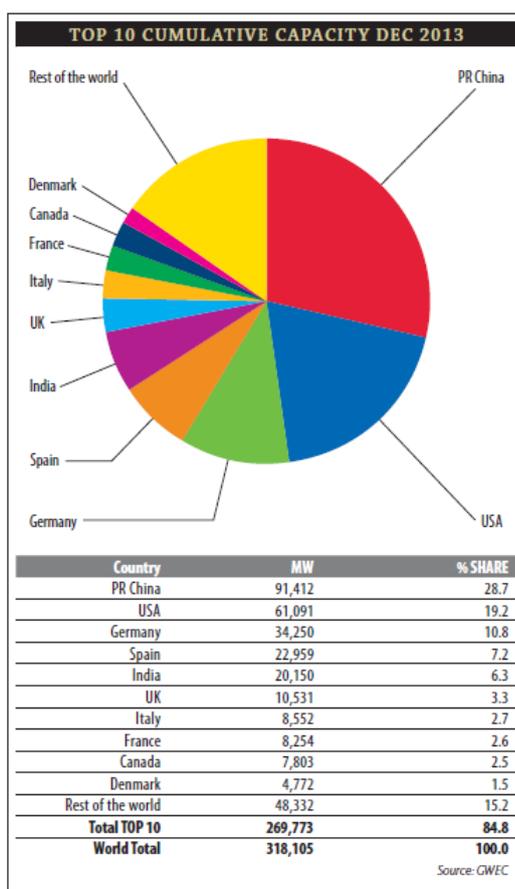


Figura 2.1 – Potencial eólico mundial instalado até o ano de 2013.
Fonte: (GWEC, 2014).

2.2 Potencial Eólico da Região Nordeste do Brasil

A distribuição geral dos ventos sobre o Brasil é controlada pelos aspectos da circulação geral planetária da atmosfera próxima, conforme se apresenta na Figura 2.2. Dentre esses aspectos, sobressaem os sistemas de alta pressão Anticiclone Subtropical do Atlântico Sul e do Atlântico Norte e a faixa de baixas pressões da Depressão Equatorial (AMARANTE et al., 2001).

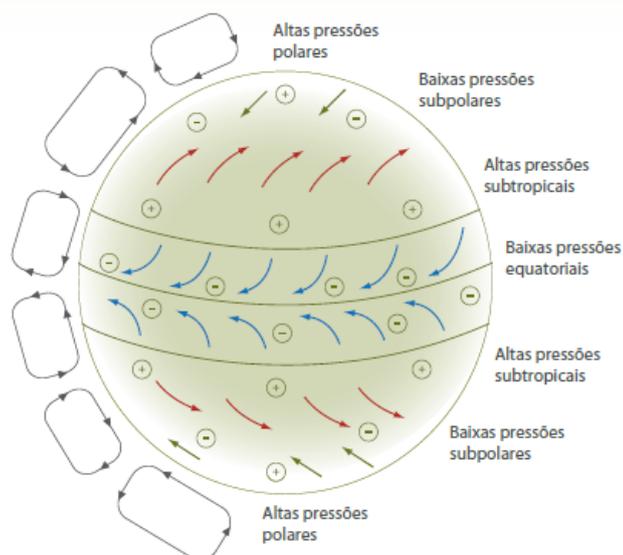


Figura 2.2 – Distribuição geral dos ventos.
Fonte: (ANDRADE GUERRA et al., 2011).

A posição média da Depressão Equatorial estende-se de oeste a leste ao longo da região Norte do Brasil e sobre o Oceano Atlântico adjacente. Ela coincide com a localização e orientação da Bacia Amazônica, no centro da qual existe uma faixa persistente de baixas pressões. A Depressão Equatorial é geralmente uma zona de pequenos gradientes de pressão e ventos fracos. Ao norte da Depressão Equatorial os ventos são persistentes de leste a nordeste. Ao sul, os ventos são persistentes de leste a sudeste entre a Depressão Equatorial e o Anticiclone Subtropical Atlântico, o qual tem uma posição média anual próxima a 30° S, 25° O. Esse perfil geral de circulação atmosférica induz ventos de leste ou nordeste sobre o território brasileiro ao norte da Bacia Amazônica e no litoral nordeste. Os ventos próximos à superfície são geralmente fracos ao longo da Depressão Equatorial, porém aumentam de intensidade ao norte e ao sul dessa faixa (AMARANTE et al., 2001).

A área entre a Depressão Equatorial e a latitude de 10° S é dominada pelos ventos alísios de leste a sudeste. Ao sul da latitude 10° S, até o extremo sul brasileiro, prevalecem

os efeitos ditados pela dinâmica entre o centro de alta pressão Anticiclone Subtropical Atlântico, os deslocamentos de massas polares e a Depressão do Nordeste da Argentina – centro de baixas pressões a leste dos Andes (AMARANTE et al., 2001).

Esse perfil geral de circulação atmosférica encontra variações significativas na mesoescala e na microescala, por diferenças em propriedades de superfícies, tais como geometria e altitude de terreno, vegetação e distribuição de superfícies de terra e água. Esses fatores atuantes nas escalas menores podem resultar em condições de vento locais que se afastam significativamente do perfil geral da larga escala da circulação atmosférica (AMARANTE et al., 2001).

A Zona Litorânea Norte-Nordeste é definida como a faixa costeira com cerca de 100 km de largura, que se estende entre o extremo norte da costa do Amapá e o Cabo de São Roque, no Rio Grande do Norte. Nessa região, os ventos são controlados primariamente pelos alísios de leste e brisas terrestres e marinhas. Essa combinação das brisas diurnas com os alísios de leste resulta em ventos médios anuais entre 5 m/s e 7,5 m/s na parte norte dessa região (litorais do Amapá e Pará) e entre 6 m/s a 9 m/s em sua parte sul, que abrange os litorais do Maranhão, Piauí, Ceará e Rio Grande do Norte. As velocidades são maiores na parte sul devido a dois principais fatores: (1) os ventos alísios geralmente tornam-se mais fortes à medida que se afastam da Depressão Equatorial; (2) as brisas marinhas são significativamente acentuadas ao sul dessa região em razão dos menores índices de vegetação e de umidade do solo, fazendo que a superfície do solo atinja temperaturas mais elevadas durante as horas de sol e, conseqüentemente, acentuando o contraste de temperaturas terra-mar e as brisas marinhas resultantes (AMARANTE et al., 2001).

As maiores velocidades médias anuais de vento ao longo dessa região estão ao norte do Cabo de São Roque, abrangendo os litorais do Rio Grande do Norte e Ceará, onde a circulação de brisas marinhas é especialmente intensa e alinhada com os ventos alísios de leste-sudeste. Adicionalmente, ocorrem áreas em que os ventos são acentuados por bloqueios ao escoamento causados por montanhas na parte continental. Entretanto, o vento médio anual decresce rapidamente à medida que se desloca da costa para o interior, devido ao aumento de atrito e rugosidade de superfície e ao enfraquecimento da contribuição das brisas marinhas (AMARANTE et al., 2001).

A Zona Litorânea Nordeste-Sudeste é definida como a faixa de aproximadamente 100 km de largura que se estende entre o Cabo de São Roque (RN) até aproximadamente o

Estado do Rio de Janeiro. As velocidades médias anuais decrescem de 8 a 9 m/s na porção norte (Rio Grande do Norte) até 3,5 m/s a 6 m/s sobre a maioria da costa que se estende até o Sudeste. A exceção mais significativa desse comportamento está na costa entre as latitudes 21° S e 23° S (sul do Espírito Santo e nordeste do Rio de Janeiro), onde as velocidades são próximas de 7,5 m/s. Isso é resultante do efeito de bloqueio do escoamento leste-nordeste (causado pelo Anticiclone Subtropical Atlântico) pelas montanhas imediatamente a oeste da costa. Nesse caso, é criada uma espécie de aceleração por obstáculo, pois o ar acelera-se para o sul para aliviar o acúmulo de massa causado pelo bloqueio das formações montanhosas. Ao sul dessa região, a costa do Estado do Rio de Janeiro desvia-se para oeste, onde os ventos passam a ser consideravelmente mais fracos devido ao abrigo das montanhas a norte e a nordeste. Disso resultam velocidades relativamente menores na região que engloba a cidade do Rio de Janeiro (AMARANTE et al., 2001).

As Elevações Nordeste-Sudeste são definidas como as áreas de serras e chapadas que se estendem ao longo da costa brasileira, desde o Rio Grande do Norte até o Rio de Janeiro, a distâncias de até 1.000 km da costa. Velocidades médias anuais de 6,5 m/s até 8 m/s devem ser encontradas nos cumes das maiores elevações da Chapada Diamantina e da Serra do Espinhaço. Essas áreas de maiores velocidades ocorrem em forma localizada, primariamente devido ao efeito de compressão vertical do escoamento predominante em larga escala, que é leste - nordeste, quando ultrapassa a barreira elevada das serras. Os ventos anuais mais intensos são geralmente encontrados nas maiores elevações, onde o efeito de compressão é mais acentuado. No entanto, o escoamento atmosférico é bastante complexo nessa região, existindo outras características locais com influência adicional, resultantes de uma combinação de fatores relacionados à topografia e ao terreno (GWEC, 2014).

Segundo os estudos realizados por (ANDRADE GUERRA et al., 2011) o potencial eólico da região nordeste é da ordem de 75 GW, representando quase a metade de todo potencial eólico Brasileiro. Porém, estes dados são baseados no *Atlas do Potencial Eólico Brasileiro*, publicado em 2001, pesquisadores acreditam que este atlas está defasado e uma versão atualizada é aguardada desde 2009. O argumento dado é trivial, segundo os pesquisadores, o atlas utiliza como referencial a altura do rotor em torno de 50 m de altura, e hoje grande parte das turbinas instaladas dispõem de alturas entre 90 m e 100 m elevando ainda mais o potencial eólico na região nordeste e também do Brasil.

É importante destacar que a instalação de parques eólicos na região nordeste permite a utilização mais eficiente dos recursos hidrelétricos desta região, devido às características de complementaridade desta fonte e a vazão do Rio São Francisco onde estão instaladas as usinas da CHESF (AQUINO et al., 2010). Na Figura 2.3 é possível perceber a complementariedade das fontes, pois durante o período seco (abril até outubro), a velocidade média mensal dos ventos na região nordeste aumenta bastante e durante o período molhado (novembro a março) ocorre o inverso, a vazão do Rio São Francisco aumenta e a velocidade média mensal do vento reduz.

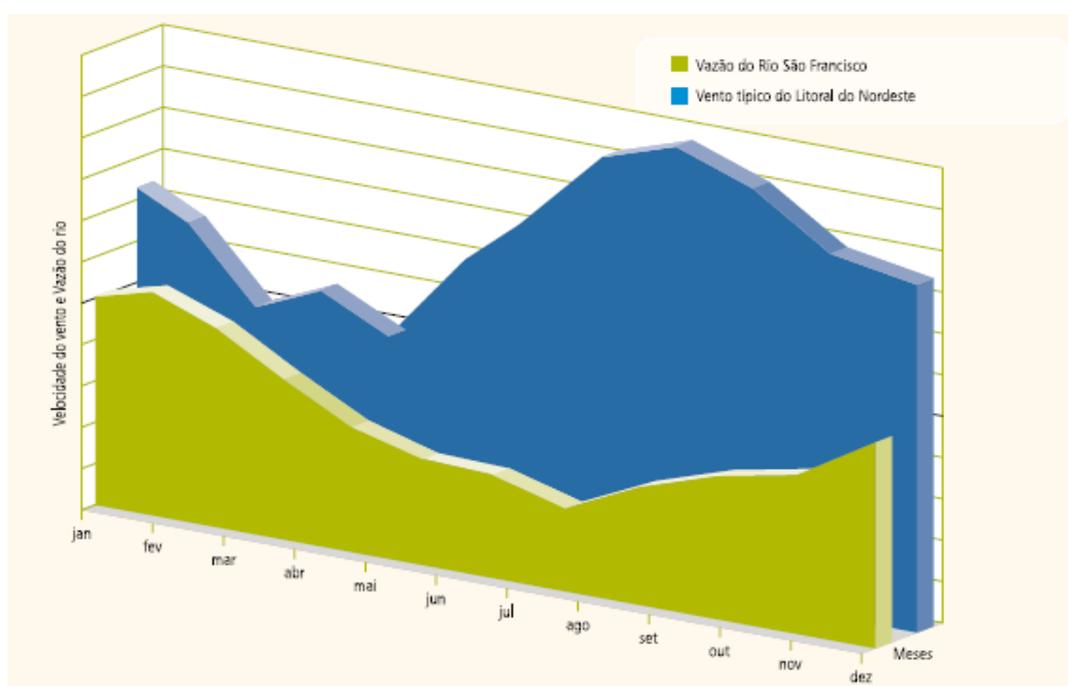


Figura 2.3 – Complementaridade entre geração hidrelétrica e eólica no nordeste do Brasil.

Uma maior preocupação com a operação do sistema deve ser estabelecida no período seco, pois o sistema fica fragilizado perante uma penetração maior da energia eólica e uma possibilidade menor de controle rápido com a escassez de energia hidroelétrica.

2.3 Produção de Energia Eólica

A produção da energia eólica é feita através da captação da energia cinética dos ventos pelas pás do aerogerador. As pás estão diretamente conectadas ao rotor, que converte a energia cinética dos ventos em energia mecânica, o rotor está conectado a um gerador, que converte a energia mecânica em energia elétrica, e esta é distribuída através da rede. A Figura 2.4 representa os principais componentes de um aerogerador.

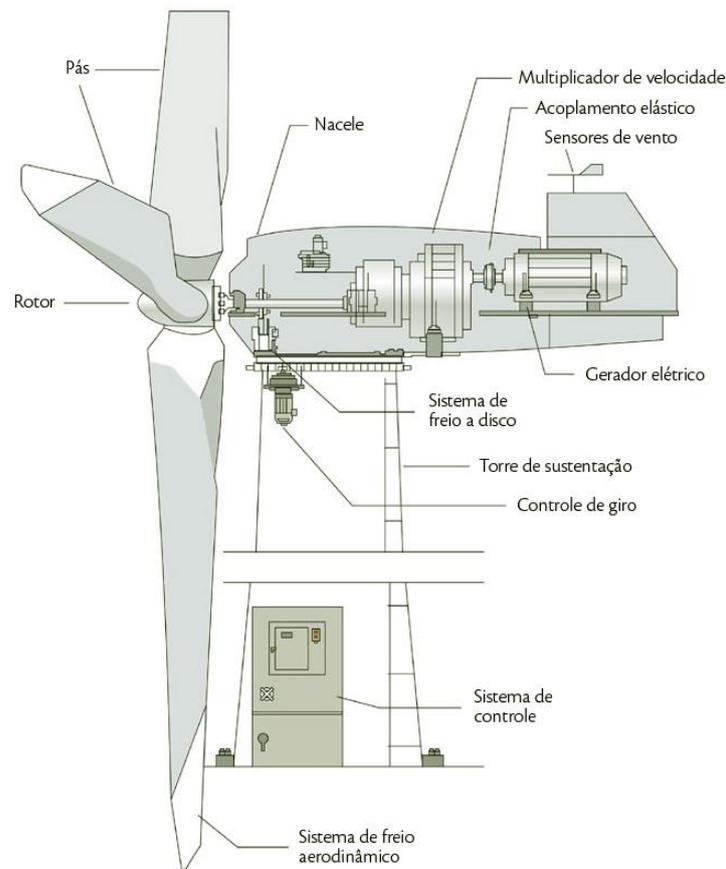


Figura 2.4 – Principais componentes de um aerogerador.
Fonte: (AMARANTE et al., 2001).

Matematicamente, a energia cinética dos ventos se expressa como:

$$E = \frac{1}{2}mv^2, \quad (2.1)$$

em que:

E = Energia cinética (J);

m = massa de ar (kg);

v = velocidade do vento (m/s).

A potência mecânica disponível no vento a montante do aerogerador, que passa pela área varrida pela turbina (A), transversal ao fluxo de ar, se expressa do seguinte modo:

$$P_{mec} = \frac{1}{2} \rho A v^3, \quad (2.2)$$

em que:

A = Área da seção transversal varrida pelo rotor (m^2);

ρ = Densidade do ar (kg/m^3).

O valor da potência calculado pela Equação (2.2) é a potência disponível no vento. Porém, a máxima potência que pode ser extraída do vento por uma turbina eólica apresenta uma limitação que é referente a uma velocidade do vento na saída do rotor eólico que não pode ser inferior a 1/3 da velocidade do vento incidente v . Neste caso, o rotor absorve a energia equivalente a 2/3 da energia disponível no vento livre antes da turbina (CUSTÓDIO, 2009). Em condições ideais, o valor máximo da energia captada por um rotor eólico é limitado pelo *máximo de Betz* dada pelo fator 0,593. O qual representa que, 59,3% da energia contida no fluxo de ar podem ser extraídos por uma turbina eólica ideal.

Devido às perdas inerentes ao processo de conversão de energia, o máximo de Betz não pode ser atingido, e assim, a potência realmente extraída pela turbina é:

$$P = \frac{1}{2} \rho A v^3 C_p, \quad (2.3)$$

em que:

C_p = Coeficiente de potência do rotor ou eficiência do rotor (adimensional).

Há dependência da potência realmente extraída em relação à densidade do ar, porém a densidade do ar é função da altura. Logo, é conveniente estimar a densidade do ar para a altura em que o rotor é instalado pela seguinte expressão (CUSTÓDIO, 2009).

$$\rho \cong \frac{353,4 \left(1 - \frac{H_m}{45271}\right)^{5,2624}}{273,15 + T}, \quad (2.4)$$

em que:

H_m = Elevação do Local (m);

T = Temperatura ambiente (K).

Outro fator é a velocidade do vento, caso a medição tenha ocorrido em uma altura diferente daquela onde será posicionado o rotor, as velocidades deverão ser corrigidas para a altura do rotor. Na literatura atual, dois métodos práticos são utilizados para fazer a conversão, através do perfil exponencial, mais conhecido como lei da potência e o comportamento logarítmico (CUSTÓDIO, 2009).

A expressão matemática do comportamento logarítmico é a seguinte:

$$\frac{v(h)}{v_0} = \frac{\ln\left(\frac{h_1}{z_0}\right)}{\ln\left(\frac{h_2}{z_0}\right)}, \quad (2.5)$$

em que:

$v(h)$ = velocidade na altura h ;

v_0 = velocidade na altura h_1 (conhecida);

h_1 = altura da medição velocidade v_0 ;

h_2 = altura pretendida para velocidade $v(h)$.

A Equação 2.6 representa a lei da potência.

$$v(h) = v_0 \left(\frac{h_2}{h_1}\right)^\alpha. \quad (2.6)$$

em que:

α = Coeficiente que depende da natureza do terreno e está contido no intervalo [0,06, 0,6].

2.4 Revisão Bibliográfica

A referência (GIEBEL et al., 2003) foi utilizada como orientação para o desenvolvimento desta seção. Em (GIEBEL et al., 2003) uma visão geral sobre as tentativas passadas e presentes para previsão de ventos e geração eólica de turbinas individuais ou regiões inteiras é fornecida. A previsão é realizada para passos de minutos até horas, e para horizonte de previsão de alguns dias à frente. Em (MADSEN et al., 2004), é elaborada uma metodologia padronizada para apresentar os resultados sobre a precisão de um modelo de previsão, com o objetivo de ter uma ideia clara sobre as vantagens de uma abordagem específica em relação aos métodos de referência.

Dependendo das entradas, os modelos para previsão de curto prazo são classificados em físicos, estatísticos ou a combinação de ambos. A modelagem física utiliza considerações físicas, ou seja, considerações meteorológicas, topológicas e características das turbinas eólicas. Modelos estatísticos utilizam variáveis explicativas e medições on-line, geralmente empregando técnicas recursivas, como mínimos quadrados recursivos ou redes neurais artificiais. O objetivo do modelo físico é encontrar a melhor estimativa possível do vento e em seguida utilizar o modelo estatístico para redução do erro remanescente. Ambos os modelos usam o NWP (*numerical weather prediction*). Modelos que não usam o NWP são aceitáveis para as três ou quatro primeiras horas, porém para longos horizontes de previsão apresentam resultados insatisfatórios. Em geral, é utilizada uma combinação de ambos os modelos para realização das previsões (SIDERATOS et al., 2006).

Um método avançado de estatística para previsão de energia eólica com bases em técnicas de inteligência artificial é apresentado (SIDERATOS et al., 2006). O método requer como entrada as medições de potência passadas e as previsões meteorológicas de velocidade e direção. A principal contribuição do método é que ele usa redes neurais, combinadas com um modelo de *lógica fuzzy* a fim de otimizar o uso dos modelos de previsão numérica de velocidade.

Em (AQUINO et al., 2013), são desenvolvidos dois modelos para previsão de geração eólica, com o passo de previsão de seis horas e horizonte de previsão de cinco dias. Ambos os modelos utilizam as RNAs como ferramenta de inteligência artificial e as entradas são velocidades de vento e/ou potência ativa, para produzirem a previsão de geração. Para o passo de previsão de seis horas, a velocidade do vento é discretizadas em

intervalos de tempo de dez minutos, e trinta minutos para o modelo com horizonte de previsão de cinco dias.

O artigo (AQUINO et al., 2012) sugere a aplicação de redes neurais artificiais, sistemas de inferência neuro-fuzzy e análise de multiresolução por transformadas wavelets para previsão de geração de energia dos sítios de Macau, Natal e Mossoró, com passo de previsão de até vinte quatro horas à frente. Os modelos são univariados e a melhoria obtida para o sítio de Natal sobre o modelo da *persistência* é da ordem de 60 % para o passo de previsão de até seis horas.

Em (FERREIRA et al., 2008), é utilizado *Reservoir Computing* do tipo ESN (*echo state networks*) para realizar a previsão de velocidade de vento dos sítios de Olinda e Belo Jardim, os sítios são localizados no estado de Pernambuco, o passo de previsão foi de vinte quatro horas à frente. O modelo é univariado e as entradas foram escolhidas a partir da análise dos coeficientes de autocorrelação. Os resultados foram comparados com o método da *Persistência* e com as redes *MLP*, obtendo desempenho superior aos métodos comparados.

CAPÍTULO 3

3. INTELIGÊNCIA ARTIFICIAL

O presente capítulo tem como objetivo expor os conceitos básicos sobre inteligência artificial que serão abordados no desenvolvimento dos modelos de previsão de vento que serão discutidos no capítulo 5. Este capítulo é composto por três seções, em que a primeira seção apresenta as Redes Neurais Artificiais, a segunda seção que aborda a Lógica Fuzzy, bem como o ANFIS, e por último as Echo State Networks (ESN).

3.1 Redes Neurais

Uma Rede Neural Artificial (RNA) é uma tentativa de reproduzir a estrutura e o funcionamento do cérebro humano em um computador. As redes neurais apresentam características que as tornam especialmente atrativas, que são: paralelismo, processamento de informação incerta, capacidade de aprendizagem, robustez e tolerância a falhas. Em outras palavras as redes neurais apresentam a capacidade de se adaptar ou aprender, depois generalizar, agrupar ou organizar dados e por fim otimizar.

As RNAs são sistemas paralelos e distribuídos compostos por unidades de processamento simples, chamados de neurônios artificiais, que calculam determinadas funções matemáticas (normalmente não lineares). Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões. Na maioria dos modelos estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede (LUDEMIR et al., 2000).

Hoje, as redes neurais servem de base, entre outras aplicações, para o sistema de reconhecimento óptico de caracteres empregados em digitalizadores, previsões meteorológicas, detectores de bombas e até mesmo em previsões para o mercado financeiro e apresentam-se como uma abordagem alternativa aos métodos estatísticos de previsão temporal.

3.1.1 Modelo de Neurônio Artificial

O artigo proposto por McCulloch e Pitts (1943) é o precursor no desenvolvimento de redes neurais e inteligência artificial. Nele o neurônio é apresentado com pesos fixos e apenas implementam funções linearmente separáveis.

Após várias pesquisas chega-se a uma rede neural artificial composta de vários neurônios artificiais altamente conectados.

Um neurônio artificial é a unidade de processamento da informação fundamental para a operação de uma rede neural. Em geral, as RNAs são compostas pela camada de entrada, camada escondida (que pode ser denominada como intermediária ou oculta e que também pode conter outras subcamadas), e camada de saída. Vale salientar que apenas a camada de entrada não é composta por neurônios (AFONSO MARQUES, 2014). A camada de entrada é responsável pelas variáveis de entrada do modelo, enquanto a camada de saída representa os resultados finais de processamento. Nas camadas intermediárias, o processamento é refinado, possibilitando a formação de relações não lineares (HAYKIN, 2001).

A Figura 3.1 representa o modelo de um neurônio artificial, podemos identificar três elementos fundamentais que compõem uma rede neural artificial: um conjunto de sinapses, um somador ou integrador de sinais e uma função de ativação (função de transferência).

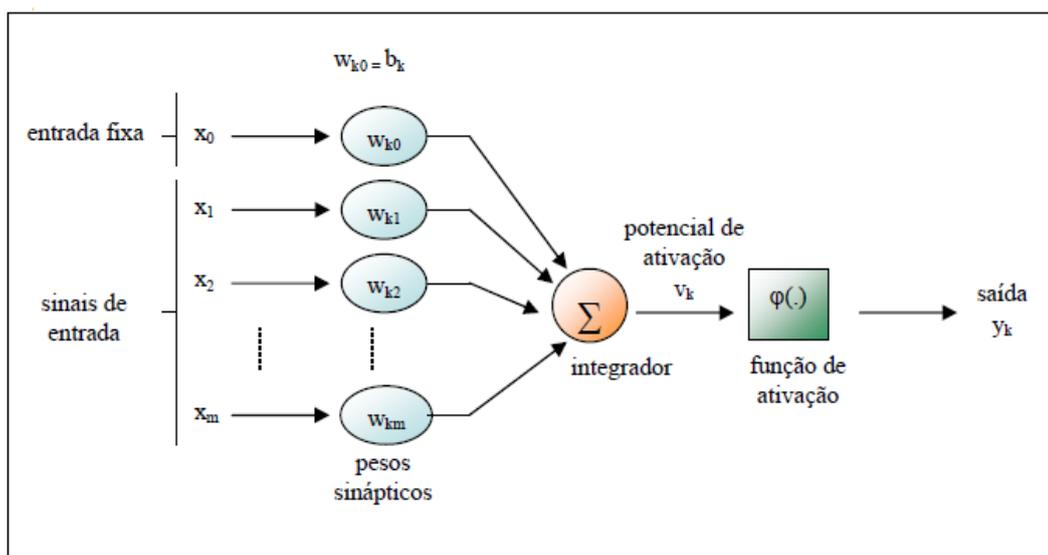


Figura 3.1 – Modelo de um Neurônio Artificial.

Fonte: (LIMA et al.,2009).

Cada sinapse é caracterizada por um peso. Um sinal na entrada da sinapse é multiplicado pelo peso sináptico. O integrador realiza a soma dos sinais das entradas, ponderado pelas respectivas sinapses. A função de ativação pode amplificar, reduzir ou restringir a amplitude do sinal de saída do neurônio artificial a um valor finito. Vale destacar que o peso sináptico pode assumir valores positivos e negativos. O modelo neural da Figura 3.1 inclui um *bias* aplicado externamente, que é representado por b_k . Ele tem a função de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo.

Matematicamente, podemos descrever um neurônio k em função das seguintes equações:

$$u_k = \sum_{j=1}^m w_{kj} x_j, \quad (3.1)$$

$$y_k = \varphi(u_k + b_k), \quad (3.2)$$

em que:

$$v_k = u_k + b_k. \quad (3.3)$$

3.1.2 Função de Ativação

A partir do modelo proposto por McCulloch e Pitts, foram derivados outros modelos que permitem a confecção de uma saída qualquer e com diferentes funções de ativação (LUDEMIR et al., 2000). Nesta dissertação serão abordados dois tipos de função de ativação (função de transferência) que serão utilizados na confecção dos modelos de previsão de vento a serem descritos no capítulo 4 deste texto.

A primeira função a ser comentada é a *função sigmóide logística*, este tipo de função é a mais comum das funções de ativação utilizadas e apresenta um gráfico cuja forma é um “s”. A função sigmóide assume um intervalo contínuo de valores entre 0 e 1 e é diferenciável. Sua representação está indicada na Figura 3.2.

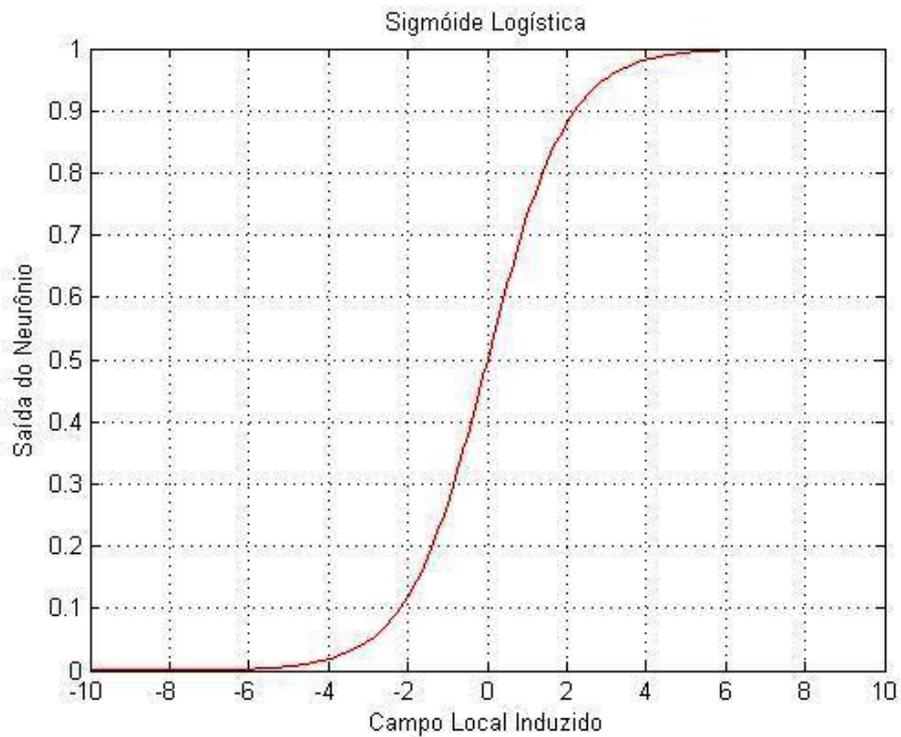


Figura 3.2 – Gráfico de exemplo de uma função Sigmóide Logística

Matematicamente, a função *sigmóide logística* se expressa da seguinte forma:

$$\varphi(v_k) = \frac{1}{1 + e^{(-av_k)}} \quad (3.4)$$

em que:

a = é o parâmetro de inclinação da função sigmóide.

Outra função de ativação comumente utilizada é a *tangente hiperbólica*. Em alguns casos sua utilização é importante, devido à necessidade de se obter o sinal no intervalo $[-1,1]$ para saída da função de ativação do neurônio. A Figura 3.3 mostra o gráfico da função de ativação tangente hiperbólica.

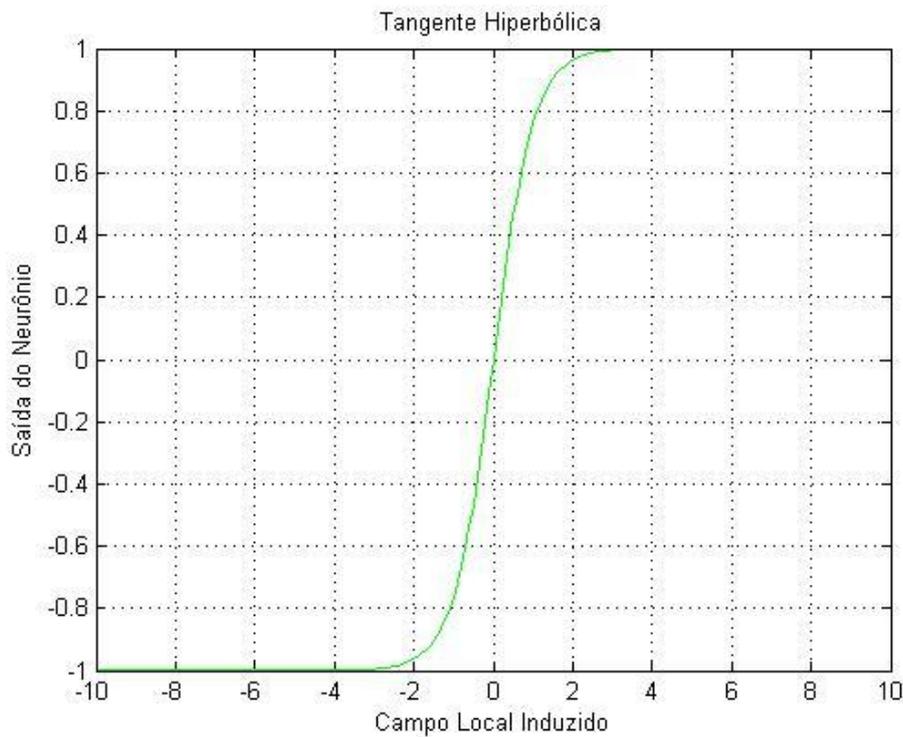


Figura 3.3 – Gráfico de exemplo de uma função Tangente Hiperbólica.

Matematicamente, a função *tangente hiperbólica* se expressa da seguinte forma:

$$\varphi(v_k) = \frac{2}{1 + e^{-av_k}} - 1 \quad (3.5)$$

É importante destacar que para a tangente hiperbólica o *software* de simulação utiliza como parâmetro de inclinação o valor de $a = 2$.

3.1.3 Topologia de Rede Neural Artificial

O modo como os neurônios de uma rede neural são dispostos está diretamente ligada ao algoritmo utilizado para treinar a rede. Em geral, podemos identificar três classes de arquiteturas de redes diferentes: redes alimentadas a diante com camada única, redes alimentadas diretamente com múltiplas camadas e as redes recorrentes.

Nesta dissertação abordaremos as redes alimentadas a diante com múltiplas camadas, ou como normalmente é disseminado na literatura *Multilayer Feed forward*, pois esta topologia será utilizada para criação dos modelos de previsão de vento.

As redes *Multilayer Feedforward* são caracterizadas pela presença de uma ou mais camadas ocultas. A função dos neurônios ocultos é intervir entre a entrada externa e a saída da rede de uma maneira coerente (HAYKIN, 2001). O sentido de conexão é sempre voltado para a camada de saída, não havendo realimentação de sinais entre as camadas.

A rede representada na Figura 3.4 é constituída de dois nós na camada entrada, duas camadas ocultas, e para cada camada oculta quatro neurônios foram dispostos e por fim um neurônio na camada de saída.

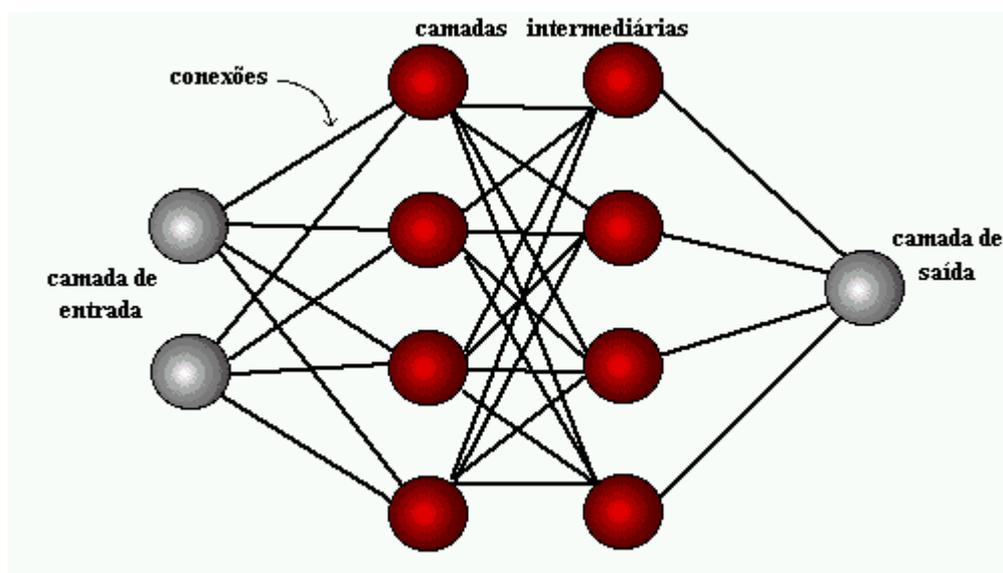


Figura 3.4 – Rede alimentada adiante com três camadas de neurônios.

De acordo com a Figura 3.4 podemos perceber que a rede é totalmente conectada, ou seja, um nó de uma camada da rede está conectado a todos os outros nós da camada adjacente seguinte.

3.1.4 O algoritmo Backpropagation

O algoritmo de aprendizagem supervisionada para o treinamento de redes MLP (*multilayer perceptron*) mais difundido é o *backpropagation* (retropropagação) devido a sua relativa facilidade de implementação e capacidade minimizar o sinal de erro obtido através do ajuste dos pesos sinápticos.

O treinamento do algoritmo de retropropagação ocorre em duas fases: fase *forward* (para frente) e *backward* (para trás), cada fase percorre um sentido da rede. Na fase

forward é apresentado à rede um padrão de dados de entrada, a rede processa esses dados e gera uma saída, essa saída é comparada com o resultado desejado e definimos o erro gerado. Na fase *backward*, é utilizado o erro calculado na fase *forward* para atualizar os pesos das conexões sinápticas objetivando a minimização do erro ou até a realização de um dado número de ciclos. O algoritmo backpropagation é apresentado a seguir:

O sinal de erro na saída do neurônio j , na iteração n é definido por:

$$e_j(n) = d_j(n) - y_j(n), \quad (3.6)$$

em que j é um nó de saída. As variáveis d_j e y_j significam, respectivamente, saída desejada e saída calculada.

O erro médio quadrático (MSE) é função de todos os parâmetros livres (pesos sinápticos e bias) da rede, ela é obtida somando o quadrado do erro de todos os neurônios da camada de saída. O MSE é dado pela seguinte equação:

$$\varepsilon(n) = \frac{1}{2} \sum_{j=1}^N e_j^2(n), \quad (3.7)$$

Considere o neurônio da camada de saída j , sendo estimulado pelas ativações produzidas por um conjunto de neurônios a sua esquerda. O potencial de ativação do neurônio j é definido por:

$$v_j(n) = \sum_{i=0}^m w_{ji}(n)y_i(n), \quad (3.8)$$

em que:

$m =$ é o número total de entradas.

Representando a função de ativação que aparece $y_j(n)$ na saída do neurônio j na iteração n é:

$$y_j(n) = \varphi_j(v_j(n)), \quad (3.9)$$

O algoritmo de retropropagação aplica uma correção $\Delta w_{ji}(n)$ ao peso sináptico $w_{ji}(n)$, que é proporcional a derivada parcial cuja expressão é:

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = \frac{\partial \varepsilon(n)}{\partial e_j(n)} \cdot \frac{\partial e_j(n)}{\partial y_j(n)} \cdot \frac{\partial y_j(n)}{\partial v_j(n)} \cdot \frac{\partial v_j(n)}{\partial w_{ji}(n)}, \quad (3.10)$$

Após o cálculo das derivadas parciais da Eq. 3.10 obtêm-se a expressão a seguir:

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = -e_j(n) \varphi'_j(v_j(n)) y_j(n), \quad (3.11)$$

A correção $\Delta w_{ji}(n)$ aplicada a $w_{ji}(n)$ é definida pela *regra delta*:

$$\Delta w_{ji}(n) = -\eta \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)}, \quad (3.12)$$

O sinal negativo indica a descida do gradiente no espaço de pesos, ou seja, busca uma direção para a mudança de peso que reduza o valor de $\varepsilon(n)$.

Após o desenvolvimento do algoritmo a atualização dos pesos pode ser expressa da seguinte por:

$$w_{ji}(n + 1) = w_{ji}(n) - \eta \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)}. \quad (3.13)$$

3.2 Sistemas *Neuro - Fuzzy*

A computação *neuro - fuzzy* é uma integração entre redes neurais artificiais e sistemas de inferência fuzzy. Ela incorpora as vantagens das redes neurais artificiais como paralelismo maciço, robustez e aprendizagem de dados em um sistema com a lógica fuzzy que possibilita a modelagem da imprecisão e conhecimento qualitativo bem como a propagação da incerteza (AFONSO MARQUES, 2014).

3.2.1 Lógica Fuzzy

A lógica *fuzzy*, ou lógica nebulosa é caracterizada pela semelhança a forma como os humanos tendem a raciocinar devido a não assumir conceitos absolutistas como “completamente verdadeiro” ou “completamente falso”. A lógica *fuzzy* trata com graus de pertinência, que varia de 0 a 1, sendo 1 o maior grau de verdade de um elemento pertencer ao conjunto, e 0 representando o menor grau de verdade (KOSKO, 1997), ou seja, uma premissa pode assumir uma proposição parcialmente verdadeira ou parcialmente falsa.

A Figura 3.5 representa um exemplo bastante difundido nas literaturas sobre lógica *fuzzy* é o exemplo da temperatura térmica. Os gráficos que constam na Figura 3.5 representam quatro variáveis térmicas: frio, conforto, relativamente quente e quente.

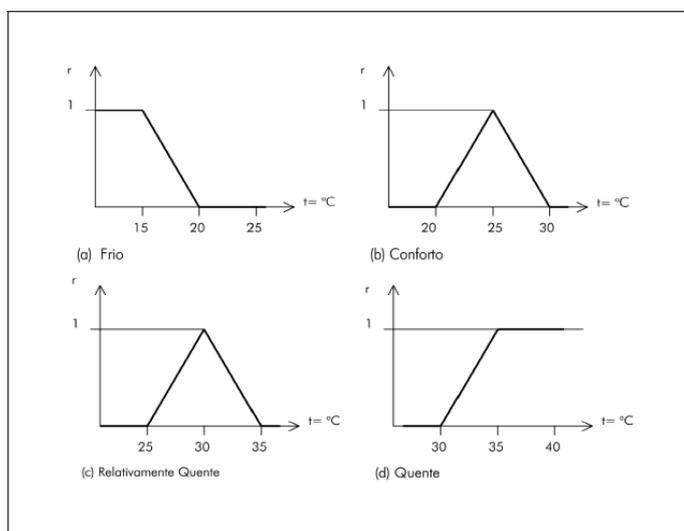


Figura 3.5 – Exemplo de funções de pertinência.

É comum a representação acima através da Figura 3.6, observa-se com mais nitidez o limite difuso (nebuloso) entre as variáveis.

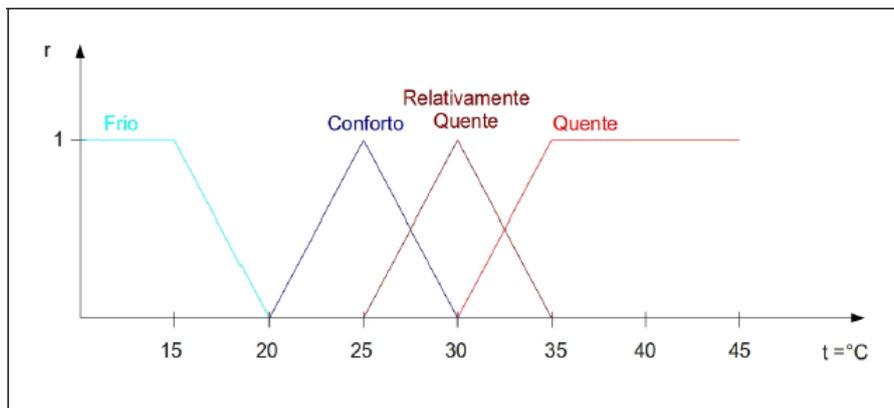


Figura 3.6 – Exemplo de funções de pertinência.

Os componentes essenciais do sistema *fuzzy* estão representando no fluxograma da Figura 3.7 e serão descritos a seguir:

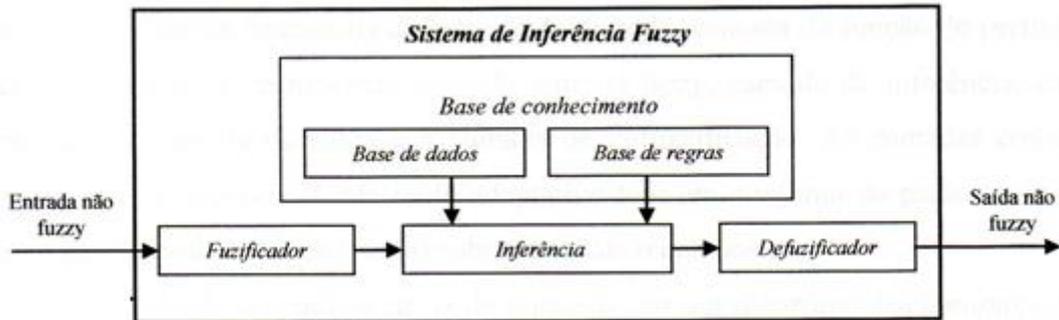


Figura 3.7 – Fluxograma conceitual do sistema *fuzzy*.

- *Fuzzificador*: aplica a cada entrada (valor real) a função de pertinência e a saída será um valor entre 0 e 1. cada função de pertinência para uma dada variável de entrada é conhecida como uma variável linguística.
- *Base de Regras*: Consiste de um conjunto de declarações linguísticas na forma de SE – ENTÃO que são criadas pelo especialista ou apropriadas da base de dados.
- *Inferência*: é um sistema que mapeia conjuntos *fuzzy* de entradas em conjunto *fuzzy* de saída, determinando como as regras são ativadas e combinadas. Os modelos de inferência mais conhecidos são: Modelo de Mamdani e Modelo de Takagi – Sugeno (KOSKO, 1997).
- *Defuzzificador*: é a etapa em que os os valores *fuzzy* são convertidos me valores reais tendo assim um conjunto de saída matematicamente definido.

3.2.2 Sistema de Inferência Mamdani

O modelo de inferência Mamdani foi um dos primeiros sistemas constituído utilizando a teoria de conjuntos *fuzzy*, sendo proposto em 1975 por Ebrahim Mamdani (REZENDE, 2005). A regra de semântica tradicionalmente utilizada para o processamento de inferências com o modelo de Mamdani é chamada de inferência Máx-Mín. Utilizando as operações de união e de interseção entre conjuntos da mesma forma de Zadeh (REZENDE, 2005).

As regras de produção em um modelo de Mamdani possuem relações *fuzzy* tanto em seus antecedentes como em seus consequentes.

Seja um sistema *fuzzy* composto de n regras, com uma das regras representada abaixo: Se $x_1 = A_1$ e $x_2 = A_2$ e...e $x_p = A_p$ então $y_1 = B_i$, em que x_i são as entradas do sistema, $A_1...A_j$ são as variáveis linguísticas definidas pelas funções de pertinência de entrada, y_1 é a saída e B_i são as variáveis linguísticas definidas pelas funções de pertinência da saída.

O processo de inferência Mamdani pode ser dividido em cinco etapas:

I. Fuzzificação das Entradas

Nesta etapa toma-se o valor de cada variável de entrada e determina-se o seu grau de pertinência para cada uma das regras, ou seja:

$$\mu_{A_1}^k(x_1), \mu_{A_2}^k(x_2), \dots, \mu_{A_j}^k \quad (3.14)$$

em que $k = 1, \dots, n$.

II. Aplicação do Operador *fuzzy*

Com as entradas fuzzificadas sabe-se qual o grau que cada parte do antecedente satisfaz cada regra. Precisa-se gerar o coeficiente de disparo de cada regra $D^{(k)}$, para isso aplica-se o operador fuzzy presente no antecedente, por exemplo, o operador “e”.

Para aplicar o operador, o sistema Mamdani utiliza a função “min”, conforme a equação 3.15.

$$D^{(k)} = \min[\mu_{A_1}^k(x_1), \mu_{A_2}^k(x_2), \dots, \mu_{A_j}^k(x_j)], \quad (3.15)$$

Todas as regras com coeficiente de disparo diferente de zero, regras que disparam, vão contribuir para o cálculo da saída correspondente do sistema de inferência.

III. Aplicação do método de implicação

O método de implicação é definido como a modelagem do conseqüente com base no coeficiente de disparo. A implicação se dá em todas as regras. O modelo de Mamdani utiliza a função *min* que trunca a saída do conjunto *fuzzy*.

$$s^{(k)} = \min[D^k, \mu_{B_i}(y)], \quad (3.16)$$

IV. Agregação das Saídas

Ao realizar o processo de implicação cada regra gera uma função de pertinência truncada para a saída da regra. Como o sistema possui n regras deve-se ter n funções de pertinências truncadas que irão gerar a função de saída. Para isso agregam-se todos os gráficos de cada uma das funções. No modelo Mamdani utiliza-se a função “máx”.

$$\mu_{B'} = \max[s^{(k)}]. \quad (3.17)$$

V. Defuzzificação

Nesta etapa é realizado o processo de conversão *fuzzy* – escalar em que serão convertidas as informações qualitativas em uma informação quantitativa. Os métodos mais utilizados para realizar a conversão *fuzzy* – escalar são: o método do centro de massa e o método da média dos máximos.

3.2.3 Sistema de Inferência Takagi – Sugeno

Na década de 1980 um novo modelo de inferência *fuzzy* foi proposto, chamado de modelo Sugeno ou basicamente TSK este modelo conseguia respostas satisfatórias para problemas que fossem representados coerentemente apenas pelas suas relações de entrada e saída.

Em contraposição ao modelo Mamdani, o modelo de inferência do tipo TSK não utiliza funções de pertinência no consequente. As relações de saída são compostas de equações paramétricas que relacionam as entradas com as saídas.

O processo de inferência TSK será descrito a seguir:

O processo de inferência do modelo TSK é similar ao modelo de inferência Mamdani, com algumas ressalvas. O modelo TSK não apresenta a fase de defuzzificação e na segunda etapa, o cálculo da função de disparo em geral não é o operador “min”.

A saída do modelo TSK é calculada como a média ponderada das saídas de cada uma das regras que compõem o sistema, em que os pesos são os coeficientes de disparo.

Podemos definir o coeficiente de disparo de cada uma das regras como sendo:

$$D^{(k)} = T[\mu_{A_1}^k(x_1), \mu_{A_2}^k(x_2), \dots, \mu_{A_j}^k(x_j)], \quad (3.18)$$

em que:

$k = 1, \dots, n$.

A saída do sistema TSK se expressa da seguinte forma:

$$z = \frac{\sum_{k=1}^n D^{(k)} \cdot \phi(x_1, x_2, \dots, x_j)}{\sum_{k=1}^n D^{(k)}}. \quad (3.19)$$

A eficiência do modelo de TSK está diretamente ligada à escolha dos parâmetros da função paramétrica de saída, normalmente os índices desta função são estimados seguindo algum índice de desempenho definido pelo usuário. A minimização do erro quadrático entre a saída do modelo de Sugeno e os dados de saída disponíveis é normalmente utilizada como medida de desempenho.

3.2.4 ANFIS

O ANFIS (*Adaptive Neuro Fuzzy Inference System*) é um modelo de inferência neuro - fuzzy em que adquire o conhecimento de dados usando algoritmos operacionais típicos de redes neurais (SDAO et al., 2013). Das redes neurais, utiliza a capacidade de aprendizagem, enquanto que da lógica *fuzzy* se utiliza da capacidade de interpretação.

Como o modelo ANFIS utiliza apenas funções deriváveis, torna-se viável a utilização de uma combinação entre o algoritmo *backpropagation* e o método de estimação de mínimos quadrados.

De acordo com a Figura 3.8, os passos que levam o ANFIS a uma adaptação serão descritos a seguir (JANG, 1993):

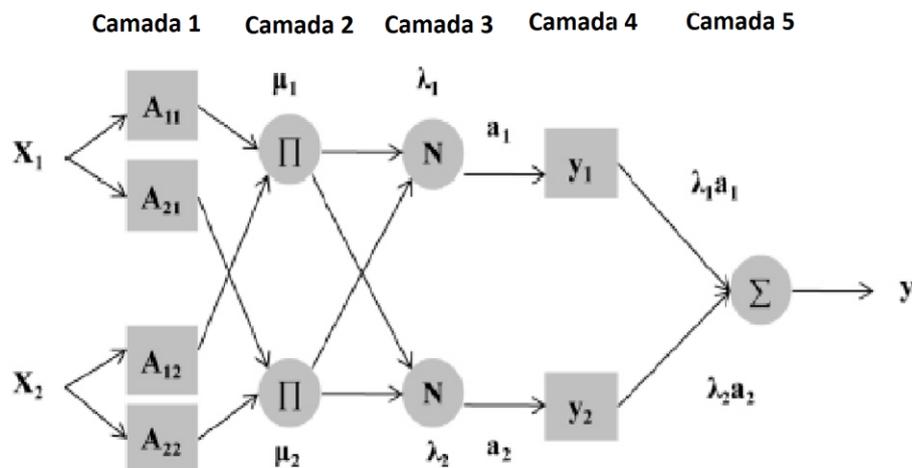


Figura 3.8 – Arquitetura da rede neuro - fuzzy ANFIS.
Fonte: (SDAO et al., 2013)

Camada 1:

Na primeira camada, cada unidade (A_{11} , A_{12} , A_{21} , A_{22}) armazena os parâmetros para definir uma função de pertinência que representa um termo linguístico como sendo:

$$O_i^1 = \mu_{A_i}(x), \quad (3.20)$$

em que x representa a entrada do nó i , A_i é a classificação linguística associada com a função do nó e O_i^1 é a saída do nó i da camada 1.

As funções de pertinência podem ser consideradas com funções sino (bell – shaped), cuja expressão é:

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\left(\frac{x_i - c_i}{a_i} \right)^2 \right]^{b_i}}, \quad (3.21)$$

em que, a_i , b_i e c_i são os parâmetros de ajuste.

A escolha da função de pertinência fica a critério do pesquisador. As mais conhecidas são: triangular, trapezoidal, gaussiana e sino (bell – shaped). Das quatro funções de pertinência que foram apresentadas as mais utilizadas são a triangular e a trapezoidal, porém possuem derivadas descontínuas nos pontos especificados por seus parâmetros, logo impossibilitando a utilização do método do gradiente para otimizar seus parâmetros. Logo, as funções de pertinência gaussiana e sino por apresentarem as características de serem não lineares e derivadas contínuas tornam-se atrativas para especificar conjuntos fuzzy.

Camada 2:

Os nós desta camada são conhecidos como nós de regras, cada nó calcula o grau de ativação de cada uma das regras, ou seja, gera-se o disparo de cada regra:

$$w_i = \mu_{A_{i1}}(x_1) \cdot \mu_{A_{i2}}(x_2), \quad i = 1, 2. \quad (3.22)$$

Camada 3:

A camada de normalização calcula o grau de desempenho relativo das i – ésimas regras para o somatório dos níveis de ativação dos nós, isto é:

$$\bar{w}_i = \frac{w_i}{w_1 + w_2 + \dots + w_R}, \quad i = 1, 2. \quad (3.23)$$

Camada 4:

Nesta camada é calculado o produto de um nível de ativação normalizado da camada 3 e uma função f_i linear das variáveis de entrada.

$$O_i^4 = \bar{w}_i \cdot f_i = \bar{w}_i (p_i x + q_i y + r_i), \quad (3.24)$$

em que $\{p_i, q_i, r_i\}$ é o conjunto de parâmetros do nó i .

Camada 5:

A camada 5 agrega os consequentes e produz uma saída *fuzzy*. O nodo simples nessa camada é um nodo fixo uma vez que calcula a média ponderada do sinal de saída da camada de saída (O) como (GIEBEL et al., 2003):

$$O_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}. \quad (3.25)$$

A Figura 3.9 representa um fluxograma conceitual do ANFIS.

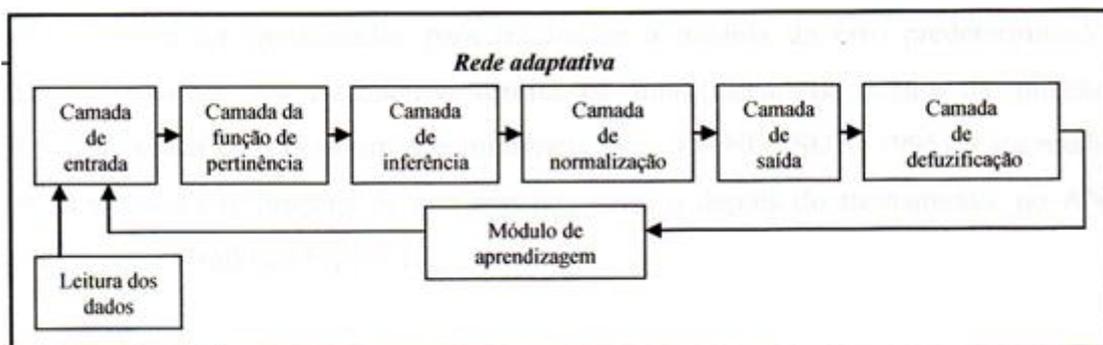


Figura 3.9 – Fluxograma conceitual do ANFIS
Fonte: (AFONSO MARQUES, A. C., 2014)

3.3 Echo State Networks

As *Echo State Networks* (ESNs) representam um dos métodos pioneiros de *Reservoir Computing* e baseiam na observação que uma Rede Neural Recorrente aleatória possui certas propriedades algébricas e que o treinamento apenas da camada de saída (*readout*) é frequentemente suficiente para alcançar excelentes resultados em aplicações práticas (FERREIRA, 2011). As ESNs caracterizam-se pela presença de ao menos um laço de realimentação em seus neurônios.

Uma das principais diferenças entre a abordagem ESN e outros métodos de RNR é fato da ESN permitir a utilização de um número elevado de neurônios, da ordem de 50 a 1000 neurônios, enquanto as RNR usam basicamente de 5 a 30 neurônios. Outra diferença importante é que em uma rede ESN somente as conexões do reservatório para saída são treinadas, permitindo que o treinamento torne-se uma tarefa simples de regressão linear.

Uma ESN é composta de camada intermediária, não treinada, denominada de *reservoir* e os estados resultantes $x(n)$ são denominados de *echo states* do histórico das entradas. A Figura 3.10 representa a estrutura de uma rede ESN.

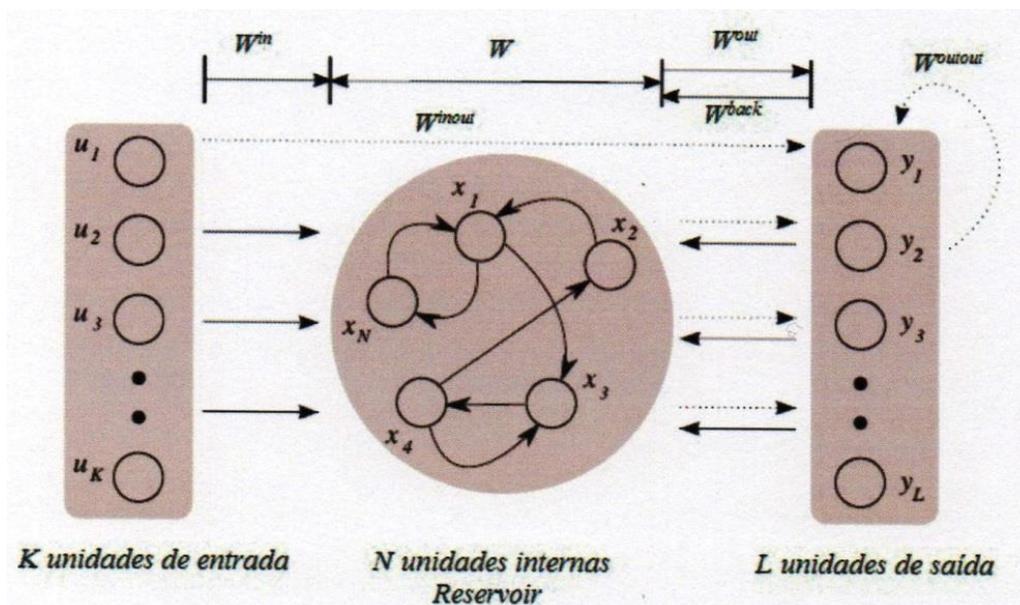


Figura 3.10 – Estrutura de uma rede ESN
Fonte: (FERREIRA, A. A., 2011)

As funções de transferência mais comuns utilizadas nas ESNs são as do tipo sigmoide simples, ou seja, sigmoide logística ou tangente hiperbólica.

A equação geral de atualização dos estados pode ser expressa da seguinte forma:

$$x(n + 1) = f(W^{in}u(n + 1) + Wx(n) + W^{back}y(n) + W^{bias}), \quad (3.26)$$

O treinamento dos neurônios da saída (*readout*) se dá de acordo com a seguinte expressão:

$$y(n + 1) = f^{out}((W^{inout}u(n + 1) + W^{out}x(n) + W^{outout}y(n) + W^{biasout}), \quad (3.27)$$

Apenas as conexões direcionadas para a camada de saída são treinadas.

Caso seja adicionado um parâmetro α (*leak rate*), aos neurônios da função de ativação, a equação 3.26 passa a ser representada da seguinte forma:

$$x(n + 1) = f((1 - \alpha)x(n) + \alpha(W^{in}u(n + 1) + Wx(n) + W^{back}y(n) + W^{bias}). \quad (3.28)$$

A adição deste parâmetro é geralmente chamada de *leaky integrator neurons*. A inserção deste parâmetro de forma coerente pode efetivamente ajustar a dinâmica o ESN para que esta seja ajustada para coincidir com a escala de tempo da entrada, possibilitando ao sistema um melhor desempenho (FERREIRA, 2011).

CAPÍTULO 4

4. INDICADORES DE DESEMPENHO DA PREVISÃO

4.1 Série Temporal

Uma série temporal é uma sequência de dados numéricos no qual cada item é associado há um instante particular no tempo (MADDALA, 2003). Uma série temporal pode apresentar variáveis contínuas ou discretas, nesta dissertação as séries temporais são discretas e com valores igualmente espaçados no tempo, com intervalo horário.

A variável aleatória X em certo instante t é representada por X_t , e a série temporal a qual esta variável se insere é representada por X_1, X_2, \dots, X_N , em que N é o tamanho extraído da série.

A previsão de uma série temporal é simplesmente o estabelecimento dos valores futuros da série. Uma previsão é uma estimativa quantitativa (ou conjunto de estimativas) acerca da verossimilhança de eventos futuros baseados na informação atual e passada. Os modelos de previsão de séries temporais propostos nesta dissertação são multivariados, ou seja, são fundamentados na análise das observações de várias séries de interesse para a especificação de algum modelo que descreva a série de previsão de vento. O horizonte de previsão é o comprimento de tempo, contado a partir de uma origem especificada, chamada origem das previsões, no sentido do futuro, para o qual as previsões devem ser determinadas. O horizonte de previsão irá variar de acordo com o propósito ou uso final das previsões. Denomina-se o número de intervalos de tempo (períodos) para frente, a partir da origem das previsões, como o número de passos de uma previsão (GOUVEIA, 2011).

4.2 Coeficiente de Correlação e Autocorrelação

Os coeficientes de correlação e autocorrelação podem ser interpretados como a relação existente entre duas variáveis (BISQUEIRA et al., 2004). As equações 4.1 e 4.2 representam os coeficientes correlação e autocorrelação, respectivamente.

$$r_i = \frac{\sum_{i=1}^N (X(i) - \bar{X}).(Y(i) - \bar{Y})}{\left(\sum_{t=1}^N (X(i) - \bar{X})^2\right). \left(\sum_{t=1}^N (Y(i) - \bar{Y})^2\right)^{1/2}} \quad (4.1)$$

$$\rho_i = \frac{\sum_{i=1}^{N-t} (Y(i) - \bar{Y}).(Y(t+i) - \bar{Y})}{\sum_{t=1}^N (Y(i) - \bar{Y})^2} \quad (4.2)$$

A interpretação relacionada aos coeficientes de autocorrelação e correlação está descrita na Tabela 4.1. É importante frisar que os coeficientes, por definição, podem assumir valores no intervalo de $[-1,1]$ e que para valores negativos a interpretação é similar.

Tabela 4.1 – Interpretação do coeficiente de correlação e autocorrelação.

Coefficiente	Interpretação
$ r = 1$	Correlação Perfeita
$0,80 < r < 1$	Muito Alta
$0,60 < r < 0,80$	Alta
$0,40 < r < 0,60$	Moderada
$0,20 < r < 0,40$	Baixa
$0 < r < 0,20$	Muito Baixa
$ r = 0$	Nula

Fonte: (BISQUEIRA et al., 2004)

A partir destes valores espera-se poder inferir a dependência que os dados da série têm entre si e com outras séries, as quais ajudam a explicar a grandeza de interesse, o que facilitará a determinação da ordem de regressão dos dados usados como entradas dos modelos de previsão (OLIVEIRA, 2005).

4.3 Comparação com o Método da Persistência

O modelo da *persistência* é um dos métodos mais simples utilizado para prever a velocidade média do vento. Portanto, só é vantajoso desenvolver e implementar uma ferramenta avançada de previsão de previsão dos ventos se ela for capaz de superar os modelos de referência, ou seja, se a ferramenta fornecer resultados melhores do que aqueles obtidos com os modelos de referência (MADSEN et al., 2004). Provavelmente, o modelo de referência mais comumente utilizado na previsão de energia eólica ou no campo meteorológico é o Modelo da Persistência. Este modelo simples assume que a estimação no instante tempo $t + k$ é igual ao último valor medido (em t), ou seja,

$$\hat{v}_{pers}(t + k|t) = v(t). \quad (4.3)$$

No caso da série temporal da velocidade média dos ventos, apesar de sua aparente simplicidade, este modelo pode ser difícil de ser batido para os primeiros passos de previsão (de 0 a 6 horas), pois a escala de mudanças na atmosfera é lenta (MADSEN et al., 2004).

4.4 Comparação pelos Erros de Previsão

No campo de previsões de séries temporais em geral, o erro é definido como a diferença entre os valores medido e previsto. Para cada passo, o erro da previsão é expresso do seguinte modo:

$$e_v(t + k|t) = v(t + k|t) - \bar{v}(t + k|t), \quad (4.4)$$

Qualquer erro de previsão pode ser decomposto como a soma de duas parcelas, sendo uma delas denominada erro sistemático (μ_e), e a outra, erro aleatório (ε_e) (MADSEN et al., 2004).

$$e = \mu_e + \varepsilon_e, \quad (4.5)$$

em que, μ_e é um valor constante, enquanto que ε_e tem característica aleatória cuja média é zero. O erro sistemático é igual ao valor médio do erro de previsão sobre todo o período de avaliação e é calculado para cada passo de previsão de acordo com a seguinte equação:

$$\hat{\mu}_e(k) = \overline{e(k)} = \frac{1}{N} \sum_{t=1}^N e(t + k|t), \quad (4.6)$$

Para o desenvolvimento deste texto, três tipos básicos de erros foram utilizados para medir o desempenho dos modelos de previsão, que são os seguintes: o erro absoluto médio (*Mean Absolut Error – MAE*), o erro absoluto percentual médio (*Mean Absolut Percentage Error – MAPE*) e o erro quadrático médio (*Mean Squared Error – MSE*). As equações utilizadas para calculá-los são expressas a seguir:

$$MAE_v(k) = \frac{1}{N} \sum_{t=1}^N |e_v(t + k|t)|, \quad (4.7)$$

$$MAPE_v(k) = \frac{100}{N} \sum_{t=1}^N \frac{|e_v(t + k|t)|}{v(t + k)}, \quad (4.8)$$

$$MSE_v(k) = \frac{1}{N} \sum_{t=1}^N e_v(t + k|t)^2, \quad (4.9)$$

4.5 Critérios para Comparação dos Modelos

Ao propor um novo modelo de previsão, é muito importante destacar e quantificar os ganhos obtidos em relação aos modelos de referência, este ganho, indica uma melhoria em relação ao modelo de referência considerado (MADSEN et al., 2004). A fórmula utilizada para calcular estes ganhos percentuais para cada passo de previsão é a seguinte:

$$G_{ref,CA}(k) = 100 \left(\frac{CA_{ref}(k) - CA(k)}{CA_{ref}(k)} \right), \quad (4.10)$$

em que:

$CA_{ref}(k)$ – é o critério de avaliação do modelo de referência;

$CA(k)$ – é o critério de avaliação do modelo proposto.

O critério de avaliação pode ser o MAE, MAPE ou MSE. Observe que, ao calcular o ganho, o mesmo critério deve ser utilizado para se avaliar os dois modelos.

CAPÍTULO 5

5. ELABORAÇÃO DOS MODELOS DE PREVISÃO DE VENTO

Neste capítulo se descreve a metodologia utilizada no desenvolvimento dos modelos de previsão de velocidade de vento. Apresenta-se onde foram coletados os dados utilizados nos modelos de previsão e as características mais relevantes dos experimentos realizados.

5.1 Bases de Dados

5.1.1 Séries Históricas do INMET

Uma parcela das séries dispostas nesta dissertação é oriunda do banco de dados do Instituto Nacional de Meteorologia (INMET), no endereço (<http://www.inmet.gov.br>). Foram utilizadas variáveis do INMET para a elaboração dos modelos de previsão de vento, abaixo listadas:

- Velocidade instantânea do vento;
- Temperatura instantânea do ar;
- Umidade relativa Instantânea do ar;
- Radiação solar.

Cada grupo de variáveis correspondente a cada uma das cinco estações meteorológicas automáticas localizadas nos estados de Pernambuco e Rio Grande do Norte.

Em Pernambuco, as estações meteorológicas estão localizadas nas cidades de Petrolina e Ouricuri; no estado do Rio Grande do Norte as estações meteorológicas estão localizadas nas cidades de Natal, Macau e Mossoró.

Uma estação meteorológica é composta principalmente de um sistema de coleta de dados, através de sensores que medem as variáveis ambientais; um sistema de controle e armazenamento local (*datalogger*); um sistema de energia; e um sistema de comunicação (INMET, 2011).

A estação meteorológica automática coleta, de minuto em minuto, as informações meteorológicas do local em que está inserida, integraliza os dados para o período de uma hora e disponibiliza-os para serem transmitidos para a sede do INMET.

Os dados coletados pelas estações meteorológicas automáticas são coletados a uma altura de 10 m a partir do solo e são disponibilizados os dados referentes há 90 dias anteriores ao dia em que o usuário consultou os dados.

5.1.2 Séries Históricas de Marés e Fases da Lua

As séries de previsão de marés são disponibilizadas pela Diretoria de Hidrografia e Navegação (DHN) da Marinha e podem ser coletados a partir do endereço (<http://www.mar.mil.br/dhn/chm/box-previsao-mare/tabuas/>). Nela, os valores das previsões das horas e das alturas máximas e mínimas alcançadas pelas águas do mar são informados em base diária para o ano inteiro. Concomitantes aos dados de marés são disponibilizadas as fases da lua em séries diárias, em que as utilizamos para criação dos modelos de previsão de vento. Foram utilizadas nesta dissertação duas séries de previsão de marés localizadas no Rio Grande do Norte; uma para o porto de Natal e outra para o porto de Macau.

5.2 Localização dos Postos de Medição

5.2.1 Localização das estações automáticas do INMET

Foram escolhidas cinco estações meteorológicas automáticas para aquisição de dados:

- **Petrolina** – Município pertencente ao estado de Pernambuco, sua estação meteorológica está localizada na latitude 9° 23' 18" sul e a uma longitude 40° 31' 24" oeste. Sua altitude é de 373 metros acima do nível do mar.
- **Ouricuri** – Município pertencente ao estado de Pernambuco, a estação meteorológica está localizada na latitude 7° 53' 5" sul e a uma longitude 40° 6' 3" oeste. Sua altitude é de 461 metros acima do nível do mar.
- **Natal** – Município pertencente ao estado do Rio Grande do Norte, a estação meteorológica está localizada na latitude 5° 50' 13" sul e a uma longitude 35° 12' 28" oeste. Sua altitude é de 47 metros acima do nível do mar.

- **Macau** – Município pertencente ao estado do Rio Grande do Norte, a estação meteorológica está localizada na latitude 5° 9' 3" sul e a uma longitude 36° 34' 23" oeste. Sua altitude é de 17 metros acima do nível do mar.
- **Mossoró** – Município pertencente ao estado do Rio Grande do Norte, a estação meteorológica está localizada na latitude 4° 54' 14" sul e a uma longitude 37° 22' 1" oeste. Sua altitude é de 29 metros acima do nível do mar.

5.2.2 Localização das estações automáticas do DHN

- **Porto de Macau** – A previsão de marés para o porto de Macau é relativa ao local com coordenadas geográficas de latitude 05° 06' 0" sul e longitude 36° 40' 4" oeste.
- **Porto Natal** – A Previsão de marés para o porto de Natal é relativa para o local coordenadas geográficas de latitude 05° 46' 7" e longitude 35° 12' 5".

5.3 Estatística Descritiva

O objetivo desta seção é resumir as principais características extraídas das séries horárias médias por meio de tabelas e gráficos. Esta análise possibilita uma visão geral dos dados e uma compreensão mais profunda dos mesmos.

5.3.1 Séries de Velocidades Médias Horárias

Para cada uma das estações automáticas, os dados foram armazenados em um vetor, de modo a facilitar a análise e manipulação dos mesmos. Estes dados de velocidade média horária foram filtrados de modo a serem retirados dados incompatíveis com os padrões observados, oriundos de falhas ocorridas nas estações meteorológicas automáticas. Na Tabela 5.1 constam o período e o número de padrões de velocidade utilizados para o desenvolvimento dos modelos de previsão de cada estação meteorológica automática:

Tabela 5.1 – Base de dados de vento utilizada para o desenvolvimento dos modelos de previsão.

Estação	Período	Total de Padrões
PETROLINA	Agosto de 2010 até Maio de 2014	30861
MACAU	Março de 2007 até Maio de 2014	56739
NATAL	Outubro de 2007 até Maio de 2014	44965
MOSSORÓ	Maio de 2007 até Maio de 2014	54878
OURICURI	Agosto de 2010 até Maio de 2014	28928

A Tabela 5.2 apresenta os valores máximos, mínimos, médios e os desvios padrões das séries de velocidades das estações meteorológicas de PETROLINA, MACAU, NATAL, MOSSORÓ e OURICURI, respectivamente.

Tabela 5.2 – Estatísticas da séries de velocidade de Petrolina, Macau, Natal, Mossoró e Ouricuri.

<i>Estação</i>	<i>Mínima [m/s]</i>	<i>Máxima [m/s]</i>	<i>Média [m/s]</i>	<i>Desvio Padrão [m/s]</i>
PETROLINA	0,00	9,80	3,54	1,25
MACAU	0,10	13,60	4,69	2,05
NATAL	0,00	10,50	4,49	1,57
MOSSORÓ	0,10	9,40	3,54	1,87
OURICURI	0,10	11,60	2,99	1,44

Na Figura 5.1 são os histograma da frequência de distribuição da velocidade do vento para as cinco estações apresentadas na Tabela 5.1.

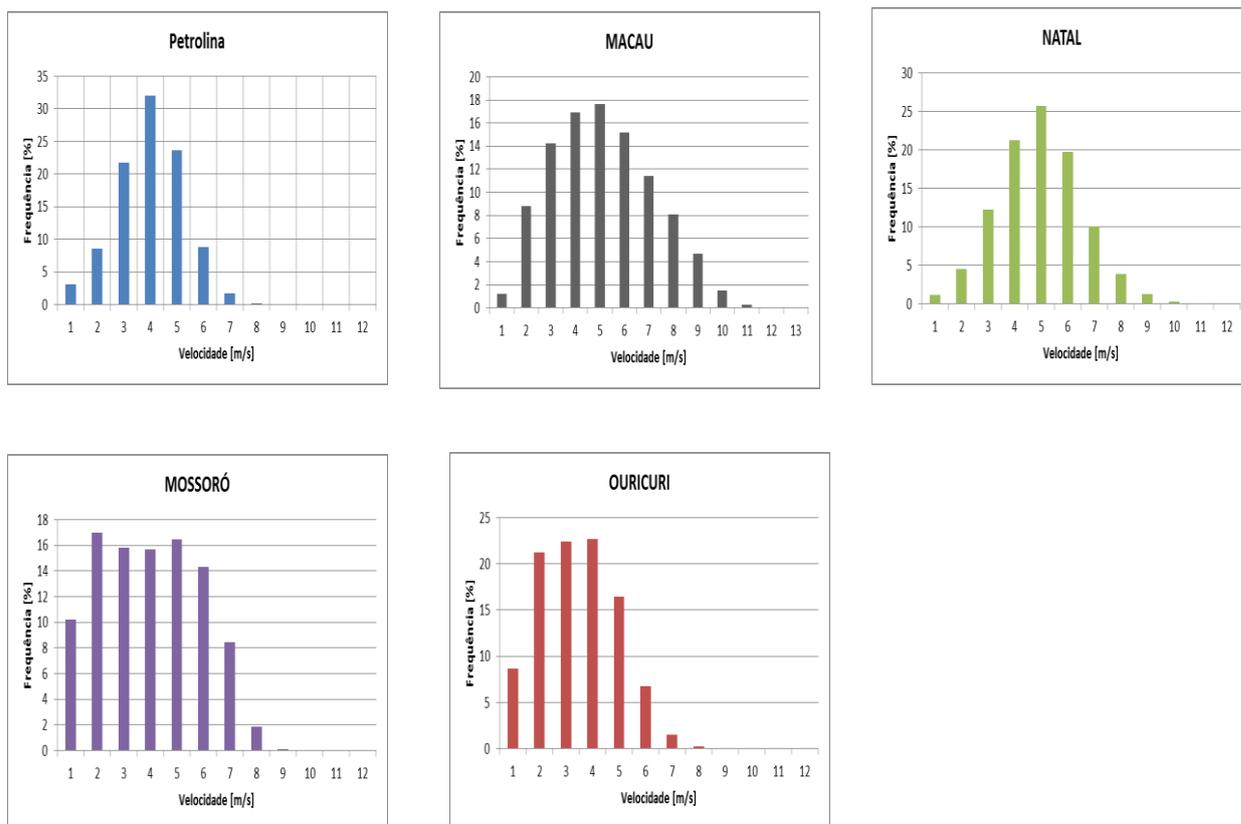


Figura 5.1– Histograma da velocidade do vento de Petrolina, Macau, Natal, Mossoró e Ouricuri.

A partir da análise dos histogramas, podemos perceber que para Petrolina, Macau e Natal, existe uma pequena porcentagem de velocidades menores ou iguais a 2 m/s, 11,61 %, 10,01 % e 5,68 %, respectivamente. Porém, para Mossoró e Ouricuri, 27,19 % e 29,95 %, respectivamente, estão na faixa menor ou igual a 2 m/s. É importante perceber que para os cinco sítios listados a maior parte das velocidades concentram-se em valores menores ou iguais a 6m/s; 98,29% para Ouricuri, 84,54 % para Natal, 97,96 % para Petrolina, 89,49 % para Mossoró e 73,97 % para Macau, dos dados para cada sítio.

A Figura 5.2 representa a sazonalidade de toda série temporal de velocidade de vento para o sítio de Petrolina e Ouricuri. Ela é obtida calculando-se a média aritmética mensal das velocidades de vento. A análise da sazonalidade é de grande importância para geração eólica na região nordeste, devido ao regime de complementaridade observado entre a vazão do Rio São Francisco e a Velocidade do vento, ou seja, no período seco a geração eólica poderia ser uma alternativa a redução de vazão no Rio São Francisco e no período molhado a escassez de vento poderia ser mitigada através da geração hidrelétrica.

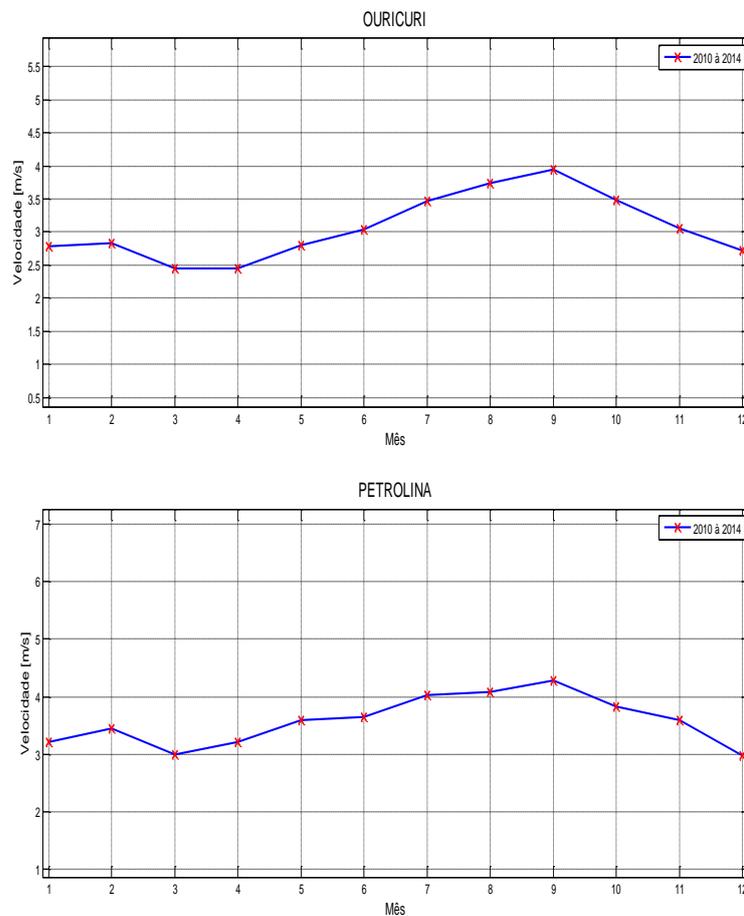


Figura 5.2 – Comportamento sazonal da velocidade média mensal do vento para Ouricuri e Petrolina.

As autocorrelações podem ser analisadas a partir do Apêndice A.1. Estas medidas serão a base para criação dos modelos de previsão de velocidade de vento. O passo máximo para o cálculo do coeficiente de autocorrelação e correlação foi de 84 horas. À medida que o número de passos aumenta, os coeficientes de autocorrelação e correlação diminuem, visto que os coeficientes decrescem com o aumento do tempo de regressão.

5.3.2 Séries de Temperaturas Médias Horárias

Diferentemente da velocidade do vento, a temperatura não sofre variações bruscas no seu valor para intervalos curtos de tempo. A Tabela 5.3 mostra os valores mínimos, máximos e a temperatura média para os cinco sítios analisado.

Tabela 5.3 – Estatísticas da séries de temperatura de Petrolina, Macau, Natal, Mossoró e Ouricuri.

<i>Estação</i>	<i>Mínima [°C]</i>	<i>Máxima [°C]</i>	<i>Média [°C]</i>	<i>Desvio Padrão [°C]</i>
PETROLINA	17,30	38,70	27,28	3,85
MACAU	19,40	37,60	27,55	2,82
NATAL	20,30	32,20	26,72	1,93
MOSSORÓ	16,00	35,50	27,15	3,07
OURICURI	15,20	37,90	26,50	3,88

A Figura 5.3 apresenta a distribuição de frequência da temperatura para Petrolina, Macau, Natal, Mossoró e Ouricuri. A partir da análise do histograma percebe-se um comportamento similar da temperatura para os cinco sítios. Para Petrolina, Macau, Natal, Mossoró e Ouricuri, existem uma pequena porcentagem de valores abaixo de 26°C, 7,79 %, 0,99 %, 1,33%, 3,12% e 11,99 %, respectivamente. Grande parte dos valores de temperatura está concentrada no intervalo entre 26 °C e 36 °C, 78,76 % para Petrolina, 92,67 % para Macau, 98,66 % para Natal, 89,89 % para Mossoró e 78,17 % para Ouricuri. Temperaturas a partir de 36 °C representa uma pequena porcentagem, 13,44 % para Petrolina, 6,34 % para Macau, menor que 0,01 para Natal, 6,98 % para Mossoró e 9,83 % para Ouricuri. Isso vem a ratificar a pequena amplitude térmica que essas cidades sofrem ao longo do ano.

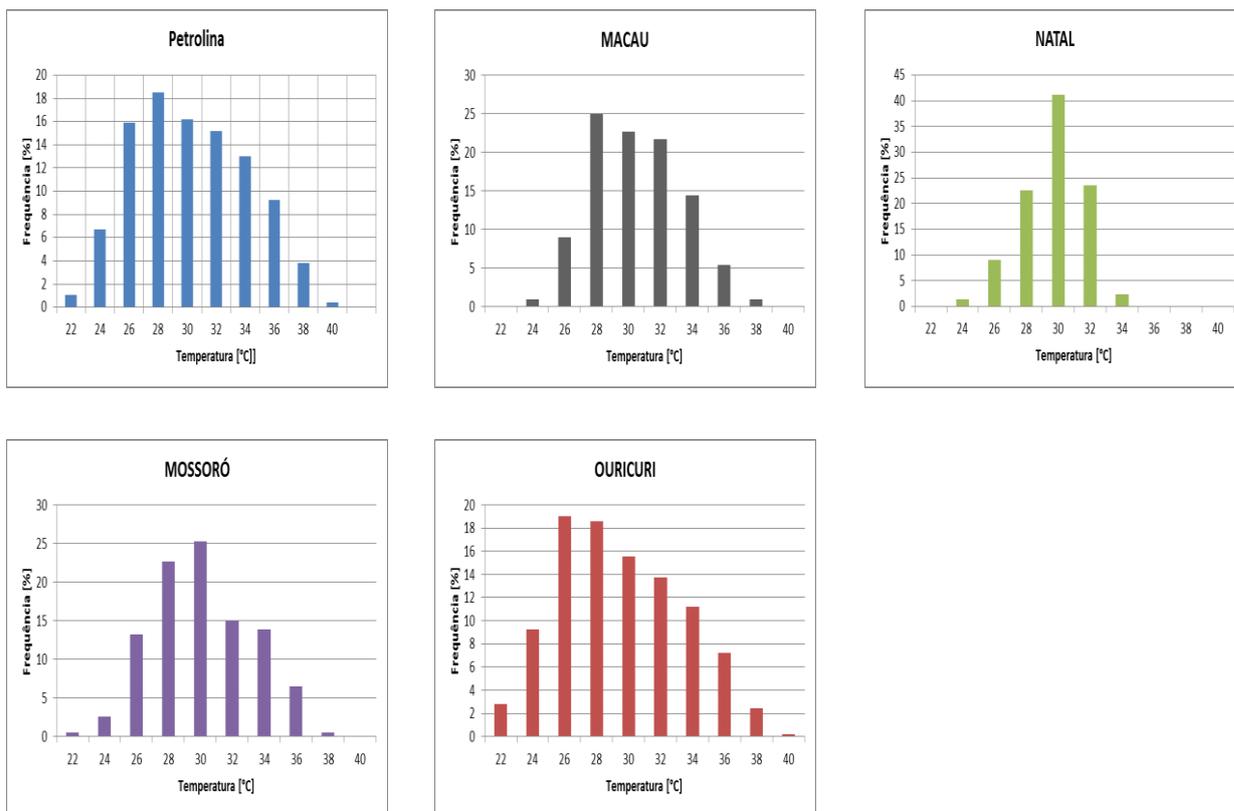


Figura 5.3 - Histograma da temperatura de Petrolina, Macau, Natal, Mossoró e Ouricuri.

5.3.3 Séries de Umidades Médias Horárias

A Tabela 5.4 mostra as características dos dados de umidade relativa do ar, percebe-se que para os sítios localizados no sertão de Pernambuco, Petrolina e Ouricuri, a média da umidade relativa do ar encontra-se por volta de 50 %, enquanto para os sítios localizados mais próximos a região litorânea, estes apresentaram valores médios de umidade relativa do ar superiores a 70 %.

Tabela 5.4 – Estatísticas das séries de umidade do ar para Petrolina, Macau, Natal, Mossoró e Ouricuri.

<i>Estação</i>	<i>Mínima [%]</i>	<i>Máxima [%]</i>	<i>Média [%]</i>	<i>Desvio Padrão [%]</i>
PETROLINA	11,00	92,00	51,80	16,58
MACAU	28,00	100,00	70,34	17,13
NATAL	45,00	97,00	74,70	8,55
MOSSORÓ	23,00	100,00	70,91	15,37
OURICURI	9,00	96,00	56,85	19,74

A Figura 5.4 representa a distribuição da umidade relativa do ar para os cinco sítios pesquisados. Para Petrolina e Ouricuri a porcentagem da umidade relativa do ar entre 30 % e 70 % é de 73,43 % e 60,91 % dos dados, respectivamente; porém, Para Natal, Macau e Mossoró a porcentagem é de 31,85 %, 47,24 % e 44,44 %. Para umidade do ar acima de 70 % Natal, Macau e Mossoró apresentam valores de 68,15 %, 52,08 % e 55,39%, respectivamente. Para porcentagens abaixo de 30 %, Petrolina aparece com 12,02 %, Ouricuri com 10,70 %. Natal, Macau e Mossoró destacam-se pelos baixíssimos valores de porcentagem abaixo de 30 %, 0 % para Natal, 0,68 % para Macau e 0,17 % para Mossoró. A baixa porcentagem de umidade relativa do ar, abaixo de 30 %, para as cidades de Natal, Macau e Mossoró se deve ao fato de que as cidades acima citadas estão próximas à região litorânea.

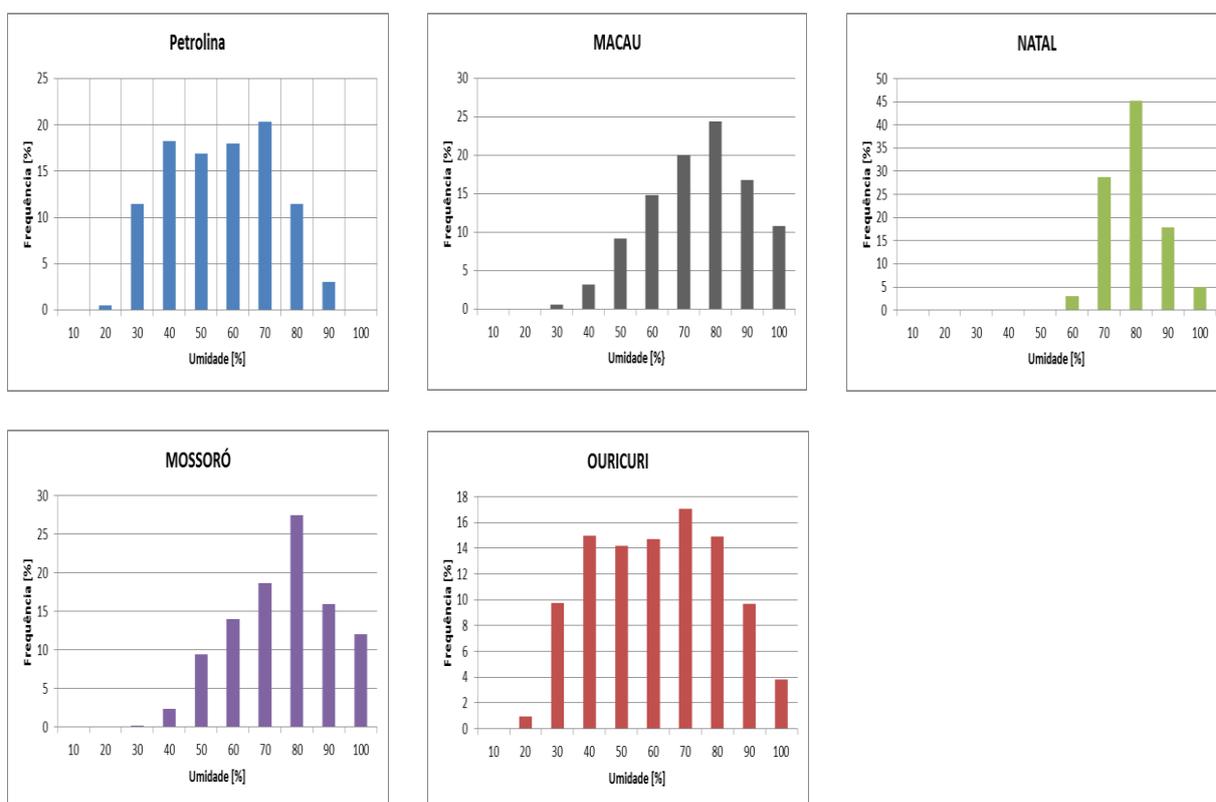


Figura 5.4 – Histograma da umidade relativa do ar para Petrolina, Macau, Natal, Mossoró e Ouricuri.

O **Apêndice A.3** mostra os gráficos de correlação entre a velocidade do vento e a umidade relativa do ar. A correlação entre as variáveis será de fundamental importância para avaliar as entradas dos modelos de previsão.

5.3.4 Séries de Radiação Solar Média Horária

De acordo com a Tabela 5.5 podemos perceber a variabilidade do nível de radiação solar ao longo de um ciclo de 24 horas devido ao movimento de rotação da Terra, esses extremos entre o máximo valor de radiação e o mínimo decorrem do período ensolarado e do período sem incidência solar (dia e noite).

Tabela 5.5 – Estatísticas das séries de radiação solar para Petrolina, Macau, Natal, Mossoró e Ouricuri.

<i>Estação</i>	<i>Mínima</i> [kJ/m ²]	<i>Máxima</i> [kJ/m ²]	<i>Média</i> [kJ/m ²]	<i>Desvio Padrão</i> [kJ/m ²]
PETROLINA	-3,54	4615,00	895,98	1224,30
MACAU	-7,02	4152,00	874,59	1151,54
NATAL	-4,30	4972,60	647,02	1231,19
MOSSORÓ	-7,02	4084,00	931,79	1206,44
OURICURI	-3,54	4073,00	858,96	1150,69

A radiação solar tem uma característica bem peculiar quando comparada com as outras variáveis devido ao seu ciclo diário. Durante o nascer, entardecer e a noite, quando há incidência solar é mínima ou nula, a radiação solar assume uma porcentagem alta de valores abaixo de 100 kJ/m², 63,09 % para Petrolina, 58,04 % para Macau, 77,61 % para Natal, 51,84 % para Mossoró e 58,72 % para Ouricuri. As radiações com valores acima de 1000 kJ/m², que correspondem aos horários em que há o máximo de incidência solar, correspondem para Petrolina, Macau, Natal, Mossoró e Ouricuri a 29,76 %, 34,91 %, 15,12%, 40,52 % e 34,12 %, respectivamente. Para valores entre 100 kJ/m² e 1000 kJ/m² as porcentagens são as seguintes: 29,75 % para Petrolina, 27,56 % para Macau, 9,48 % para Natal, 26,76 %.

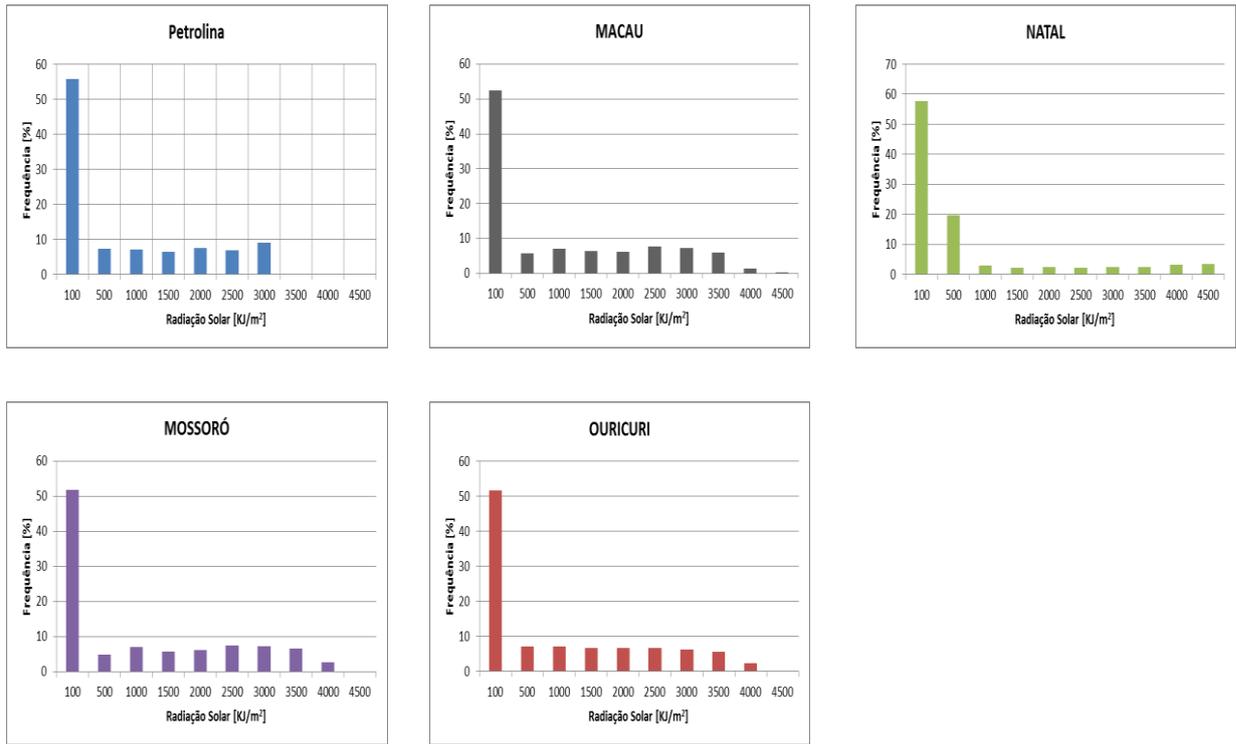


Figura 5.5 - Histograma da radiação solar para Petrolina, Macau, Natal, Mossoró e Ouricuri.

5.3.5 Tábua de Marés

As séries de marés disponibilizadas pela Diretoria de Hidrografia e Navegação (DHN) são discretizadas contabilizando apenas os valores máximos e mínimos, ver Figura 5.6, das alturas das marés ao longo do tempo.

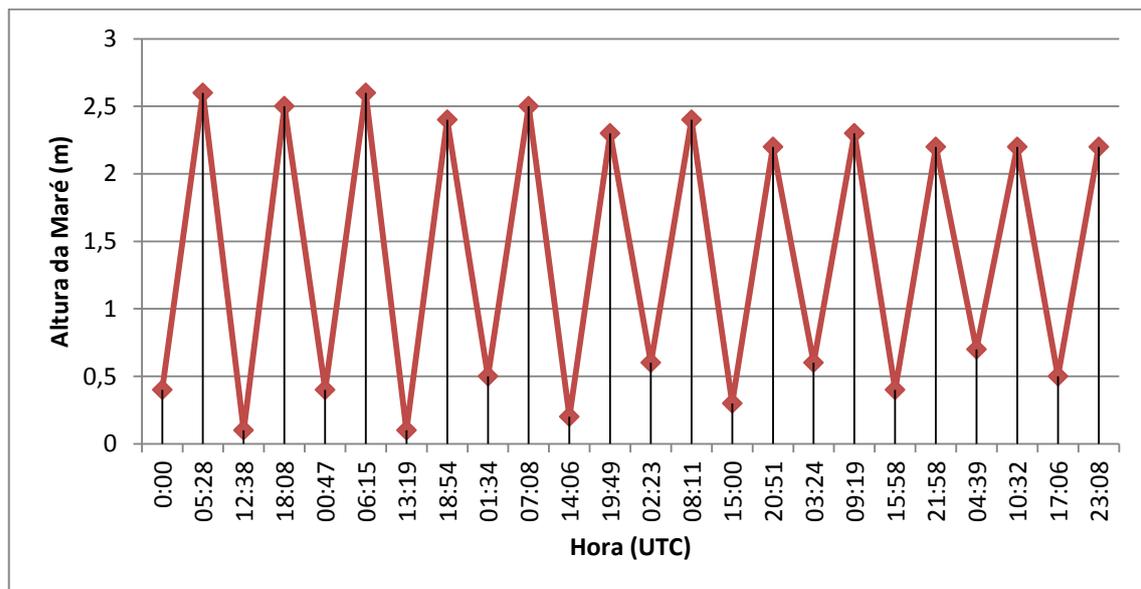


Figura 5.6 – Intervalo de 48 h para a série de maré de Macau.

Porém os dados como foram dispostos pelo banco de dados da DHN não estavam enquadrados com os modelos de séries de médias horárias para os sítios de Macau e Natal. Fez-se necessária a discretização horária com o objetivo de compatibilizar todas as séries de médias horárias, logo, uma interpolação senoidal foi aplicada aos dados de marés. A Figura 5.7 representa uma fração do gráfico da altura da maré para Macau em um horizonte de 24 horas após a realização da interpolação senoidal.

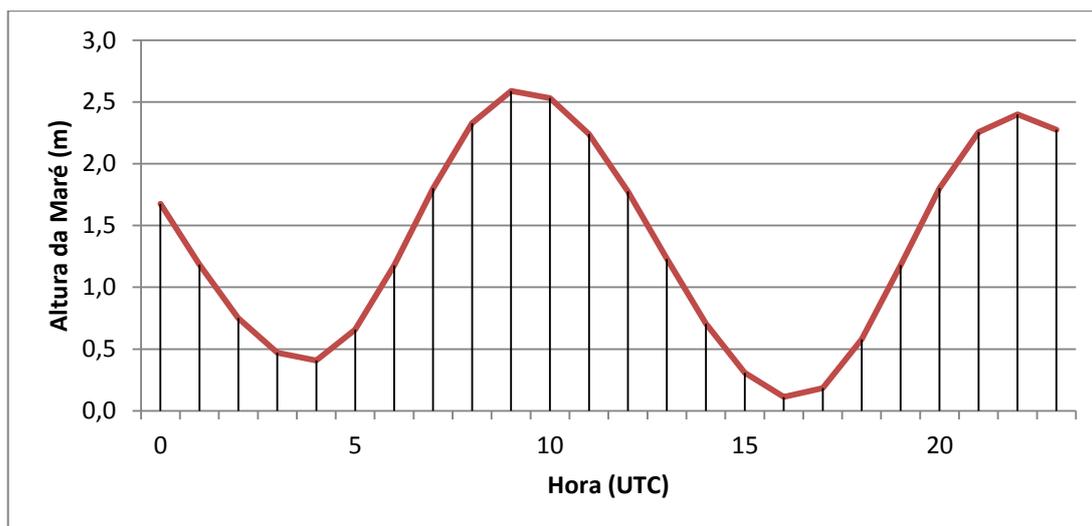


Figura 5.7 – Interpolação senoidal para Macau.

A partir da interpolação senoidal podemos obter as médias horárias das alturas das marés e realizar a análise estatística dos dados obtidos.

A Tabela 5.6 representa os valores mínimos, máximos, médios e os desvios padrões para as previsões de marés de Macau e Natal, respectivamente.

Tabela 5.6 – Estatísticas das séries de marés de Macau e Natal.

Estação	Mínima [m]	Máxima [m]	Média [m]	Desvio Padrão [m]
MACAU	-0,10	2,80	1,39	0,93
NATAL	-0,20	2,70	1,28	0,85

A Figura 5.8 apresenta os histogramas da frequência com que são distribuídas as alturas das marés para Macau e Natal. Percebe-se que para uma altura de até 1 m, as porcentagens correspondem a 37,50 % para Macau e 33,80 % Natal, para uma altura menor ou igual a 2 m e maior que 1 m, para Macau e Natal, as porcentagens correspondem a 49,82 % e 43,96%, respectivamente. Alturas superiores a 2 m representam valores de porcentagem inferiores aos apresentados anteriormente, 12,68 % para Macau e 22,24 %

para Natal. Esta abordagem para as alturas das marés pode ser relevante para estudos no que diz respeito à geração de energia elétrica a partir das ondas do mar, segundo (SILVA, 2012) a predominância de marés nesta faixa de frequência proporciona as características ideais para geração de energia elétrica a partir das ondas do mar.

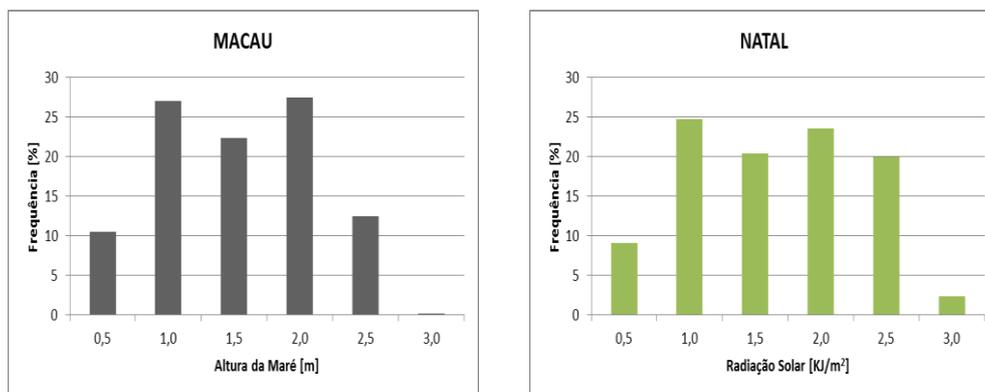


Figura 5.8 – Histograma das alturas das marés para Macau e Natal.

5.4 Descrição dos Modelos de Previsão de Velocidade de Vento

Para os sítios em que os dados de marés e fases da lua foram disponibilizados, inicialmente são propostos dez modelos para a previsão das velocidades médias horárias dos ventos para um horizonte de até quatro horas. Destes dez modelos, nove se caracterizam pela combinação de uma ou mais séries de médias horárias e o último modelo elaborado é uma combinação dos dois melhores modelos avaliados.

Os sítios em que as marés não fazem parte do universo de observação devido as suas elevadas distâncias as regiões costeiras, foram elaborados seis modelos para a previsão das velocidades médias horárias dos ventos para um horizonte de até quatro horas. Dos quais, cinco correspondem há combinação de uma ou mais séries de médias horárias e o último modelo elaborado é uma combinação dos dois melhores modelos avaliados.

Todos os modelos iniciais utilizam o ANFIS (*Adaptive Neuro – Fuzzy Inference System*) e as entradas obtidas levaram em consideração os coeficientes de autocorrelação e correlação que estão dispostos no **Apêndice A** deste texto.

Após a avaliação destes dez modelos para os sítios que dispunham de dados de marés e dos seis modelos para os sítios que não contemplam os dados de marés, foram escolhidos os quatro e os três modelos, respectivamente, que obtiveram melhor desempenho. O Modelo [2], que será descrito na seção 5.4.2, foi escolhido de antemão, devido a servir de entrada para a maioria dos modelos que obtiveram melhor desempenho.

Assim, utilizamos as *Redes Neurais Artificiais* (RNAs), as *Echo State Networks* (ESNs) e novamente o ANFIS para fazer uma avaliação mais profunda dos modelos e observar como os modelos se comportaram quando aplicados a diferentes métodos de inteligência artificial. É importante destacar que durante a segunda utilização do ANFIS houve a variação do raio espectral.

Tabela 5.7 – Relações dos modelos elaborados para cada sítio.

Sítios	M [1]	M [2]	M [3]	M [4]	M [5]	M [6]	M [7]	M [8]	M [9]	M [10]
										<i>best 1* + best 2*</i>
Natal	X	X	X	X	X	X	X	X	X	X
Macau	X	X	X	X	X	X	X	X	X	X
Petrolina	X	X					X	X	X	X
Ouricuri	X	X					X	X	X	X
Mossoró	X	X					X	X	X	X

* M [] – Modelos Propostos

5.4.1 Modelo [1]

Devido a utilizar apenas as séries históricas de velocidade este modelo foi aplicado a todos os sítios e foi o modelo mais simples proposto nesta dissertação. Basicamente o modelo é composto de quatro entradas e quatro saídas. As quatro entradas correspondem às quatro últimas velocidades médias horárias e as saídas correspondem à velocidade média horária prevista para os passos de previsão $t + 1$, $t + 2$, $t + 3$ e $t + 4$. A Figura 5.9 representa o esquema de entrada e saída do modelo de previsão.

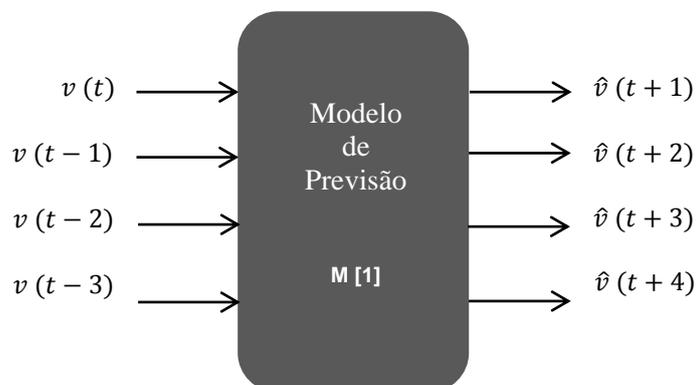


Figura 5.9 – Esquema de entrada e saída do modelo [1].

5.4.2 Modelo [2]

O modelo [2] foi elaborado a partir dos coeficientes de autocorrelação dispostos no Apêndice A.1. Ele é composto de seis entradas e quatro saídas. As duas primeiras entradas correspondem as duas últimas velocidades médias horárias e cada uma das outras quatro entradas seguintes correspondem à média aritmética simples das três velocidades medidas 24 horas, 48 horas e 72 horas atrás. Esses valores de velocidade são aqueles que apresentaram melhor coeficiente de autocorrelação. O cálculo foi realizado de acordo com as Equações (5.1), (5.2), (5.3) e (5.4) que são expressas da seguinte maneira:

$$\overline{v\overline{v}}_{(t-1)} = \frac{(t - 25) + (t - 49) + (t - 73)}{3} \quad (5.1)$$

$$\overline{v\overline{v}}_{(t-2)} = \frac{(t - 24) + (t - 48) + (t - 72)}{3} \quad (5.2)$$

$$\overline{v\overline{v}}_{(t-3)} = \frac{(t - 23) + (t - 47) + (t - 71)}{3} \quad (5.3)$$

$$\overline{v\overline{v}}_{(t-4)} = \frac{(t - 22) + (t - 46) + (t - 70)}{3} \quad (5.4)$$

O esquema de entrada e saída que representa o modelo está apresentado na Figura 5.10.

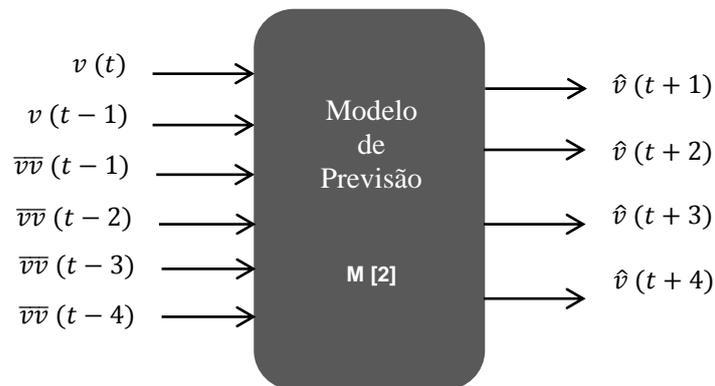


Figura 5.10 – Esquema de entrada e saída do modelo [2].

5.4.3 Modelo [3]

Neste caso, o modelo apresenta como entrada o modelo [2] mais as alturas das marés discretizadas em intervalos de uma hora. Essa discretização só foi obtida após uma interpolação senoidal, em que foi possível obter valores aproximados de marés para intervalos horários, proporcionando uma compatibilização das séries horárias de velocidade de vento e altura das marés. A Figura 5.11 representa o esquema de entrada e saída do modelo [10]. Este modelo foi aplicado apenas aos sítios de Natal e Macau, pois apenas estes apresentavam dados de marés no seu banco de dados.

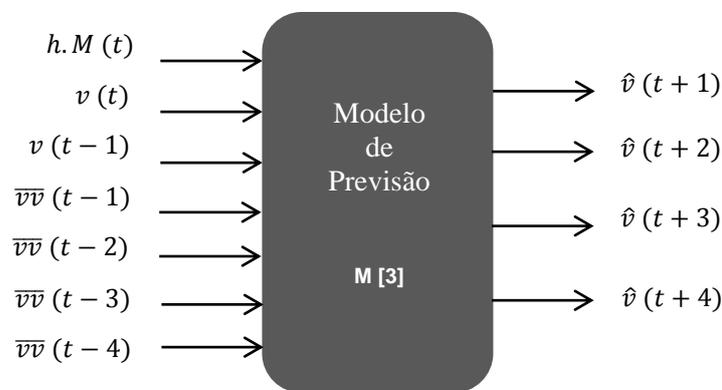


Figura 5.11 – Esquema de entrada e saída do modelo [3].

5.4.4 Modelo [4]

Este modelo foi proposto com o objetivo de avaliar a influência das fases da lua na previsão de velocidade de vento. O modelo é uma junção do modelo [2] com as fases da lua representadas em formato de número decimal. A Tabela 5.8 representa os códigos da lua em formato decimal.

Tabela 5.8 – Representação das fases da lua em formato decimal.

Fase da Lua	Fase da lua em Código Decimal (F.L.D)
 Lua cheia	4
 Lua Crescente	3
 Lua Nova	1
 Lua Minguante	2

A Figura 5.12 apresenta a composição das entradas e saídas do modelo [4].

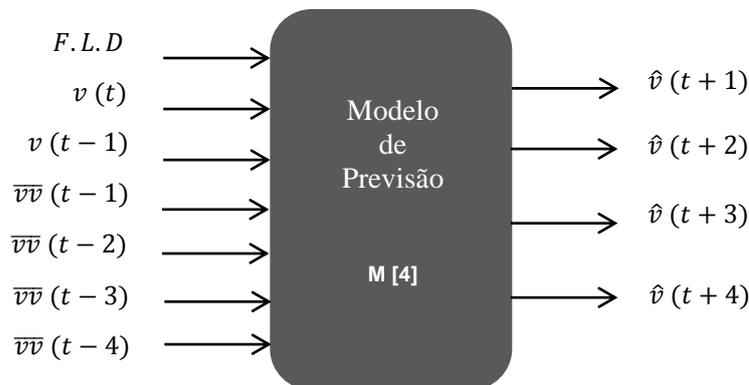


Figura 5.12 – esquema de entrada e saída do modelo [4].

A aplicação deste modelo só foi realizada apenas para os sítios de Natal e Macau, pois estes sítios estão localizados próximos à região costeira, e para estas localidades os dados de marés estão disponíveis.

5.4.5 Modelo [5]

Este modelo apresenta os mesmos padrões de saída, o que vai diferenciá-lo em relação aos outros modelos de previsão são suas entradas. O modelo [5] é composto da junção do modelo [2] com as fases da lua representadas em código binário, logo, o modelo será composto de oito entradas e quatro saídas.

A Tabela 5.9 apresenta a representação binária das fases da lua.

Tabela 5.9 – Representação das fases da lua em formato binário.

Fase da Lua		Fase da lua em Código Binário (F.L.B)	
	Lua cheia	1	1
	Lua Crescente	0	1
	Lua Nova	0	0
	Lua Minguante	1	0

O esquema de entrada e saída do modelo do modelo aqui citado está representado de acordo com a Figura 5.13.

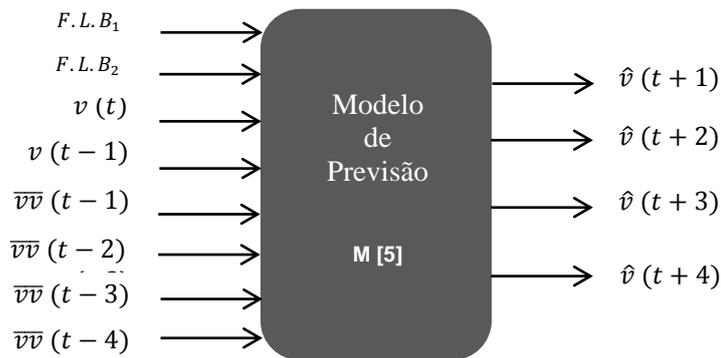


Figura 5.13 – Esquema de entrada e saída do modelo [5].

5.4.6 Modelo [6]

O modelo [6] é composto de oito entradas e quatro saídas. A representação binária utilizada para criação do modelo [5] foi à base para o desenvolvimento das duas primeiras entradas deste modelo, as outras seis entradas são as entradas do modelo [2]. Foi observado o comportamento da função $\text{sen}(x)$ e da função $\text{cos}(x)$, ambas foram plotadas em um mesmo gráfico e os valores inteiros da função seno foram confrontados com os valores inteiros da função cosseno (ver Figura 5.14) e assim foi obtida a representação das fases da lua em seno e cosseno (Ver Tabela 5.10).

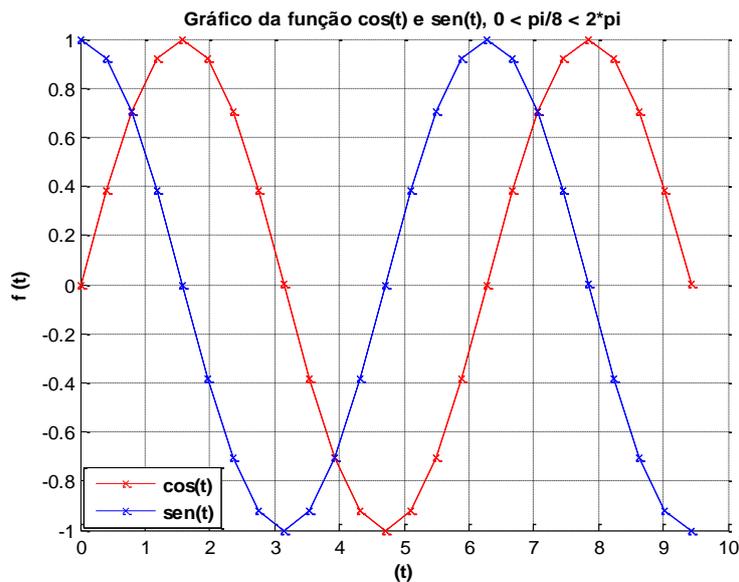


Figura 5.14 – Gráfico das funções $\text{sen}(t)$ e $\text{cos}(t)$.

Tabela 5.10 – Representação das fases da lua em seno e cosseno.

Fase da Lua	Fase da lua em Código
	cos(t) e sen(t) (F.L.C.S)
 Lua cheia	1 0
 Lua Crescente	0 1
 Lua Nova	- 1 0
 Lua Minguante	0 - 1

A Figura 5.15 apresenta o esquema de entrada do modelo [6].

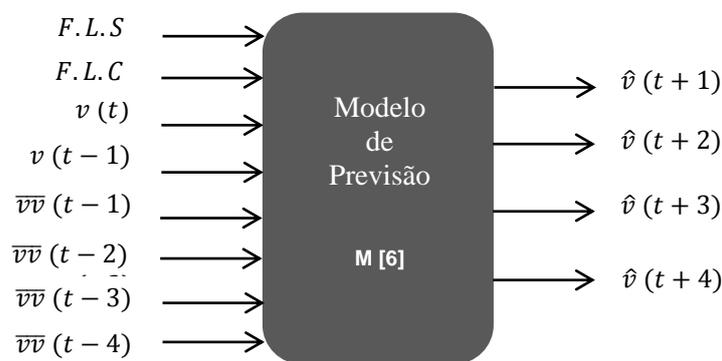


Figura 5.15 – Esquema de entrada e saída do modelo [6].

5.4.7 Modelo [7]

O modelo foi criado levando em consideração a boa correlação existente entre a temperatura e velocidade de vento para os sítios de Macau, Natal e Mossoró, porém o modelo foi estendido para os sítios de Petrolina e Ouricuri mesmo estes apresentando uma correlação “baixa”. As entradas deste modelo são compostas pelas entradas do modelo [2] e as duas últimas temperaturas instantâneas, T_t e T_{t-1} . As duas últimas temperaturas foram escolhidas em função da correlação entre as variáveis velocidade de vento e temperatura (ver Apêndice A.2). O esquema com as oito entradas do modelo e as quatro saídas está representado na Figura 5.16.

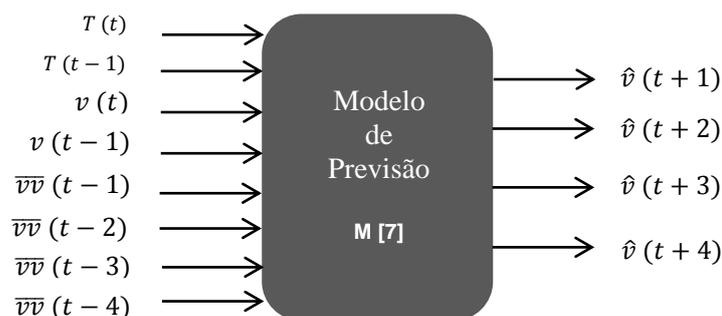


Figura 5.16 – Esquema de entrada e saída do modelo [7].

5.4.8 Modelo [8]

O modelo [8] é composto da combinação das entradas do modelo [2] com os três últimos valores da radiação solar, R_t , R_{t-1} e R_{t-2} , observados a partir da correlação linear entre as variáveis radiação solar e velocidade de vento. O **Apêndice A.4** mostra os gráficos contendo os coeficientes de correlação, Para Macau, Natal, Mossoró e Ouricuri as correlações podem ser ditas como satisfatórias, em contrapartida, para Petrolina a correlação entre velocidade de vento e radiação solar é “muito baixa”. Porém, para critério de avaliação dos modelos, este modelo foi aplicado as cinco sítios.

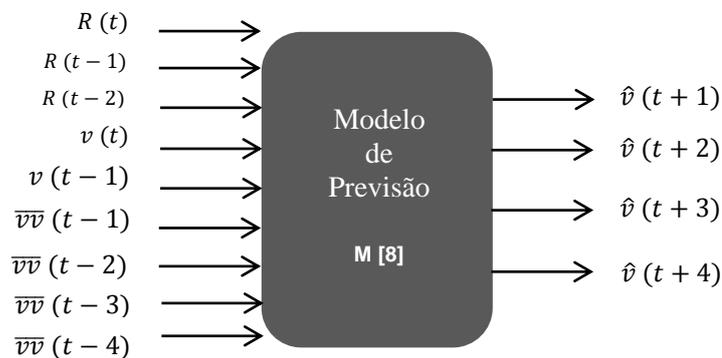


Figura 5.17 – Esquema de entrada e saída do modelo [8].

5.4.9 Modelo [9]

Este modelo é composto pelas entradas do modelo [2] com a adição dos três últimos valores de umidade relativa do ar, U_t , U_{t-1} e U_{t-2} , as entradas foram avaliadas em função dos coeficientes de correlação listados no Apêndice A.4 entre a variável velocidade do vento e umidade relativa do ar. Percebe-se que apenas para Natal e Mossoró as correlações apresentaram valores favoráveis, mas o modelo foi estendido para os sítios de Petrolina, Ouricuri e Macau. A Figura 5.18 representa o esquema de entrada e saída para o modelo [9].

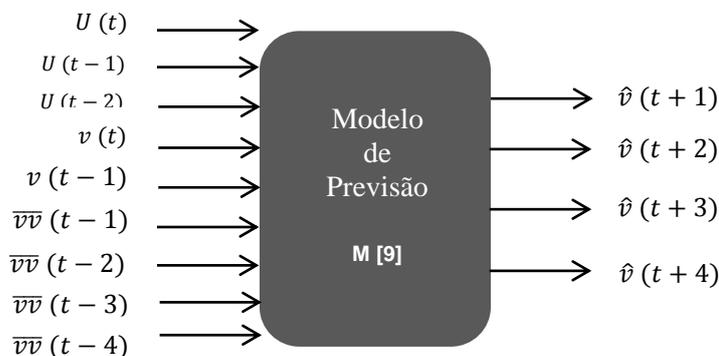


Figura 5.18 – Esquema de entrada e saída do modelo [9].

5.4.10 Modelo [10]

O modelo [10] é uma composição dos dois melhores modelos avaliados entre os nove modelos anteriores. A Figura 5.19 representa o esquema de entrada e saída deste modelo. O número de entradas deste modelo não pode ser definido previamente, devido à necessidade de avaliação dos modelos desenvolvidos anteriormente.

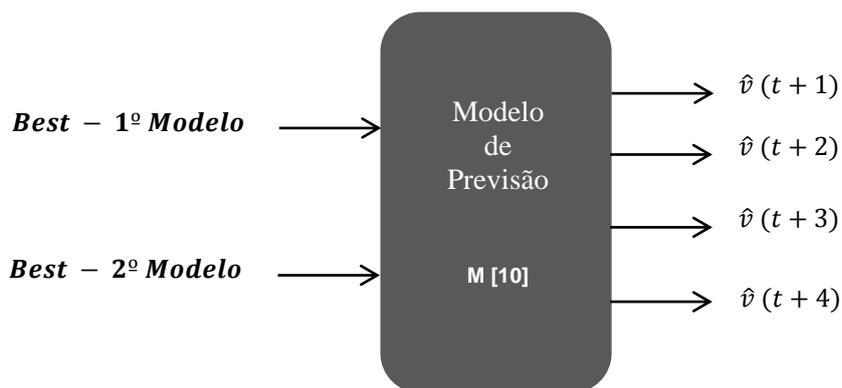


Figura 5.19 – Esquema de entrada e saída do modelo [10].

5.5 Escolha dos Melhores Modelos

O passo inicial antes da escolha dos melhores modelos é a partição dos dados; primeiramente, para cada sítio, a partir de cada uma das séries apresentadas anteriormente, foi criada uma matriz de padrões para cada passo de previsão (de 1 a 4 horas). O número de padrões está representado na Tabela 5.1. Como as saídas são fixas, as primeiras quatro colunas representam as saídas desejadas e as colunas seguintes representam as entradas dos modelos. Após a criação das matrizes de padrões, os dados foram particionados da seguinte maneira:

- 60 % dos dados até 31/05/2013 foram utilizados para criação do conjunto de **treinamento**;
- 20 % dos dados até 31/05/2013 foram utilizados para criação do conjunto de **validação**;
- 20 % dos dados até 31/05/2013 foram utilizados para criação do conjunto de **teste**;
- O período de 01/06/2013 à 31/05/2014 foi utilizado para criação do conjunto de **simulação**, este conjunto tem como função validar a capacidade de generalização da rede.

Todos os modelos iniciais foram simulados utilizando o ANFIS (*Adaptive Neuro – Fuzzy Inference System*) e calculou-se o MAPE, MAE e o MSE, para conjuntos de treinamento, validação, teste e simulação. O seguinte procedimento foi realizado para simulação dos modelos utilizando o ANFIS:

- I. Utilizando a técnica *subtractive clustering*, a partir do conjunto de treinamento, gerou-se um FIS com raio de influência igual a 0,3;
- II. Foram utilizados os conjuntos de treinamento e validação para realizar a adaptação das funções de pertinência do FIS.
- III. Os conjuntos de treinamento validação teste e simulação foram simulados e por fim foram calculados o MAPE, MAE e o MSE.

Todos os passos acima mencionados foram aplicados a Petrolina, Macau, Natal, Mossoró e Ouricuri. Os melhores modelos foram escolhidos em função do MAE médio do conjunto de validação. Na Tabela 5.11 estão calculados os MAEs do conjunto de validação para cada sítio.

Tabela 5.11 – Valores médios do MAE.

Sítio	Natal	Macau	Petrolina	Ouricuri	Mossoró
Modelo	MAE [m/s]	MAE [m/s]	MAE [m/s]	MAE [m/s]	MAE [m/s]
<i>M [1]</i>	0,6946	1,1934	0,7666	0,9021	1,0272
<i>M [2]</i>	0,5823	0,8207	0,7114	0,8487	0,7053
<i>M [3]</i>	0,5837	0,8202			
<i>M [4]</i>	0,5861	0,8241			
<i>M [5]</i>	0,5874	0,8268			
<i>M [6]</i>	0,5873	0,8268			
<i>M [7]</i>	0,5695	0,8028	0,7111	0,8452	0,6791
<i>M [8]</i>	0,5777	0,8090	0,7056	0,8310	0,7018
<i>M [9]</i>	0,5715	0,7867	0,7157	0,8551	0,6957
<i>M [10]</i>	0,5636	0,7722	0,7071	0,8276	0,6795

Para Natal, Macau e Mossoró, o modelo [10] é uma composição dos dois modelos que apresentaram melhor desempenho, modelo [7] e o modelo [9]. Esses três sítios, Natal, Macau e Mossoró, denotaram que, devido proximidade desses municípios à região costeira, proporcionando uma alta umidade relativa do ar média, resultados de simulações

com os modelos de umidade foram superiores aos modelos que continham de radiação solar como entradas.

Para Petrolina e Ouricuri, o modelo [10] é composto do modelo [7] e do modelo [8], estes apresentaram melhor desempenho quando comparados com os outros modelos. Para Petrolina e Ouricuri, região do sertão Pernambucano, os modelos com umidade não se mostraram satisfatórios, porém, nestes locais, devido a alta incidência de radiação solar, os modelos que continham radiação se mostraram bastantes satisfatórios na realização das previsões.

A partir da Tabela 5.11, para os sítios de Natal e Macau, será escolhido o modelo [2] e mais os quatro modelos que apresentaram melhor desempenho; para os sítios de Petrolina, Mossoró e Ouricuri o modelo [2] também será escolhido e mais os três modelos que apresentaram melhor desempenho.

Estes modelos serão simulados utilizando as *Redes Neurais Artificiais* (RNAs), as *Echo State Networks* (ESNs) e o ANFIS, ver Tabela 5.12, sempre varrendo diversos parâmetros, em busca da melhor arquitetura para cada modelo.

Tabela 5.12 – Modelos que serão simulados com a RNA, ESN e ANFIS.

Natal	Macau	Petrolina	Ouricuri	Mossoró
<i>M [2]</i>				
<i>M [7]</i>				
<i>M [8]</i>	<i>M [8]</i>	<i>M [8]</i>	<i>M [8]</i>	<i>M [9]</i>
<i>M [9]</i>	<i>M [9]</i>	<i>M [10]</i>	<i>M [10]</i>	<i>M [10]</i>
<i>M [10]</i>	<i>M [10]</i>	X	X	X

5.6 Procedimentos para o Treinamento e Ajustes dos Melhores Modelos Utilizando RNA, ANFIS e ESN

Nesta seção os modelos que apresentaram melhor desempenho serão treinados utilizando os três métodos de inteligência artificial abordados neste texto e alguns parâmetros de cada método serão varridos em busca da arquitetura que obtiver melhor desempenho para cada modelo.

5.6.1 Treinamento dos Modelos Utilizando RNA

5.6.1.1 Partição e Normalização dos Dados

O primeiro passo, que é a partição dos dados obedeceu aos mesmos critérios que foram estabelecidos na **Seção 5.5**. Em seguida, faz-se necessária à normalização dos dados, a normalização é importante para assegurar que todas as variáveis utilizadas nos modelos tenham o mesmo nível de atenção durante o treinamento. Além disto, os neurônios artificiais, geralmente, são compostos de funções de ativação que são limitadas. Assim, a normalização deve limitar os valores dos dados utilizados nos extremos das funções de ativação (GOUVEIA, 2011). Nesta dissertação, os dados foram normalizados de acordo com a Equação (5.1), em que os valores estão no intervalo de [0, 1].

$$\tilde{x}(t) = \frac{x(t) - x_{\min}}{x_{\max} - x_{\min}} \quad (5.1)$$

5.6.1.2 Escolha da Arquitetura

Em cada um dos modelos em que a Rede Neural Artificial foi utilizada, a determinação do número de neurônios na camada oculta obedeceu ao mesmo critério utilizado em (AQUINO, 2009), em que o número de neurônios da camada oculta é escolhido através de tentativas, sendo escolhido aquele número de neurônios na camada oculta que proporcionar melhor desempenho durante o treinamento da rede.

Para a aplicação das redes neurais nos modelos já definidos, o seguinte procedimento foi adotado para determinar o número de neurônios na camada oculta:

- I. Primeiramente, foi criada uma rede com quatro neurônios na camada oculta;
- II. Foram atribuídos pesos aleatórios para todas as conexões da rede, e realizou-se o treinamento da rede através do algoritmo LM (*Levenberg-Marquardt*) e foi calculado o MSE para o conjunto de treinamento, validação e teste;
- III. O passo anterior foi repetido dez vezes. Após a décima repetição foi calculada a média do MSE para cada conjunto (treinamento, validação e teste);
- IV. Outro neurônio foi adicionado a camada oculta, e os passos II, III e IV foram repetidos, até a rede possuir dezesseis neurônios na camada oculta;
- V. A arquitetura escolhida foi a que foi a que apresentou menor MSE para o conjunto de validação.

Realizado o procedimento anterior, o número de neurônios na camada oculta para os sítios de Macau, Natal, Mossoró, Petrolina e Ouricuri, são apresentados na Tabela 5.13.

Tabela 5.13 – Número de neurônios na camada oculta.

	M[2]	M[7]	M[8]	M[9]	M[10]
Petrolina	10	7	8		10
Ouricuri	8	15	15		13
Natal	12	14		16	7
Macau	13	11		14	14
Mossoró	14	16		16	15

5.6.2 Treinamento dos Modelos Utilizando o ANFIS

Primeiramente, fez – se necessário à partição dos dados, esta etapa obedeceu aos mesmos critérios utilizados na **seção 5.5** desta dissertação. Após a realização desta etapa, os melhores modelos foram treinados utilizando o ANFIS e calculou – se o MAPE, MAE e o MSE, para o conjunto de treinamento, validação, teste e simulação. O seguinte procedimento foi realizado para simulação dos modelos utilizando o ANFIS:

- I. Utilizando a técnica *subtractive clustering*, a partir do conjunto de treinamento, gerou-se um FIS com raio de influência igual a 0,3;
- II. Foram utilizados os conjuntos de treinamento e validação para realizar a adaptação das funções de pertinência do FIS.
- III. Os conjuntos de treinamento validação teste e simulação foram simulados e por fim foram calculados o MAPE, MAE e o MSE.
- IV. Um novo FIS foi gerado, adicionou-se 0,1 ao tamanho do raio e retornou ao item II. O MAPE, MAE e o MSE foram calculados para o FIS até o raio atingir valor de 0,7. Passou-se para o passo seguinte;
- V. O melhor FIS foi escolhido de acordo com o MSE do conjunto de validação.

Este procedimento foi realizado para os sítios de NATAL, MACAU, MOSSORÓ, OURICURI e NATAL. Os raios de influência para os sítios de Petrolina e Ouricuri estão representados na Figura 5.20.

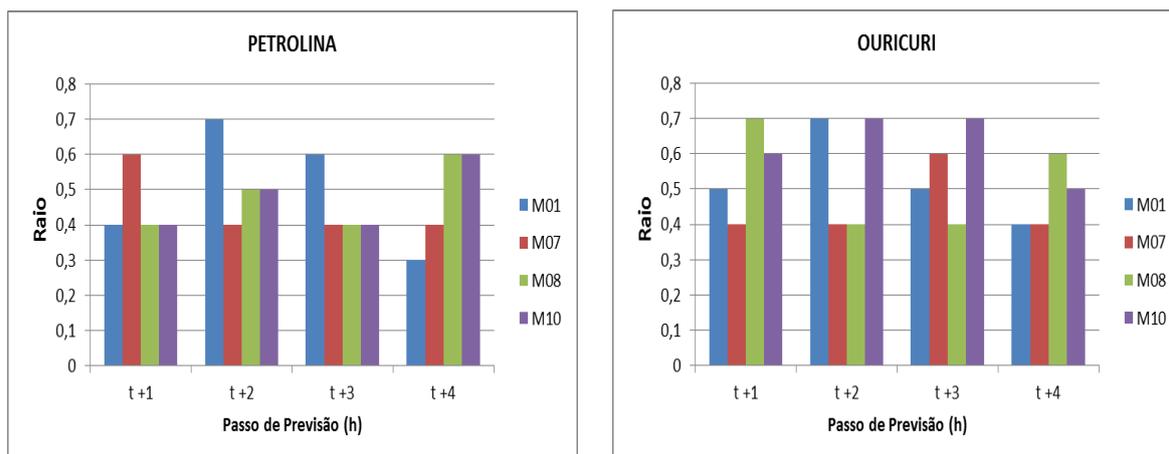


Figura 5.20 – Raios para os sítios de Petrolina e Ouricuri.

5.6.3 Treinamento dos Modelos Utilizando o ESN

Para o treinamento dos experimentos utilizando ESN a divisão dos conjuntos obedeceu aos mesmos critérios estabelecidos na **seção 5.5**. Os parâmetros escolhidos para o treinamento e ajuste dos modelos foram os seguintes:

- Conectividade das matrizes de pesos;
Variando de 0,3 até 0,4 com incremento de 0,1.
- Número de neurônios da camada oculta;
Variando de 200 até 500 com incremento de 50;
- Função de ativação dos neurônios;
As funções de ativação utilizadas foram a sigmoide logística e a tangente hiperbólica.
- Raio espectral;
Variando de 0,8 até 1,2 com incremento de 0,1.
- Tipo de rede ESN;

Três tipos de redes foram treinadas, para cada tipo de rede os parâmetros acima foram variados e obteve-se a melhor configuração.

Para os sítios de Natal e Petrolina os melhores parâmetros estão apresentados nas Tabelas 5.14 e 5.15.

Tabela 5.14 – Parâmetros de treinamento do ESN para Natal.

MODELOS	<i>PARÂMETROS</i>				
	<i>Rede ESN</i>	<i>Número de Neurônios</i>	<i>Raio</i>	<i>Função ativação</i>	<i>Conectividade</i>
Mod. [02]	leaky_ESN	500	1,1	Sigmóide	0,4
Mod. [07]	leaky_ESN	500	1,1	Sigmóide	0,3
Mod. [08]	leaky_ESN	500	1,0	Sigmóide	0,3
Mod. [09]	leaky_ESN	500	1,2	Sigmóide	0,3
Mod. [10]	leaky_ESN	500	0,8	Sigmóide	0,4

Tabela 5.15 – Parâmetros de treinamento do ESN para Petrolina.

MODELOS	<i>PARÂMETROS</i>				
	<i>Rede ESN</i>	<i>Número de Neurônios</i>	<i>Raio</i>	<i>Função ativação</i>	<i>Conectividade</i>
Mod. [02]	leaky_ESN	500	0,8	Sigmóide	0,4
Mod. [07]	leaky_ESN	500	1,2	Sigmóide	0,3
Mod. [08]	leaky_ESN	500	1,2	Sigmóide	0,4
Mod. [10]	leaky_ESN	500	1,2	Sigmóide	0,4

Para os dois sítios citados nas Tabelas 5.14 e 5.15, os parâmetros tipo de rede, número de neurônios e função de ativação foram comuns.

CAPÍTULO 6

6. PREVISÕES E COMPARAÇÕES ENTRE OS MODELOS DE PREVISÃO

Neste capítulo serão apresentados os desempenhos dos modelos desenvolvidos para os sítios de NATAL, MACAU, MOSSORÓ, OURICURI e PETROLINA, bem como, as comparações entre os modelos desenvolvidos e o modelo de referência *Persistência* que foi explicitado na seção 4.3.

O capítulo será dividido em cinco seções, em que cada seção corresponde às simulações obtidas para cada sítio utilizando as RNAs, o ANFIS e o ESN. O último nível da lista dentro de cada seção será uma avaliação de cada modelo aplicado aos três métodos de inteligência artificial e ao modelo de referência.

Para todos os modelos, o período escolhido para avaliação corresponde à hora zero (UTC) do dia 01/06/2013 a hora 23 (UTC) do dia 31/05/2014.

6.1 Previsões de Velocidades para o Sítio de NATAL

6.1.1 Previsões Utilizando RNA

A Figura 6.1 corresponde ao gráfico dos valores do MAE do conjunto de simulação para o horizonte de previsão até quatro horas utilizando *Redes Neurais Artificiais*.

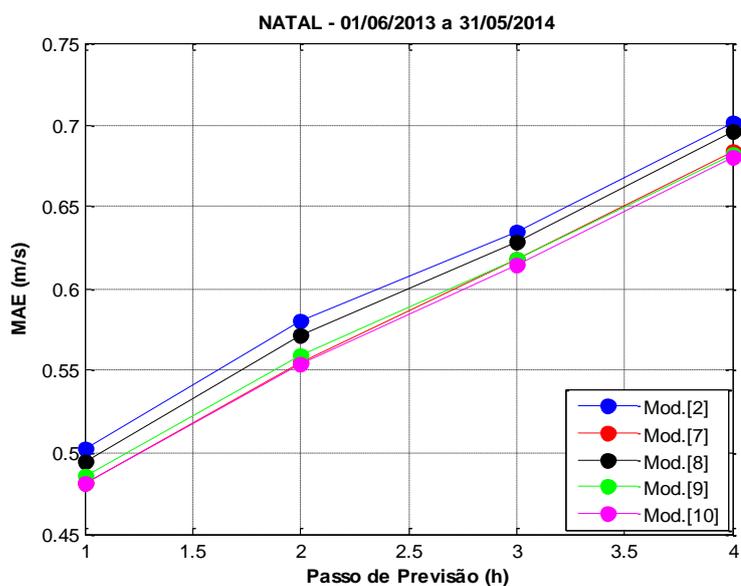


Figura 6.1 – MAE das previsões de velocidade em Natal utilizando RNA.

É possível perceber, a partir da análise do gráfico, que os modelos [7], [9] e [10] apresentam previsões mais confiáveis quando comparados com os modelos [2] e [8]. O modelo [10], que para este sítio, é a composição dos modelos [7] e [9], apresentou menor média do MAE para o conjunto simulado, mas, para a primeira hora de previsão apresentou um desempenho inferior ao modelo [7].

Os ganhos obtidos por cada modelo em relação ao modelo da *Persistência* estão representados na Figura 6.2. Os modelos [2] e [8] foram os modelos que obtiveram menores ganhos quando comparados aos outros modelos, porém, quando o gráfico $G_{PERS,MAE}$ é analisado, nota-se que para todos os modelos o ganho mínimo para o horizonte de previsão de uma hora foi acima de 10 % e para o horizonte de previsão de quatro horas o ganho foi superior a 25 % mostrando a eficácia dos modelos propostos neste texto quando comparados com o modelo de referência.

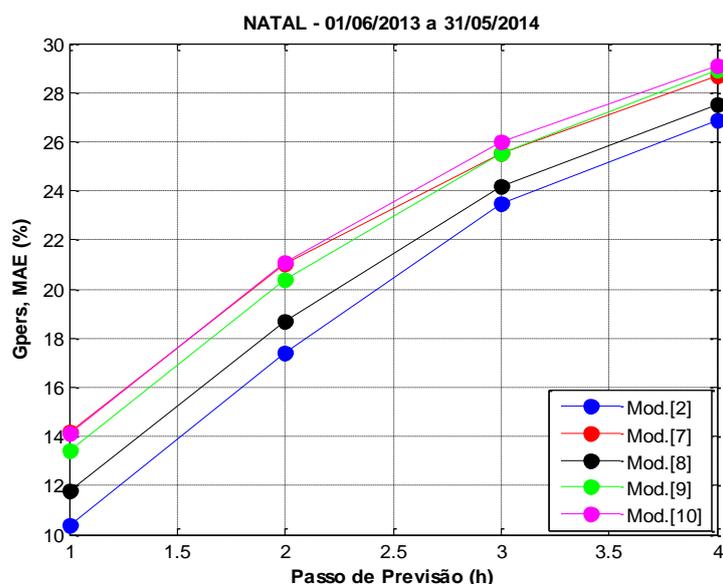


Figura 6.2– Ganho das previsões de velocidade em Natal utilizando RNA.

6.1.2 Previsões Utilizando ANFIS

A Figura 6.3 corresponde ao gráfico dos valores do MAE do sítio de Natal para o conjunto de simulação com horizonte de previsão de até quatro horas utilizando o *ANFIS* nos modelos de previsão.

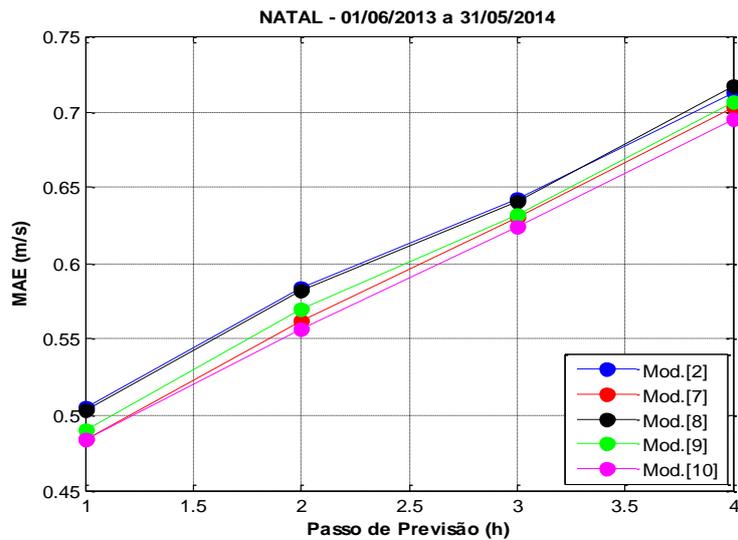


Figura 6.3 – MAE das previsões de velocidade em Natal utilizando ANFIS.

Ao avaliar os mesmo modelos de previsão de vento propostos a partir do ANFIS, é possível perceber a partir da Figura 6.3 que o modelo [10] se sobrepôs a todos os outros modelos para qualquer horizonte de previsão de uma a quatro horas. Os modelos [2] e [8] continuaram a apresentar resultados inferiores aos outros modelos.

Os ganhos obtidos por cada modelo em relação ao modelo da *Persistência* estão representados na Figura 6.4. Ao analisar o gráfico $G_{PERS,MAE}$ observa-se que todos os modelos apresentaram ganhos satisfatórios quando comparados com o modelo da *Persistência*. Para o horizonte de previsão de quatro horas todos os modelos apresentaram ganhos superiores a 25 %, isso ratifica o bom desempenho dos modelos desenvolvidos.

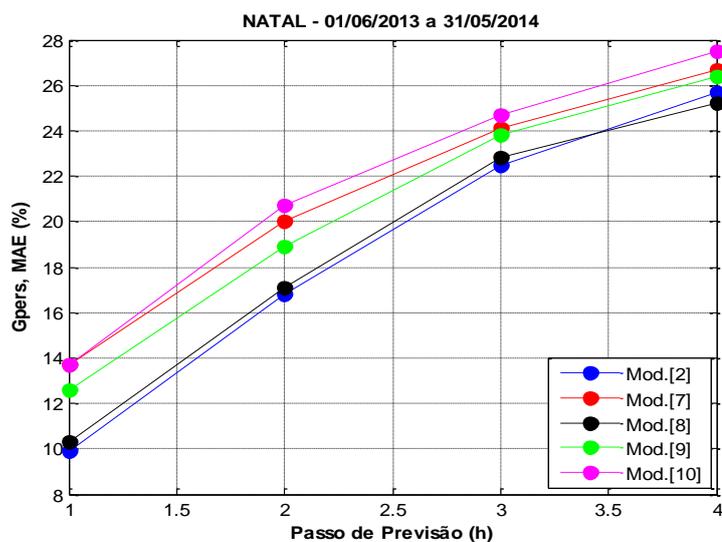


Figura 6.4 – Ganho das previsões de velocidade em Natal utilizando ANFIS.

6.1.3 Previsões Utilizando ESN

A Figura 6.5 representa o MAE do conjunto de simulação para o horizonte de previsão de até quatro horas para o sítio de NATAL em que os modelos utilizaram as ESN.

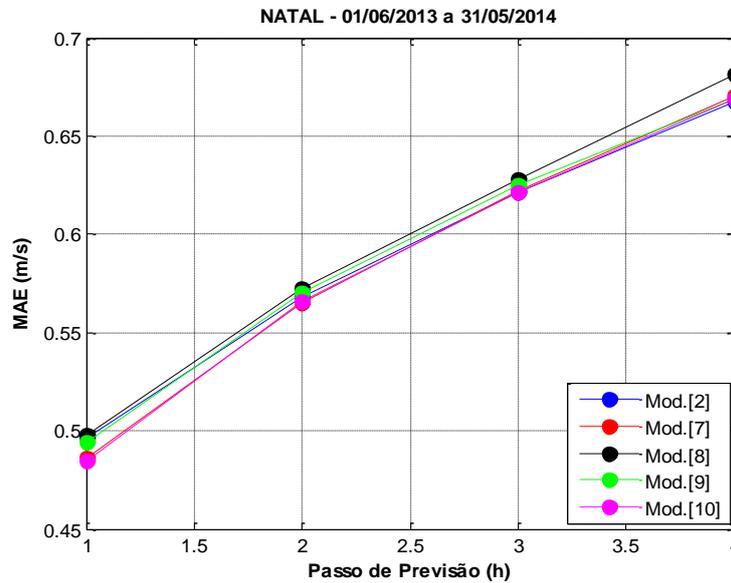


Figura 6.5 – MAE das previsões de velocidade em Natal utilizando ESN.

Ao utilizar o ESN aos modelos de previsão pode-se notar que o Modelo [2] apresenta um desempenho similar quando comparado aos outros modelos. A Figura 6.5 é capaz de mostrar que para a primeira horas o MAE do modelo [10] é superior aos outros modelos, porém, ao analisar a quarta hora que é o horizonte máximo de previsão desta dissertação, o MAE do modelo [10] apenas se sobrepõe ao MAE dos modelos [7] e [8] podendo induzir a uma perspectiva que para horizontes mais longos o modelo [10] não se comporte satisfatoriamente.

Os ganhos obtidos por cada modelo em relação ao modelo da *Persistência* estão representados na Figura 6.6. Ao analisar o gráfico $G_{PERS,MAE}$ observa-se que todos os modelos apresentaram ganhos satisfatórios quando comparados com o modelo de referência. Para o horizonte de previsão de quatro horas todos os modelos apresentaram ganhos superiores a 25 %.

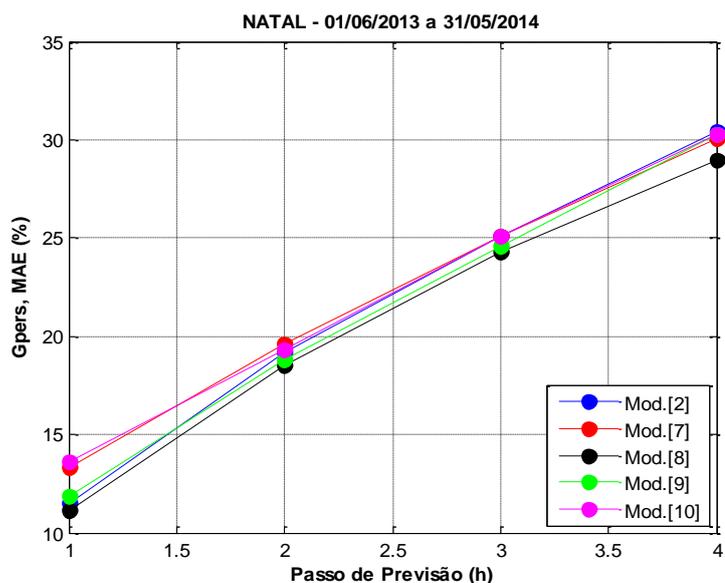


Figura 6.6 – Ganho das previsões de velocidade em Natal utilizando ESN.

6.1.4 Comparações Entre os Métodos de IA para o Sítio de NATAL

A Figura 6.7 representa o MAE para os modelos [2] e modelo [10], é possível perceber que ao comparar os três métodos de inteligência artificial abordados neste texto e aplicados ao experimento [2], nota-se que o ESN proporcionou um desempenho superior ao método de referência *Persistência*, as RNAs e o ANFIS. Porém, ao aplicar os mesmos métodos ao experimento [10] é possível perceber que para as três primeiras horas as RNAs apresentam desempenho superior aos outros métodos, sendo superada apenas, na última hora de previsão pelo ESN.

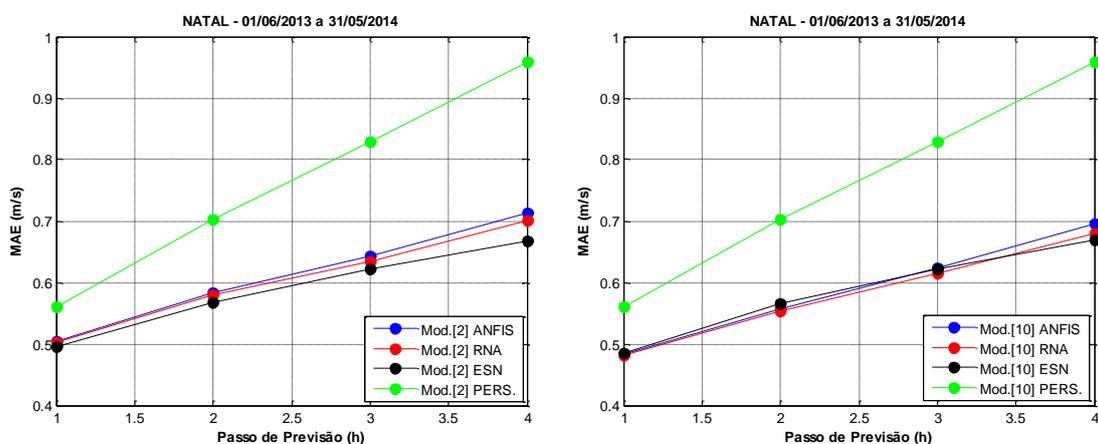


Figura 6.7 – MAE do experimento [2] e experimento [10] para Natal.

6.2 Previsões de Velocidades Para o Sítio de MACAU

6.2.1 Previsões Utilizando RNA

A Figura 6.8 representa o MAE do conjunto de simulação para o horizonte de previsão de até quatro horas para o sítio de MACAU. A partir da análise do gráfico percebe-se que o experimento [10] apresenta desempenho superior aos outros experimentos para todos os horizontes de previsão deste texto. O experimento [2], que é composto pelos dois últimos valores de velocidade do experimento [1], $v(t)$ e $v(t-1)$, e mais os quatros valores correspondente à média aritmética simples das três velocidades medidas 24 horas, 48 horas e 72 horas atrás, não apresentou desempenho satisfatório quando comparado com os outros experimentos.

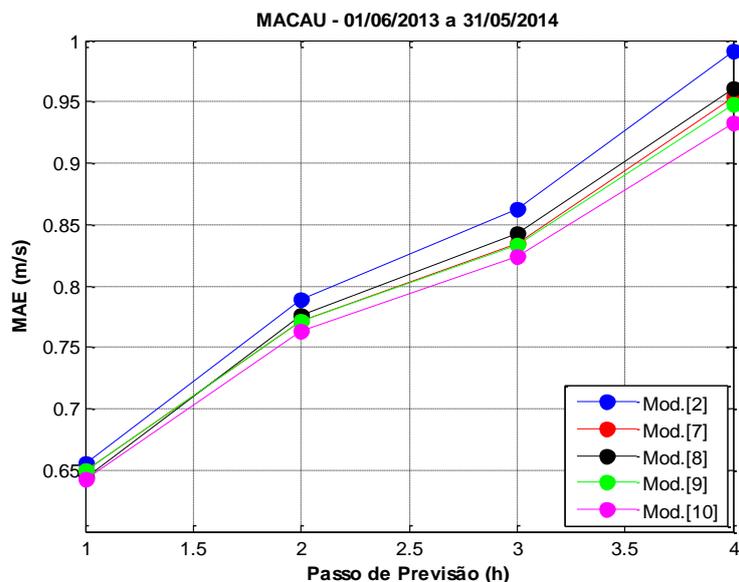


Figura 6.8 – MAE das previsões de velocidade em Macau utilizando RNA.

Quando comparados com o método da *Persistência*, para o sítio de MACAU, os ganhos obtidos pelos experimentos utilizando as RNAs foram bem satisfatórios. Para a primeira a primeira hora de previsão todos os modelos apresentaram ganhos superiores a 15 % e para a terceira hora de previsão os ganhos observados são superiores a 40 % para todos os modelos. O ganho obtido é uma forma de mostrar uma melhoria dos modelos desenvolvidos em relação ao modelo de referência.

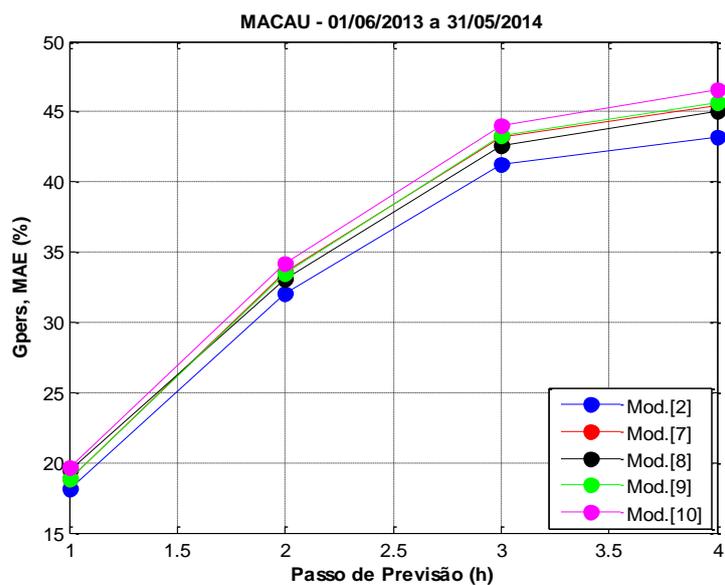


Figura 6.9 – Ganho das previsões de velocidade em Macau utilizando RNA.

6.2.2 Previsões Utilizando ANFIS

A Figura 6.10 representa o MAE do conjunto de simulação para o sítio de MACAU para o horizonte de previsão de até quatro horas.

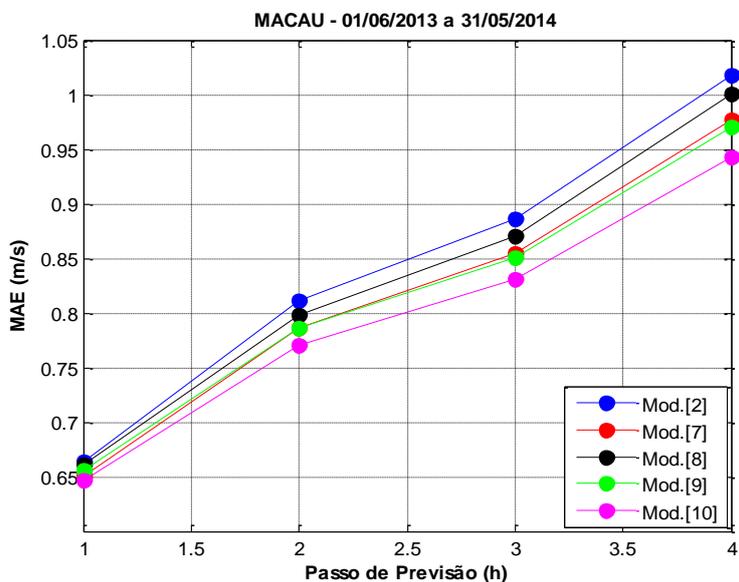


Figura 6.10 – MAE das previsões de velocidade em Macau utilizando ANFIS.

Ao observar a Figura 6.10, o experimento [10] ao utilizar o ANFIS como método de Inteligência artificial apresentou menor MAE que os outros experimentos que também utilizaram o ANFIS. O experimento [2], que utiliza como uma das variáveis de entrada os

valores médios da velocidade medidas 24 horas, 48 horas e 72 horas atrás, não apresentou desempenho relevante quando comparado com os outros modelos. Para Macau, o modelo [10], que é a composição do modelo [2] mais as entradas de temperatura e umidade relativa do ar apresentou desempenho superior a todos os outros modelos para qualquer horizonte de previsão.

Os ganhos obtidos pelos experimentos em relação ao modelo da *Persistência* estão discriminados na Figura 6.11.

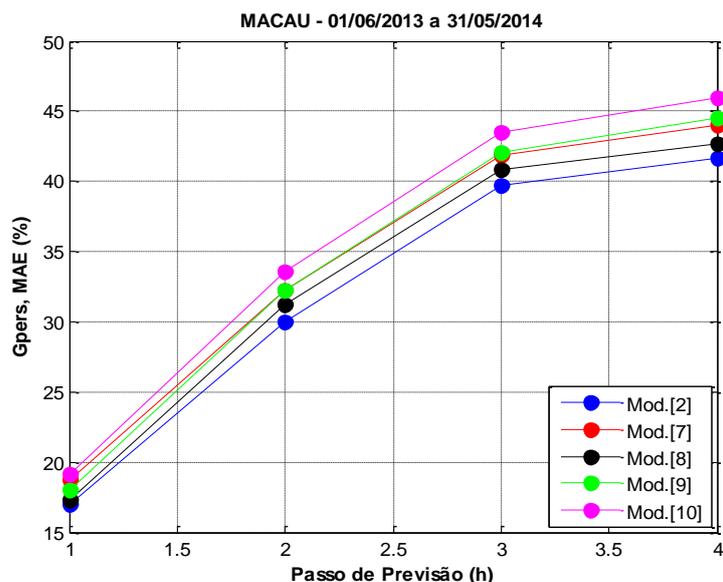


Figura 6.11 – Ganho das previsões de velocidade em Macau utilizando ANFIS.

É possível perceber, de acordo com a Figura 6.11, que todos os experimentos apresentaram ganhos superiores a 15 % quando comparados com o modelo da *Persistência*. Para o horizonte de previsão de quatro horas, o experimento [10] apresentou um ganho superior a 45 % quando comparado com o modelo de referência da *Persistência*.

6.2.3 Previsões Utilizando ESN

A Figura 6.12 representa o MAE do conjunto de simulação para o sítio de MACAU para o horizonte de previsão de até quatro horas.

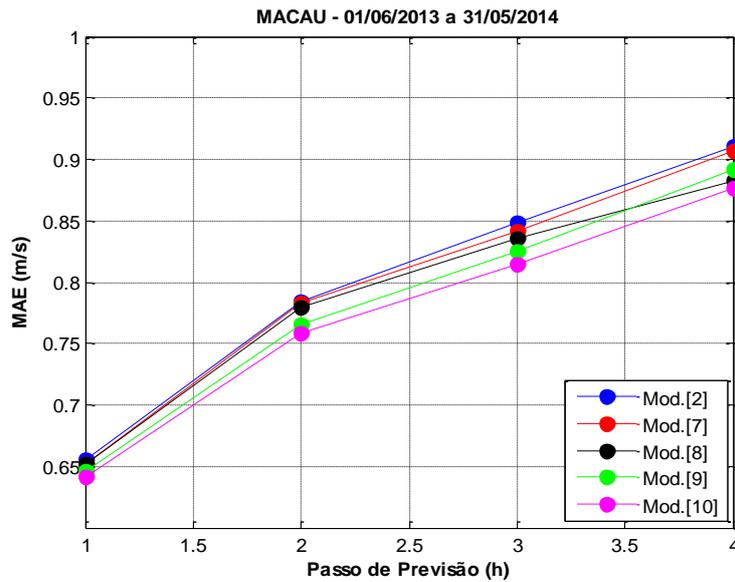


Figura 6.12 – MAE das previsões de velocidade em Macau utilizando ESN

Ao utilizar o experimento [10] como entrada para o método de inteligência artificial ESN, este obteve melhor desempenho quando comparado com todos os outros experimentos para qualquer horizonte de previsão de uma a quatro horas.

O ganho obtido deste método em relação ao método da *Persistência* é representado a partir da Figura 6.13. Todos os modelos apresentaram desempenhos superiores quando comparados com o modelo de referência, por exemplo, o modelo [10] apresentou desempenho cerca de 50 % superior ao modelo de referência adotado.

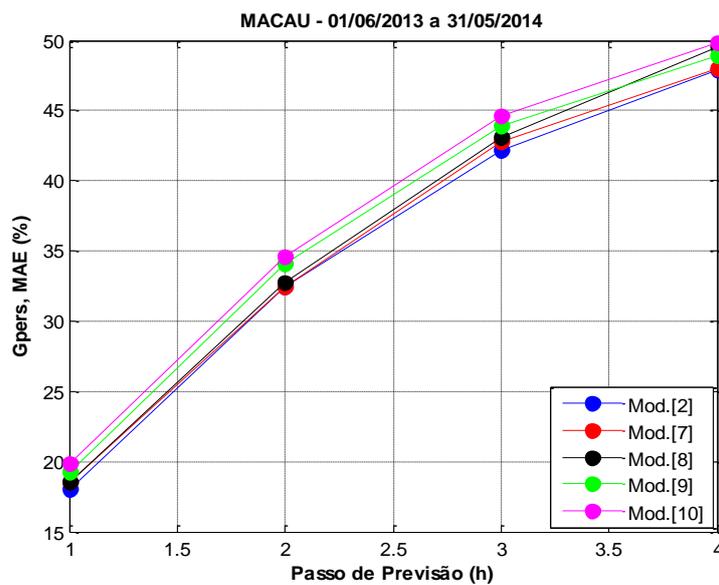


Figura 6.13 – Ganho das previsões de velocidade em Macau utilizando ESN.

6.2.4 Comparações Entre os Métodos de IA para o Sítio de MACAU

A Figura 6.14 apresenta a evolução do MAE para o sítio de MACAU com horizonte de previsão de até quatro horas. Para os experimentos [2] e [10] o método de inteligência artificial ESN se sobrepõe aos outros métodos abordados para todos os horizontes de previsão.

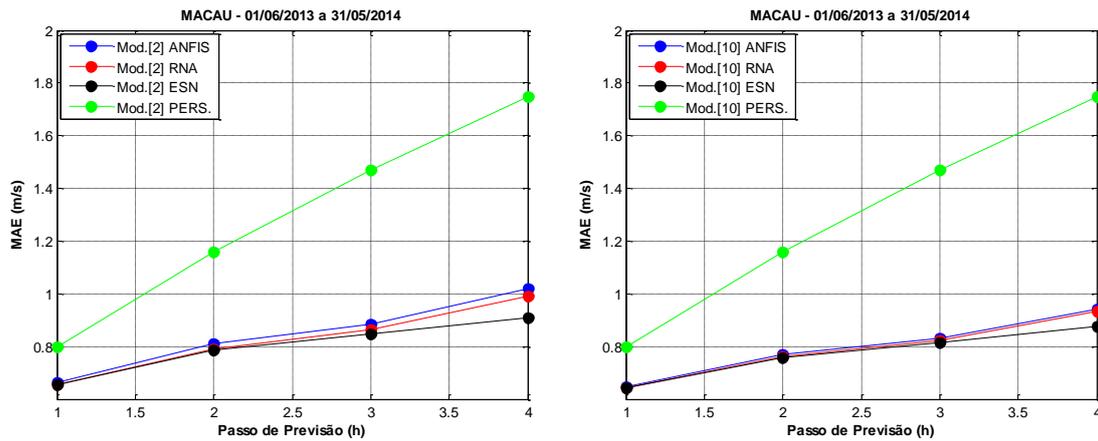


Figura 6.14 – MAE do experimento [2] e experimento [10] para o sítio de Macau.

6.3 Previsões de Velocidades Para o Sítio de PETROLINA

6.3.1 Previsões Utilizando RNA

A Figura 6.15 representa o MAE do conjunto de simulação para o horizonte de previsão de até quatro horas. Como o sítio de Petrolina não faz parte da região litorânea, a altura das marés, que compõe o experimento [3], não corresponde a análises realizadas para o sítio de Petrolina.

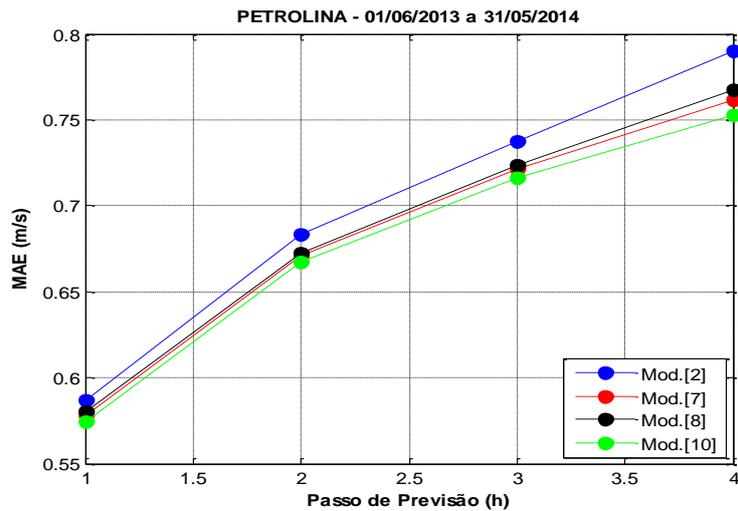


Figura 6.15 – MAE das previsões de velocidade em Petrolina utilizando RNA.

A Figura 6.15 indica que o experimento [10], utilizando RNA, apresenta menor MAE para todos os horizontes de previsão. É importante destacar que para o sítio de Petrolina, o experimento da umidade relativa do ar apresentou desempenho inferior ao experimento da radiação solar.

Os ganhos obtidos, em relação ao método da *Persistência*, pelos experimentos usando as RNAs como método de IA, estão representados na Figura 6.16. É possível observar que mesmo o experimento [2] apresentando desempenho inferior aos outros modelos, à melhoria obtida por ele, em relação ao modelo da *Persistência*, para última hora de previsão foi superior a 20 %.

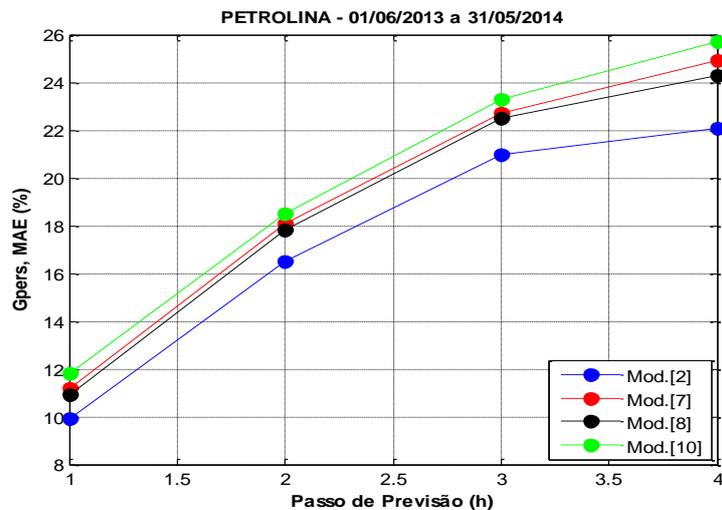


Figura 6.16 – Ganho das previsões de velocidade em Petrolina utilizando RNA.

6.3.2 Previsões Utilizando ANFIS

A Figura 6.17 representa o MAE do conjunto de simulação do ANFIS para o horizonte de previsão de até quatro horas.

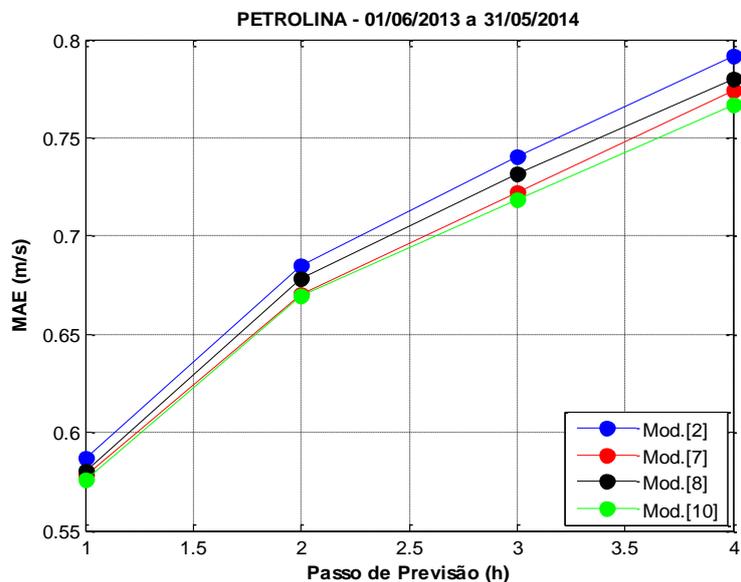


Figura 6.17 – MAE das previsões de velocidade em Petrolina utilizando ANFIS.

Dentre as características observadas a partir da Figura 6.17, o experimento [10] apresenta melhor desempenho quando comparado com outros experimentos para todos os horizontes de previsão.

Os ganhos obtidos pelos modelos quando comparados com o método da *Persistência* estão representados na Figura 6.18.

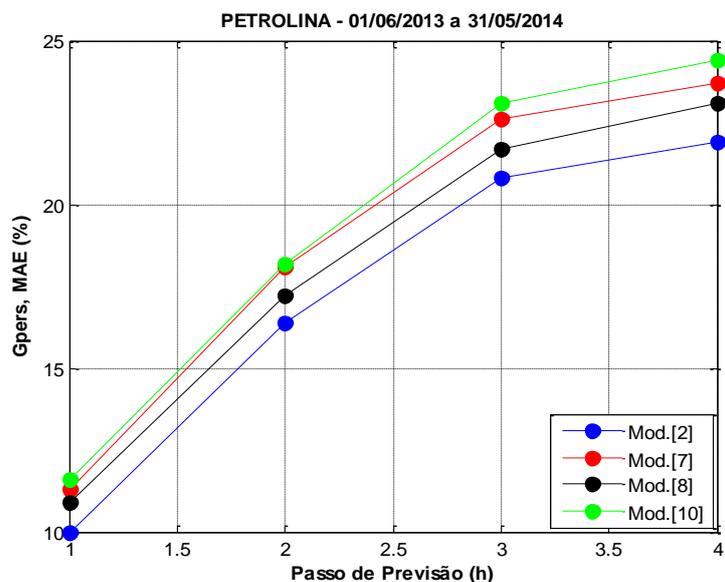


Figura 6.18 – Ganho das previsões de velocidade em Petrolina utilizando ANFIS.

Em relação ao método da *Persistência*, todos os experimentos apresentaram ganhos da ordem de 10 % para a primeira hora de previsão, destacando a evolução dos modelos quando comparados ao modelo de referência.

6.3.3 Previsões Utilizando ESN

A Figura 6.19 representa o MAE do conjunto de simulação utilizando o ESN para o horizonte de previsão de até quatro horas.

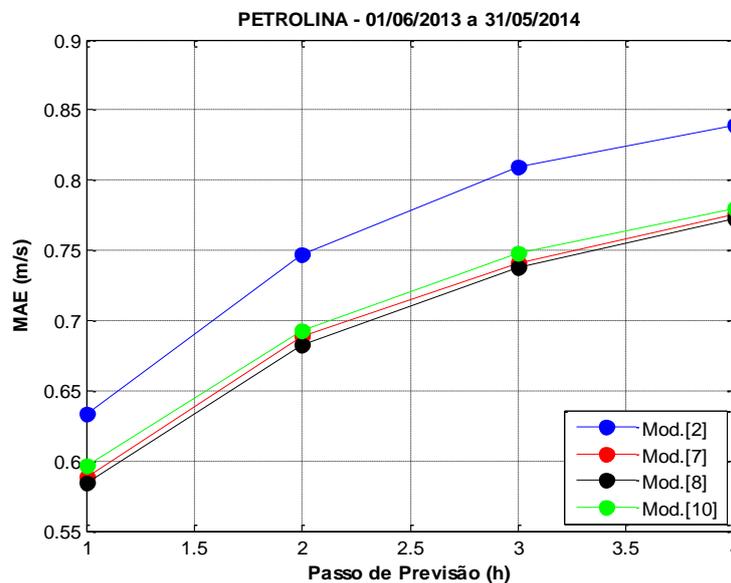


Figura 6.19 – MAE das previsões de velocidade em Petrolina utilizando ESN.

Para o sítio de Petrolina, o experimento [10], utilizando o método de inteligência artificial ESN apresentou desempenho inferior aos experimentos [7] e [8] para todos os horizontes de previsão, isso mostra que para métodos diferentes de IA, experimentos diferentes podem apresentar desempenho superior aos outros experimentos.

A Figura 6.20 representa o ganho obtido, em relação ao método da *Persistência*, pelos experimentos [2], [7], [8] e [10].

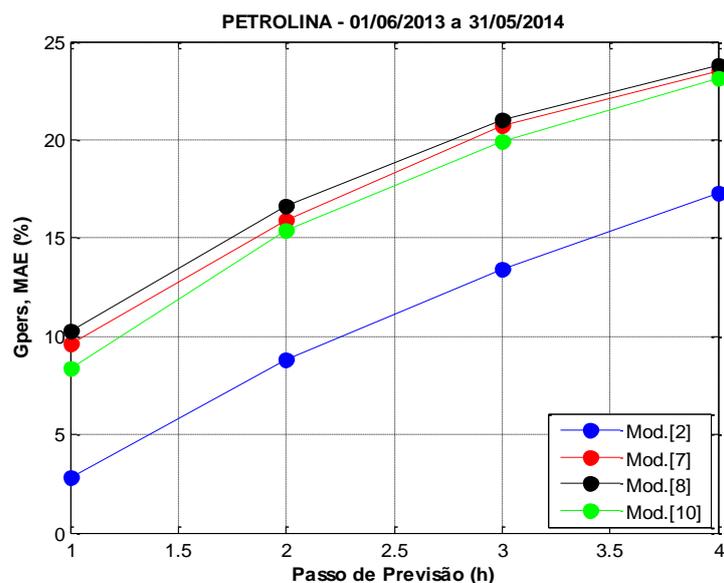


Figura 6.20 – Ganho das previsões de velocidade em Petrolina utilizando ESN.

O experimento [2] apresentou um ganho pequeno para a primeira hora de previsão quando comparado ao método da *Persistência*. Também foi o experimento que apresentou menor ganho quando comparado com o ganho obtido por todos os experimentos. Para o sítio de Petrolina, a utilização do ESN proporcionou um aumento no desempenho do modelo [8] quando comparado com os outros modelos.

6.3.4 Comparações Entre os Métodos de IA para o Sítio de PETROLINA

A Figura 6.21 representa o MAE para os horizontes de previsão de uma até quatro horas para os experimentos [2] e [10]. Para estes experimentos, o método de IA ESN apresentou desempenho inferior as RNAs e ao ANFIS. O MAE do experimento [2] mostra a pequena diferença entre o desempenho utilizando RNA e o ANFIS, na primeira hora de previsão o ANFIS consegue obter melhores resultados, porém, para as horas seguintes as RNAs conseguem apresentar desempenho superior. Em relação ao experimento [10] as RNAs apresentam desempenho superior para todos os horizontes de previsão de velocidade de vento.

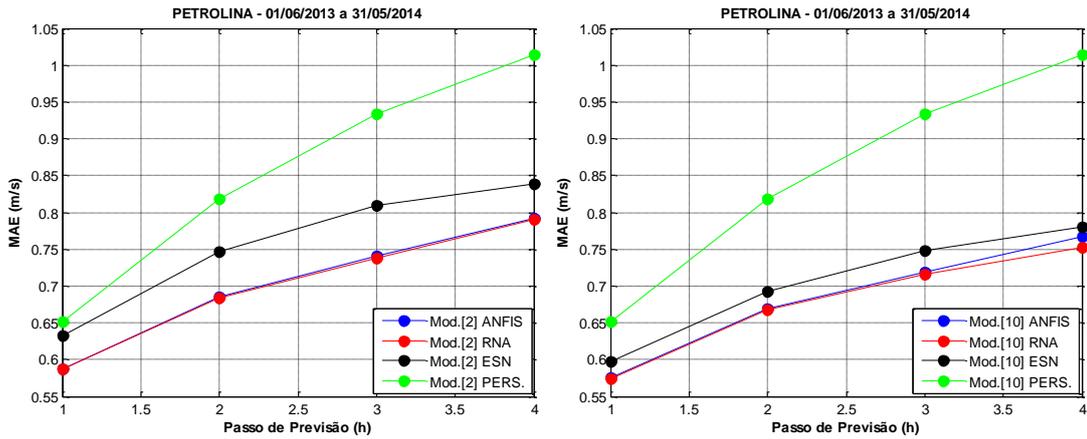


Figura 6.21 – MAE do experimento [2] e experimento [10] para o sítio de Petrolina.

6.4 Previsões de Velocidades Para o Sítio de OURICURI

6.4.1 Previsões Utilizando RNA

A Figura 6.22 representa o MAE do conjunto de simulação utilizando as RNAs para o horizonte de previsão de uma a quatro horas.

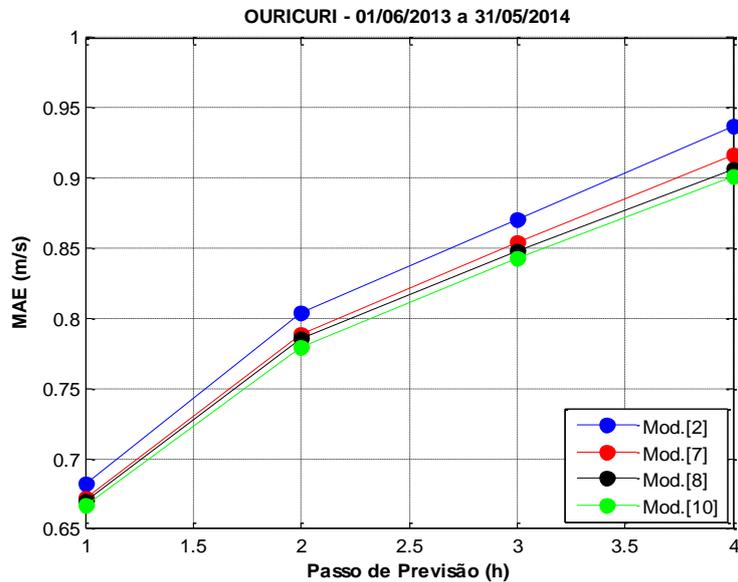


Figura 6.22 – MAE das previsões de velocidade em Ouricuri utilizando RNA.

O experimento [10] foi o que apresentou menor MAE para todos os horizontes de previsão. Diferentemente de Petrolina, o experimento [8], apresentou menor MAE quando

comparado com o experimento [7], ou seja, a radiação solar propôs melhores resultados que a temperatura instantânea do local.

O ganho obtido pelos experimentos quando comparados com o método da *Persistência* estão representados na Figura 6.23.

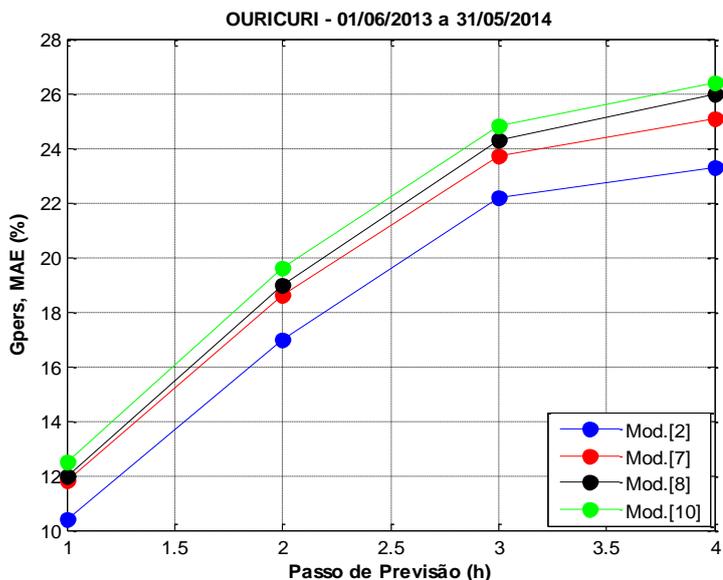


Figura 6.23 – Ganho das previsões de velocidade em Ouricuri utilizando RNA.

Para todos os experimentos, os ganhos em relação ao método da persistência são superiores a 10 % para primeira hora de previsão. Considerando o horizonte de previsão de quatro horas o experimento [10] obteve maior ganho comparando com os ganhos obtidos pelos outros experimentos.

6.4.2 Previsões Utilizando ANFIS

A Figura 6.24 representa o MAE do conjunto de simulação para o horizonte de previsão de uma até quatro horas para o sítio de Ouricuri utilizando como método de inteligência artificial o ANFIS.

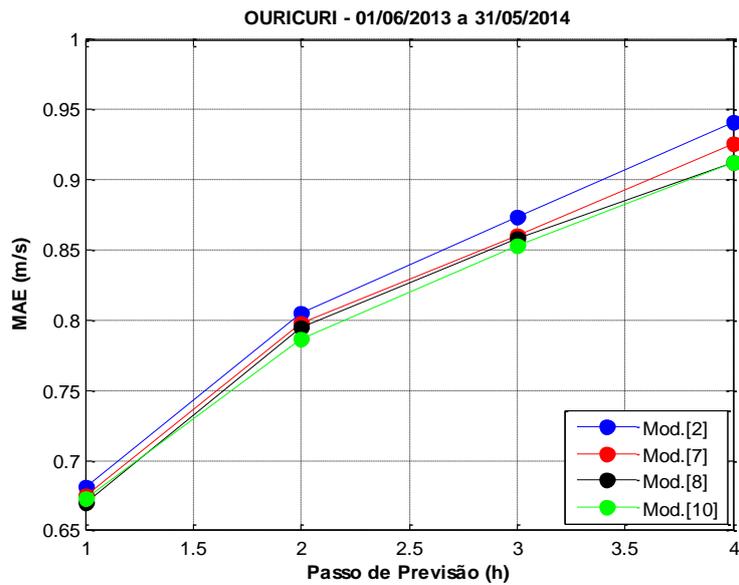


Figura 6.24 – MAE das previsões de velocidade em Ouricuri utilizando ANFIS.

Ao analisar o gráfico, percebe-se que para a primeira hora de previsão o experimento [8] apresenta melhor desempenho quando comparado com os outros experimentos, sendo superado pelo experimento [10] para horizontes de previsão de duas e três horas, respectivamente. Na quarta hora de previsão o experimento [8], novamente, apresenta desempenho superior a todos os outros experimentos.

O ganho obtido por cada experimento com relação ao método da *Persistência* está indicado na Figura 6.25.

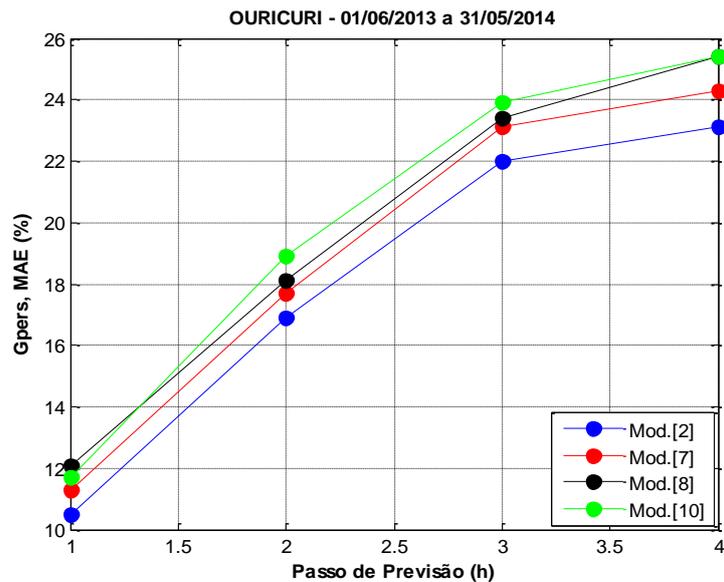


Figura 6.25 – Ganho das previsões de velocidade em Ouricuri utilizando ANFIS.

O ganho obtido por todos os experimentos em relação ao modelo de referência *Persistência* são superiores a 10 % para a primeira hora de previsão. Para última hora de previsão, apenas os experimento [8] e [10] exibem ganhos superiores a 25 %.

6.4.3 Previsões Utilizando ESN

A Figura 6.26 representa a evolução do MAE do conjunto de simulação para o horizonte de previsão de uma à quatro horas utilizando como método de inteligência artificial o ESN.

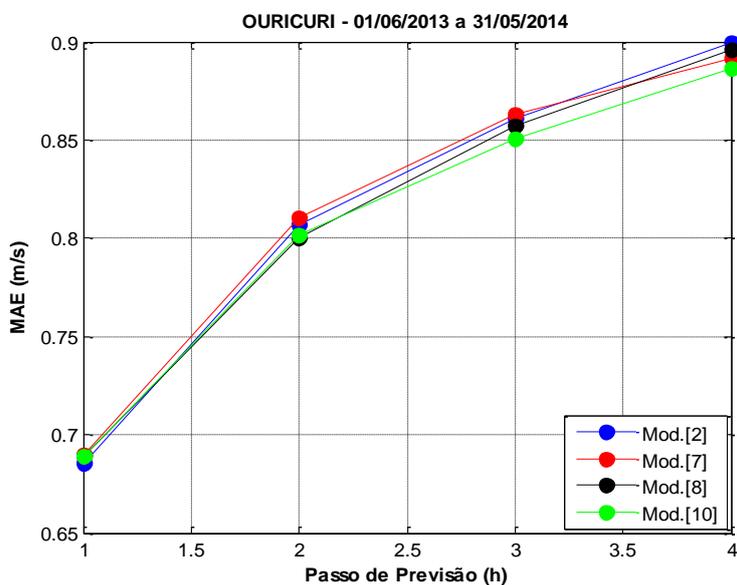


Figura 6.26 – MAE das previsões de velocidade em Ouricuri utilizando ESN.

A Figura 6.26 mostra que para a primeira hora de previsão o experimento [10] tem desempenho inferior ao experimento [2] e para segunda hora apresenta desempenho inferior ao experimento [8]. Mesmo tendo desempenho inferior para as duas primeiras horas de previsão, o experimento [10] acompanha de perto o desempenho dos modelos que foram superiores ao seu desempenho, e os supera a partir da terceira hora de previsão.

O ganho obtido por estes experimentos que utilizaram como método de IA o ESN quando comparados com o método estatístico da *Persistência* está discriminado na Figura 6.27.

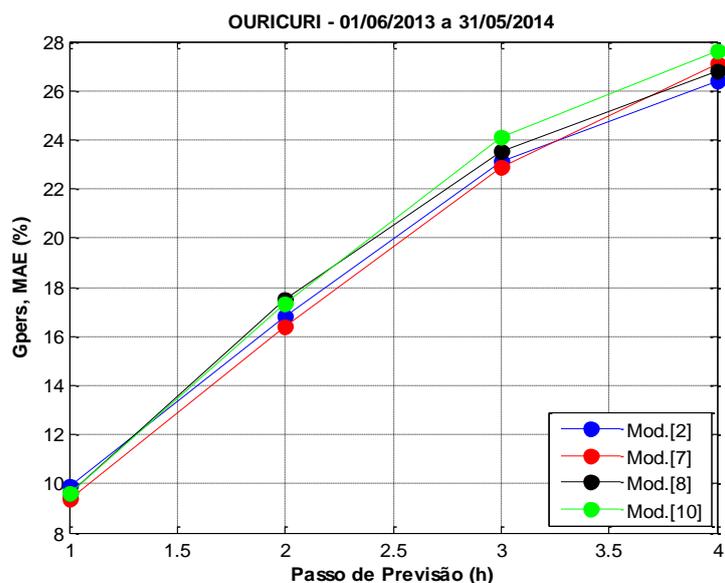


Figura 6.27 – Ganho das previsões de velocidade em Ouricuri utilizando ESN.

Todos os experimentos que utilizaram como método de IA o ESN apresentaram ganhos superiores a 26 %, quando comparados com o método da *Persistência*, para o horizonte de previsão de quatro horas.

6.4.4 Comparações Entre os Métodos de IA para o Sítio de OURICURI

A Figura 6.28 representa a comparação de um mesmo experimento para os métodos de IA e estatístico, em que o MAE é utilizado como avaliação do desempenho dos modelos desenvolvidos.

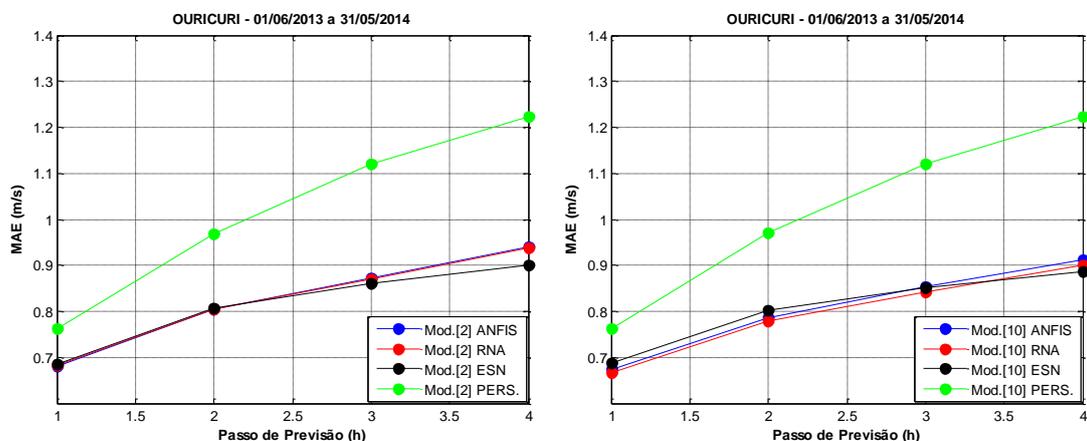


Figura 6.28 – MAE do experimento [2] e experimento [10] para o sítio de Ouricuri.

Ao avaliar a Figura 6.28 percebe-se que para o experimento [2] o ANFIS consegue fornecer melhores previsões apenas para primeira hora, perdendo para segunda hora para as RNAs, a partir da terceira hora o ESN tem um desempenho superior aos outros métodos fornecendo previsões mais confiáveis.

Para o experimento [10] as RNAs fornecem previsões mais confiáveis para as três primeiras horas de previsão, porém, perde em desempenho para quarta hora de previsão.

6.5 Previsões de Velocidades Para o Sítio de MOSSORÓ

6.5.1 Previsões Utilizando RNA

Com base na Figura 6.29, é representado o MAE do conjunto de simulação para o horizonte de previsão de até quatro horas em que o método de IA utilizado é a RNA, é possível verificar que o experimento [10] apresenta desempenho superior aos outros experimentos para qualquer horizonte de previsão estipulado neste texto.

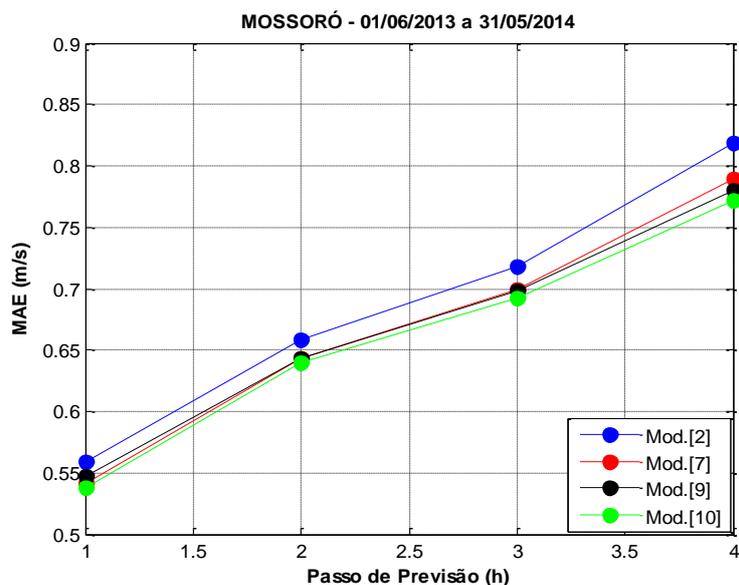


Figura 6.29 – MAE das previsões de velocidade em Mossoró utilizando RNA.

O ganho alcançado por todos os experimentos que utilizaram as RNAs quando comparado com o método da *Persistência* é da ordem de 20 % para primeira hora de previsão. Para o horizonte de previsão de quatro horas a melhora na performance foi da ordem de 45 %, isso vem a ratificar a qualidade dos modelos, em que ao ser comparado com um método de referência apresenta desempenhos superiores.

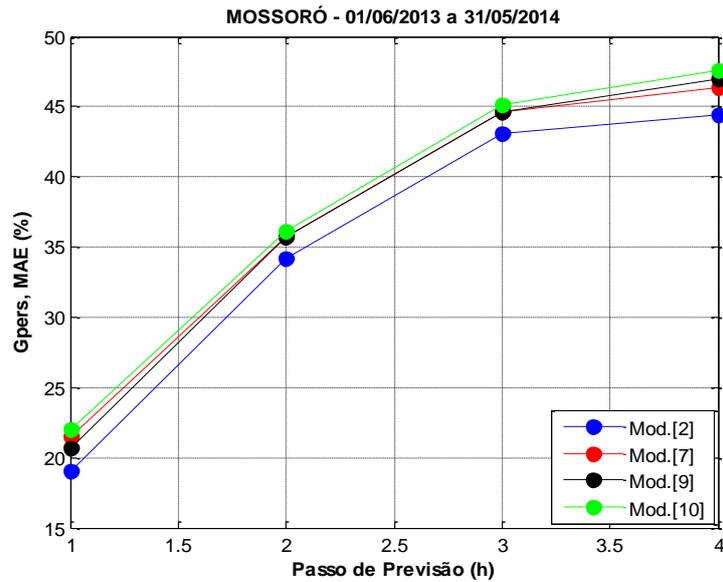


Figura 6.30 – Ganho das previsões de velocidade em Mossoró utilizando RNA.

6.5.2 Previsões Utilizando ANFIS

A Figura 6.30 representa o MAE do conjunto de simulação para o horizonte de previsão de até quatro horas, em que o método de IA utilizado é o *ANFIS*.

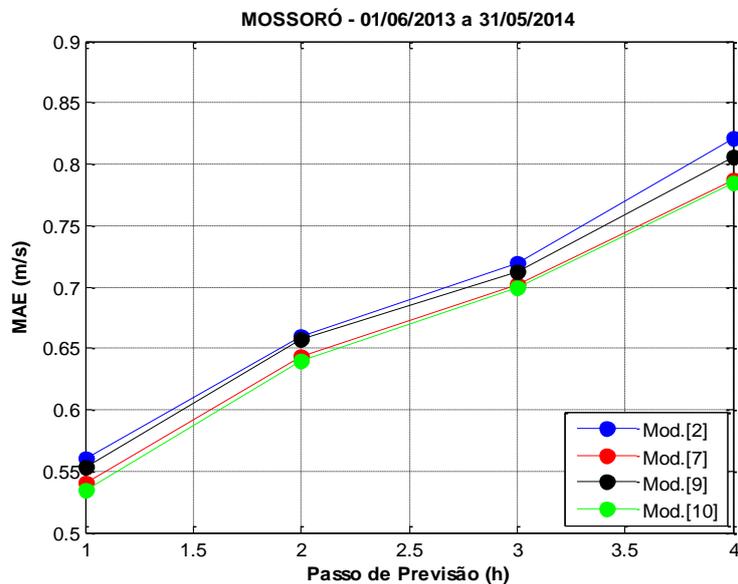


Figura 6.31 – MAE das previsões de velocidade em Mossoró utilizando ANFIS.

O experimento [10] continua a apresentar desempenho superior aos outros experimentos para o horizonte de previsão de uma até quatro horas.

Os ganhos obtidos pelos experimentos através da utilização do ANFIS são similares aos obtidos pelas RNAs. A partir da análise da Figura 6.32 é possível perceber que o experimento [10] continua a apresentar ganhos superiores aos outros experimentos quando comparado com o modelo de referência *Persistência*.

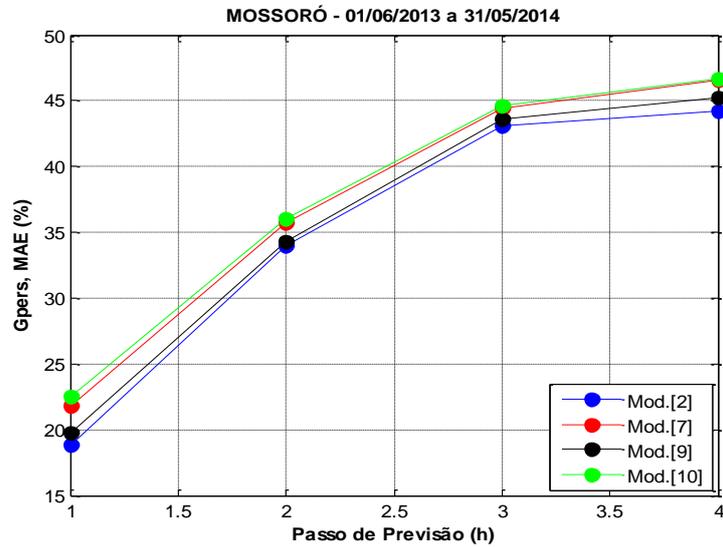


Figura 6.32 – Ganho das previsões de velocidade em Mossoró utilizando ANFIS.

6.5.3 Previsões Utilizando ESN

A Figura 6.33 representa o MAE do conjunto de simulação em que o método de inteligência artificial utilizado foi o ESN para o horizonte de previsão de até quatro horas.

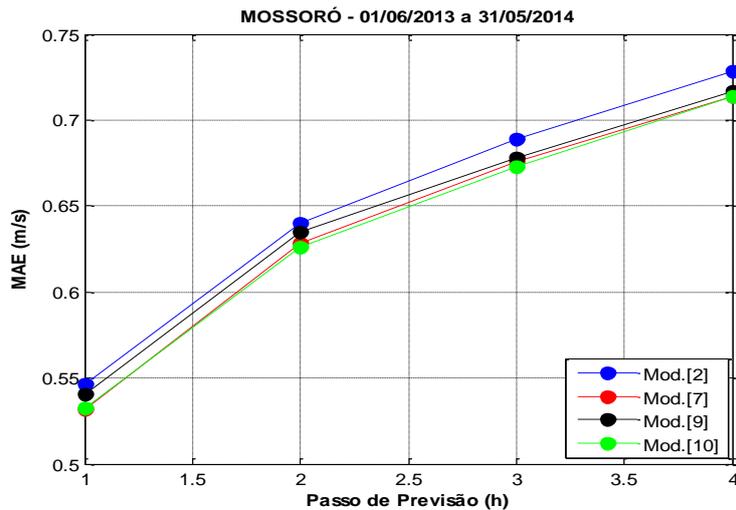


Figura 6.33 – MAE das previsões de velocidade em Mossoró utilizando ESN.

Para primeira hora de previsão, o experimento [7] apresenta melhor desempenho que o experimento [10], porém, para as horas seguintes de previsão até a hora quatro o experimento [10] consegue ser superior a todos os outros experimentos.

Os ganhos obtidos em relação ao método da *Persistência* pelos experimentos ao utilizarem o ESN foram bastante favoráveis, superiores a 50 % para o horizonte de previsão de até quatro horas.

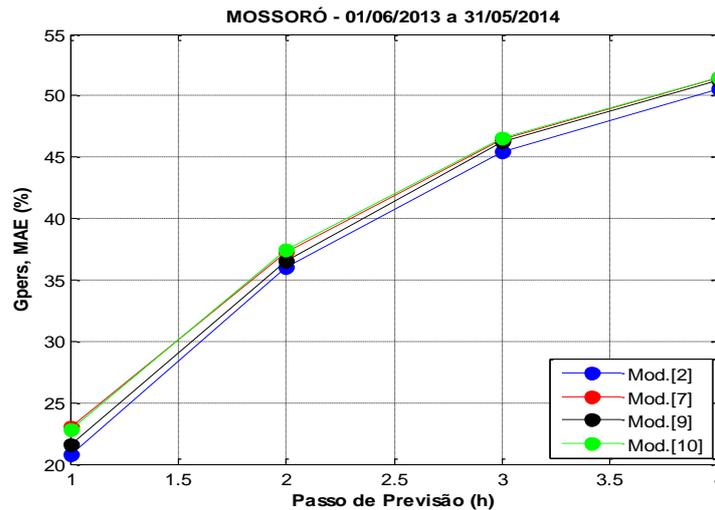


Figura 6.34 – Ganho das previsões de velocidade em Mossoró utilizando ESN.

6.5.4 Comparações Entre os Métodos de IA para o Sítio de MOSSORÓ

Ao comparar os diversos experimentos aplicados aos métodos de inteligência artificiais aqui propostos e ao método estatístico da *Persistência* é possível perceber a partir da análise da Figura 6.35 que os experimentos ao utilizarem o ESN obtiveram melhor desempenho quando comparado com os outros métodos. Isso foi percebido tanto para o experimento [2] como para o experimento [10].

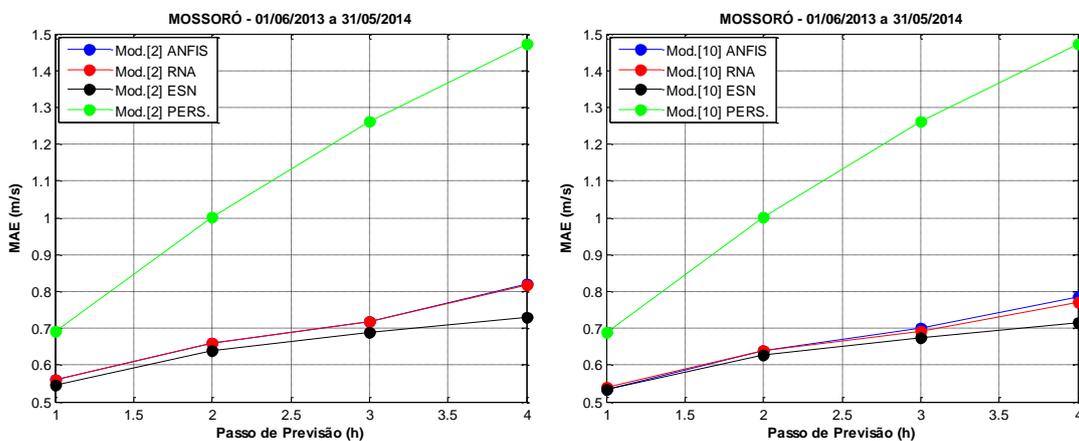


Figura 6.35 – MAE do experimento [2] e experimento [10] para o sítio de Mossoró.

CAPÍTULO 7

7. CONCLUSÕES E PROPOSTAS PARA TRABALHOS FUTUROS

7.1 Conclusões

Diversos modelos de previsão de velocidade de vento para o passo de previsão de uma até quatro horas foram desenvolvidos a partir da análise das séries temporais de velocidade de vento, altura das marés, temperatura instantânea, umidade do ar e radiação solar, através do uso de métodos de inteligência artificial.

A utilização de novas variáveis no desenvolvimento dos modelos possibilitou a avaliação destas, como alternativa ou até mesmo sua utilização concomitante com as séries de velocidade de vento. A escolha destas variáveis levou em consideração a avaliação dos coeficientes de autocorrelação e correlação. Para a altura das marés, que apresentou baixa correlação, a escolha foi em função de uma avaliação preliminar a fim de conhecer sua influência sobre a velocidade do vento.

As simulações apresentaram resultados bastante satisfatórios com a utilização de modelos multivariados aplicados aos métodos de inteligência artificial. Para os sítios de Petrolina e Ouricuri, os quais se caracterizam como de região seca, os modelos que continham radiação solar apresentaram desempenho superior aos modelos de umidade do ar. Em contraposição, os sítios de Natal, Macau e Mossoró, onde a umidade é maior que nas outras regiões, experimentaram desempenho superior no modelo de umidade do ar quando comparado com a radiação solar.

Comparando os ganhos obtidos com o modelo de referência é possível concluir que a metodologia utilizada foi eficiente, fornecendo previsões com boa confiabilidade e modelos com capacidade de generalização para dados que não lhe foram apresentados.

7.2 Propostas Para Trabalhos Futuros

Resultados satisfatórios foram obtidos, a partir da utilização de modelos multivariados na previsão de velocidade dos ventos de curto prazo. Logo, é importante destacar que a incansável busca pela mitigação dos erros de previsão provoca a evolução dos métodos utilizados e novos modelos podem vir a serem desenvolvidos. Como sugestão, os seguintes trabalhos futuros são propostos:

- Os dados de velocidade de vento utilizados neste texto são para a altura de 10 m, é importante que os dados fornecidos pelas torres anemométricas sejam aferidos na altura do rotor da turbina eólica, evitando as conversões de velocidade e retirando uma etapa de propagação do erro.
- Avaliar uma nova metodologia como forma de discretização horária das alturas das marés, visando minimizar o erro obtido no processo de interpolação senoidal.
- Utilizar os dados aferidos das médias horárias das alturas das marés como entrada dos modelos.
- Desenvolver modelos de previsões de ventos com horizontes maiores para estudos na região nordeste e no Brasil.
- Desenvolver modelos de previsão multivariados para horizontes de previsão de até 72 horas utilizando como ferramenta de inteligência artificial as ESN.

APÊNDICE A

A.1 – Coeficientes de Autocorrelações de Velocidade de Vento

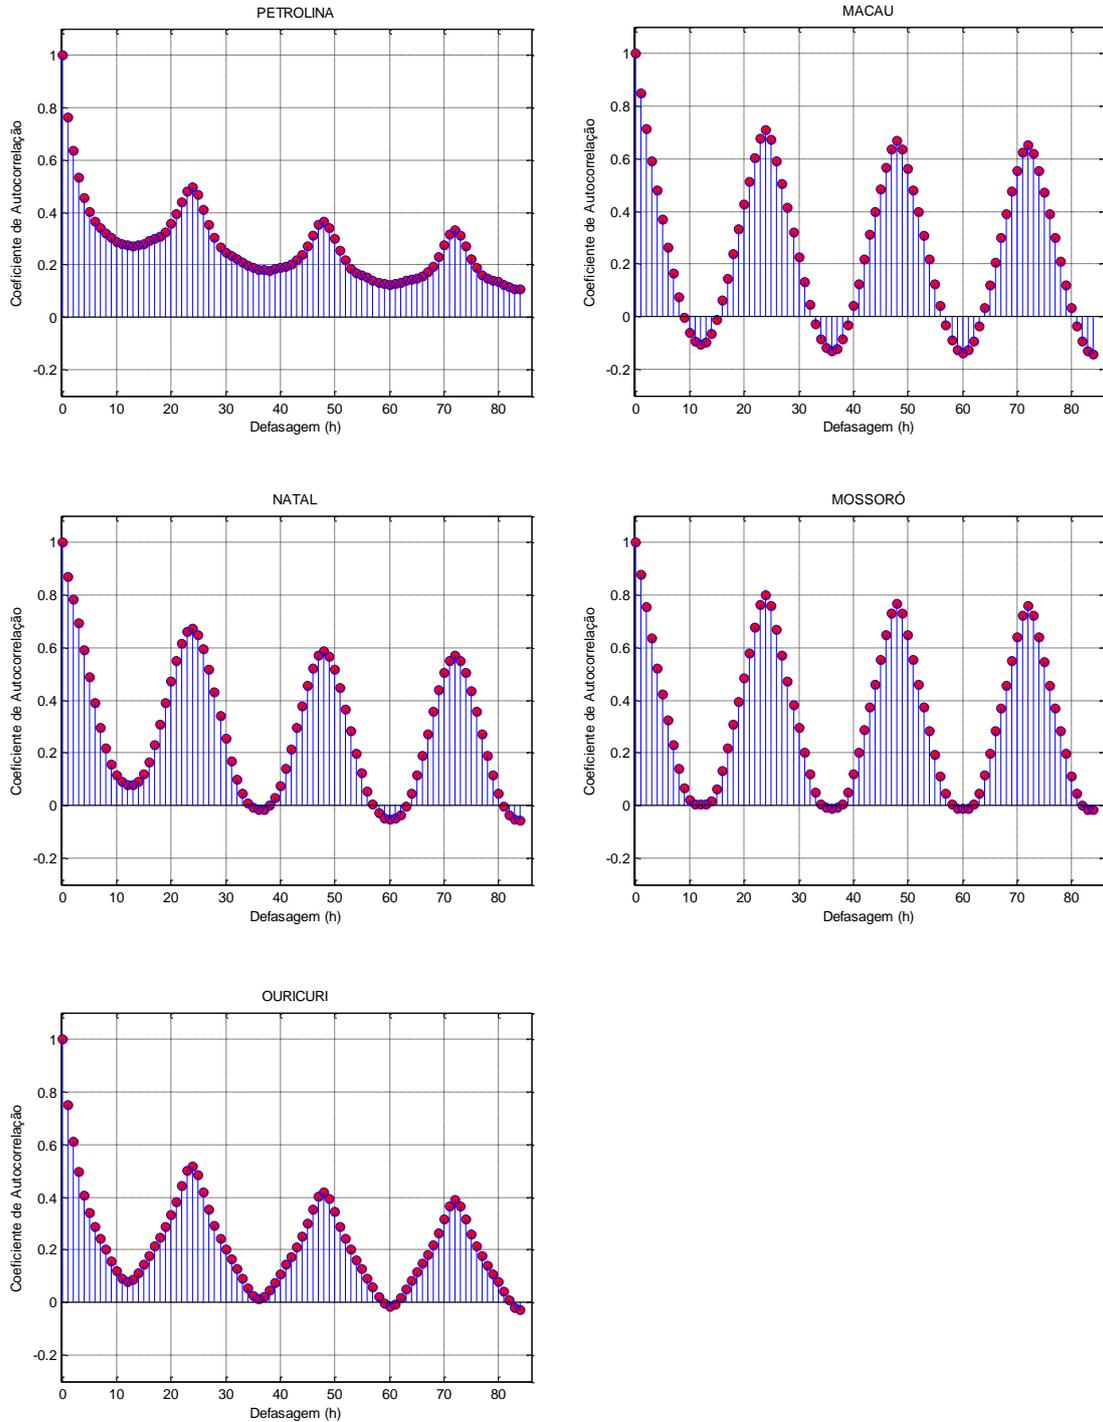


Figura A.1 – Coeficiente de autocorrelação.

A.2 – Correlação entre Velocidade de Vento e Temperatura

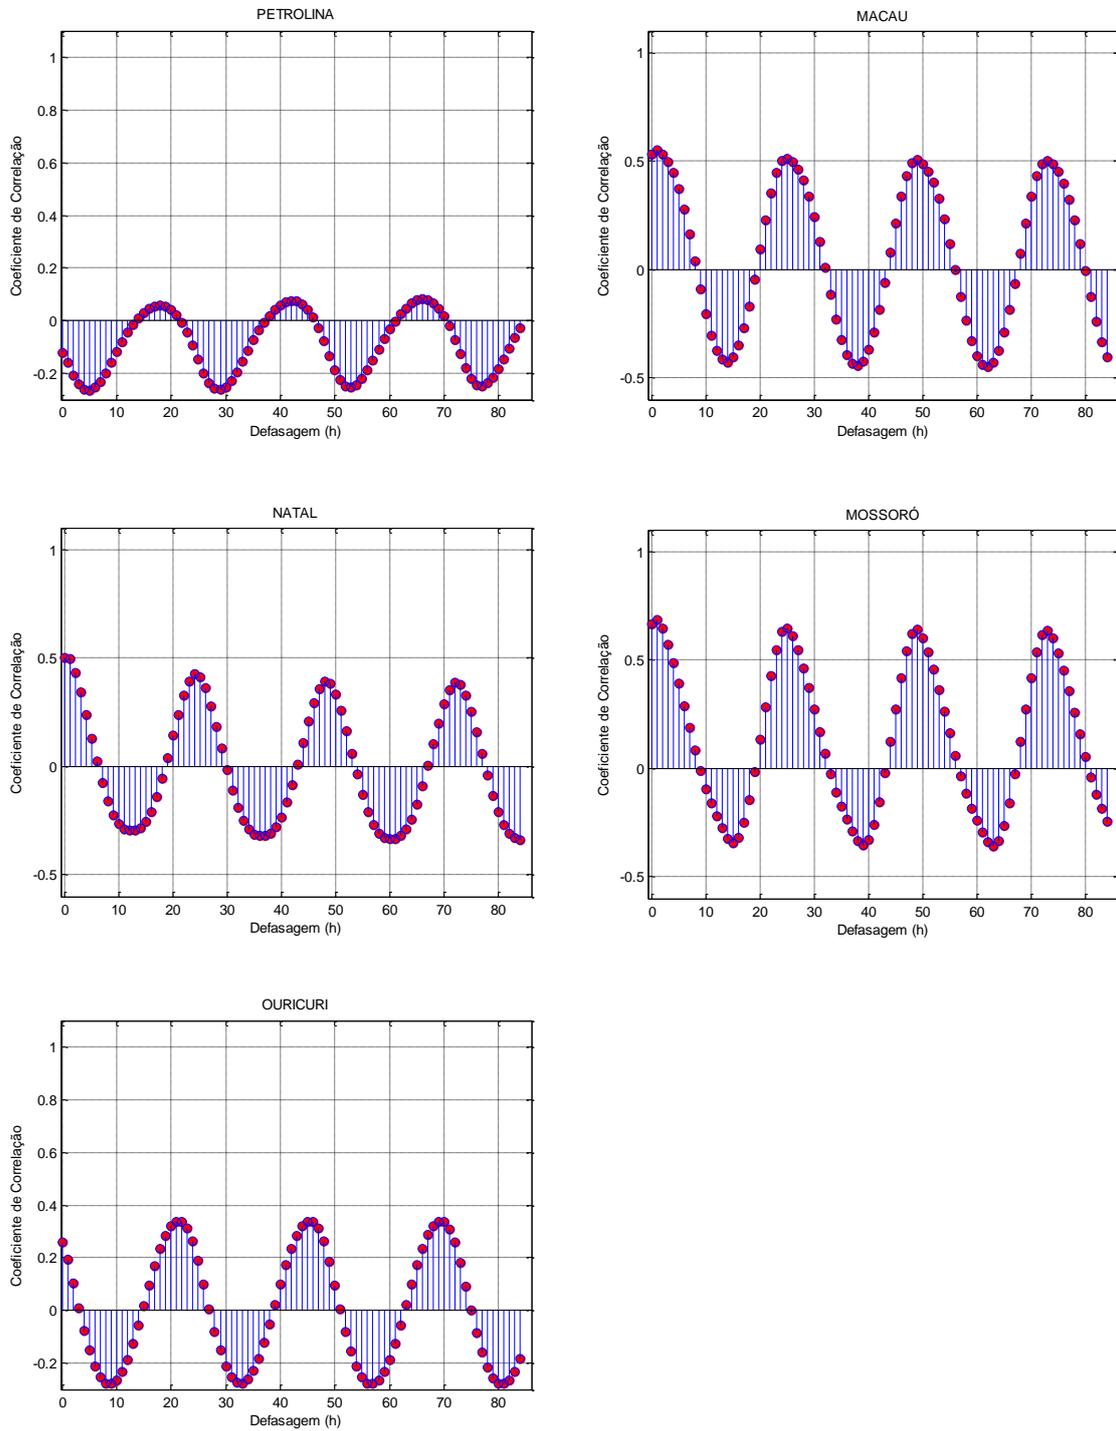


Figura A.2 – Coeficiente de correlação entre velocidade de vento e temperatura.

A.3 – Correlação entre Velocidade de Vento e umidade do Ar

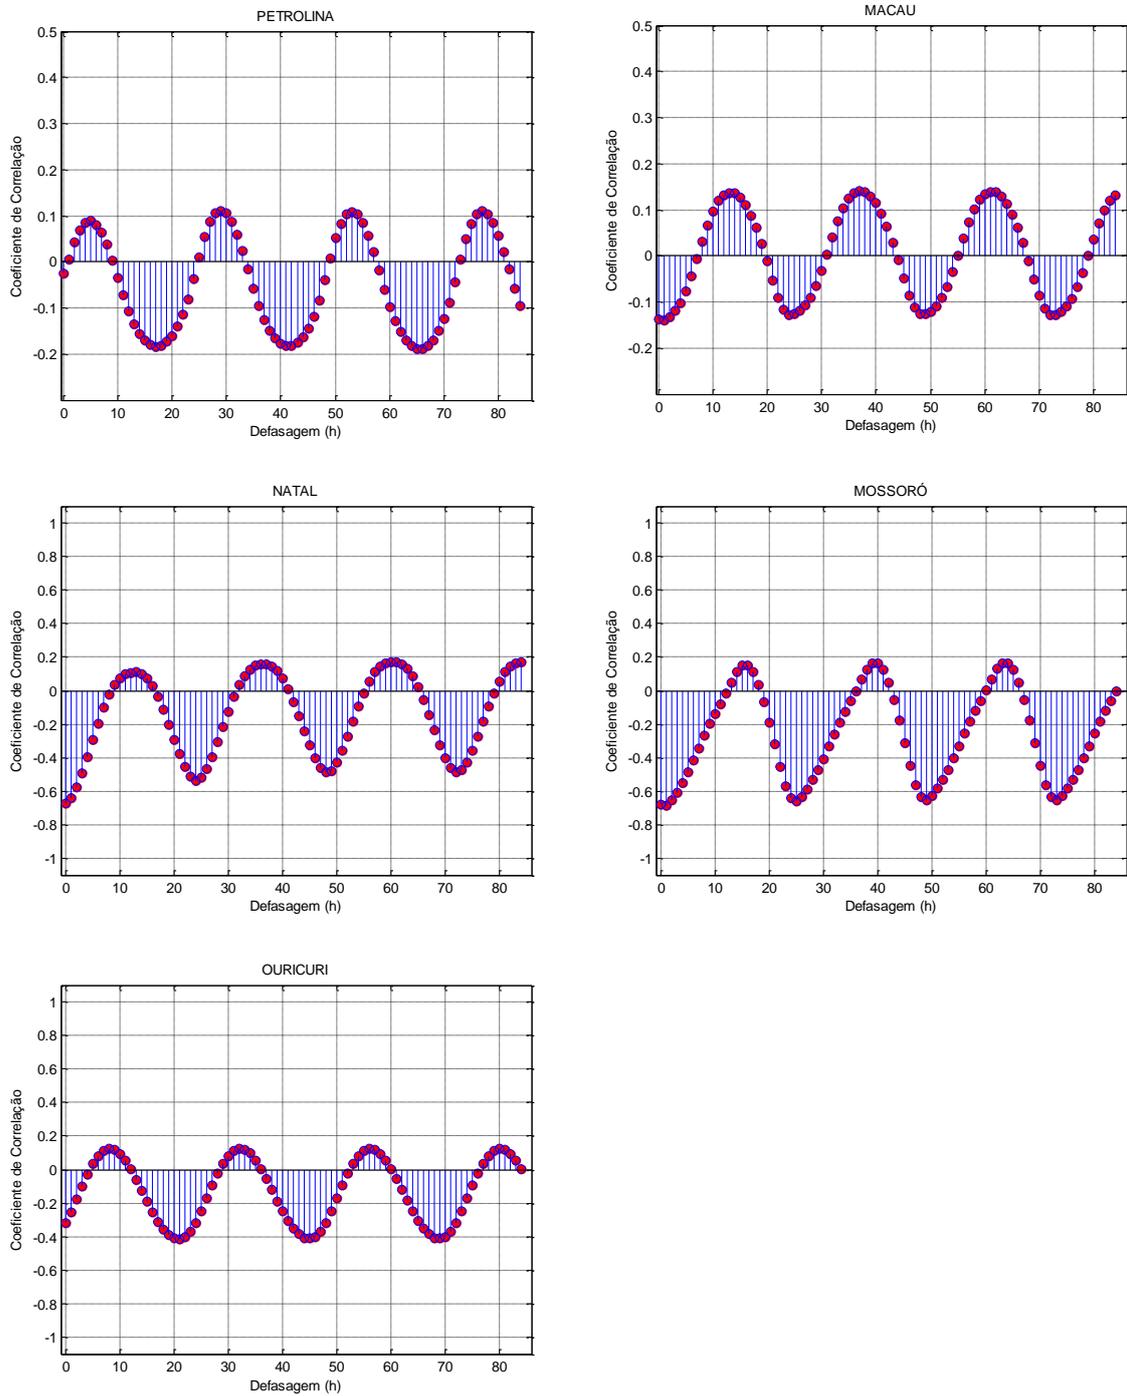


Figura A.3 – Coeficiente de correlação entre velocidade de vento e umidade do ar.

A.4 – Correlação entre Velocidade de Vento e Radiação Solar

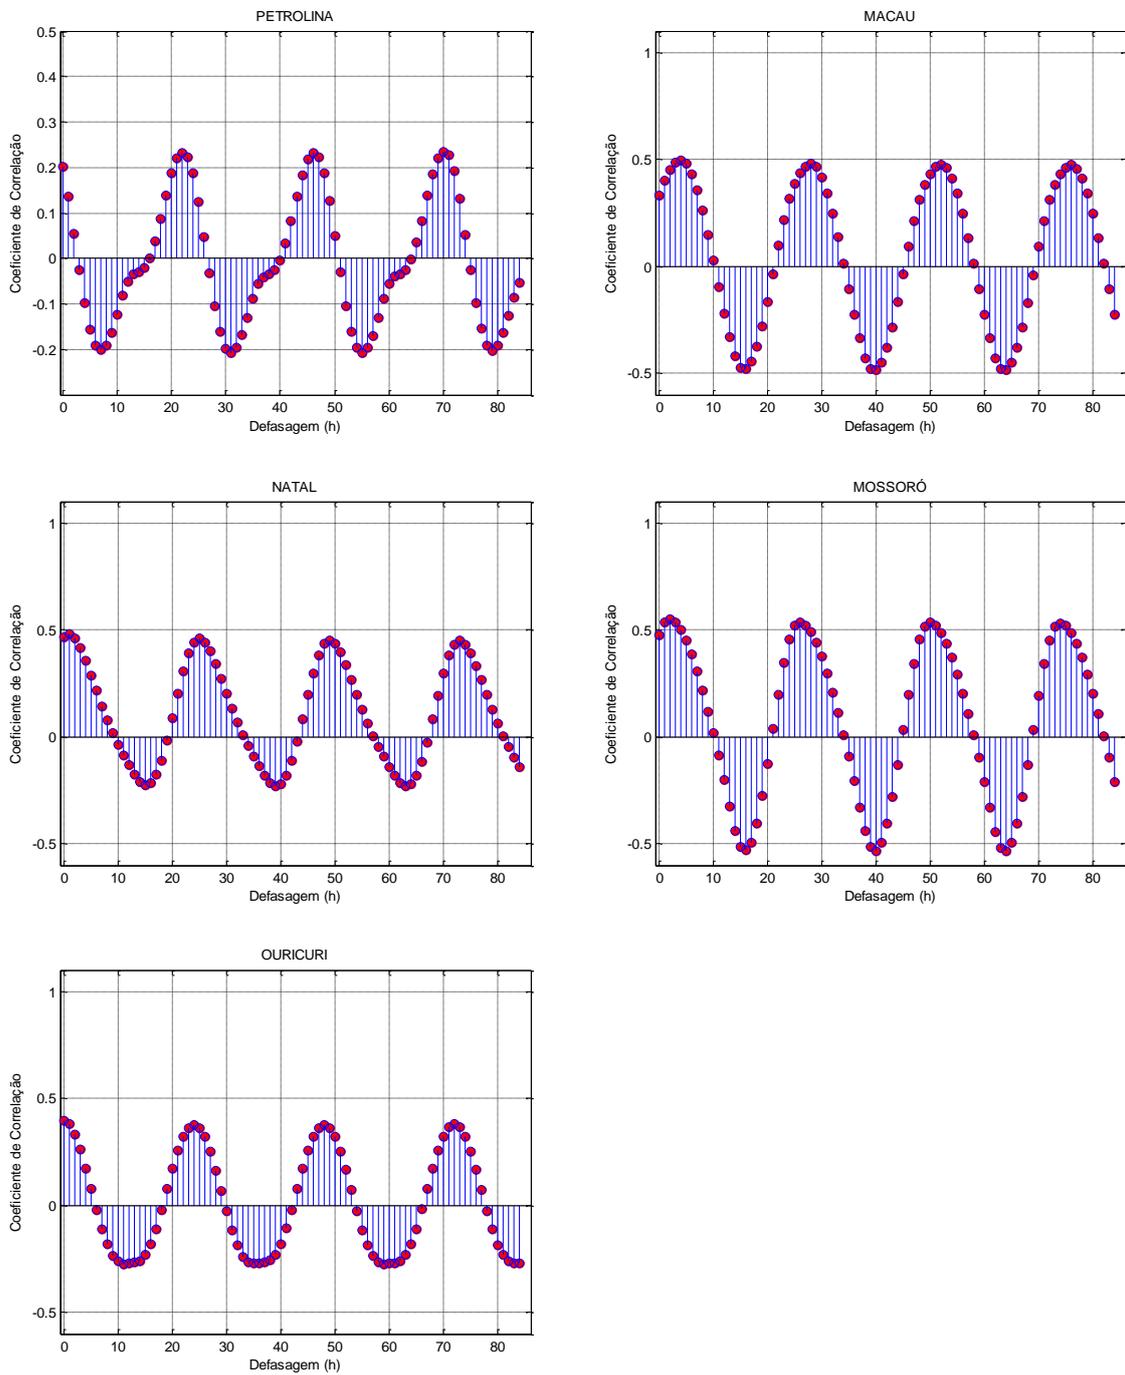


Figura A.4 – Coeficiente de correlação entre velocidade de vento e radiação solar.

A.5 – Correlação entre Velocidade de Vento e altura de marés

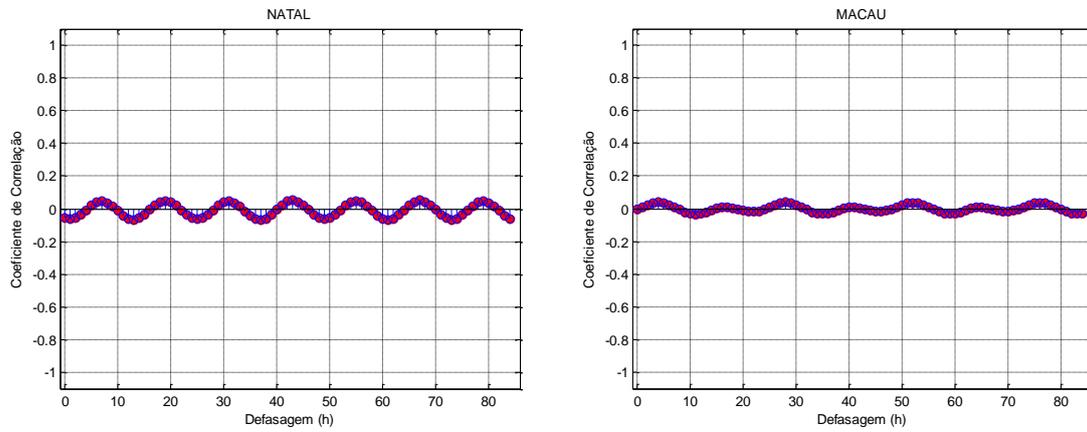


Figura A.5 – Correlação entre velocidade de vento e altura de maré.

REFERÊNCIAS

AFONSO MARQUES, A. C., **Comparação Entre Técnicas de Inteligência Artificial e Funções de Pedotransferência para Estimar a Condutividade Hidráulica Saturada de uma Área do Agreste Pernambuco**, 2º Seminário de Tese, Universidade Federal de Pernambuco, 2014.

AMARANTE, O. A. C., et al. **Atlas do Potencial Eólico Brasileiro**, Ministério de Minas e Energia, Eletrobrás, CEPEL, 2001.

Disponível: <http://www.cresesb.cepel.br/publicacoes/download/atlas_eolico/Atlas%20do%20Potencial%20Eolico%20Brasileiro.pdf>. Acesso em: 09 set. 2014.

ANDRADE GUERRA, J. B. S., et al. **Energias Renováveis: Energia Eólica**, Consórcio de Universidades Europeias e Latino-Americanas em Energias Renováveis-JELARE, Unisul, 2011. 53 p.

Disponível: http://youssefyoussef.wikispaces.com/file/view/energia_eolica.pdf

ANEEL, Agência Nacional de Energia Elétrica, Banco de Informações de Geração-Capacidade de Geração do Brasil.

Disponível: <<http://www.aneel.gov.br/aplicacoes/capacidadebrasil/capacidadebrasil.cfm>>. Acesso em: 09 set. 2014.

AQUINO, R. R. B. M. et al. Application of wavelet and neural network models for wind speed and power generation forecasting in a brazilian experimental wind park. In: **International Joint Conference on Neural Networks (IJCNN)**, Atlanta, 2009.

AQUINO, R. R. B. et al. Avaliação da Complementaridade Entre os Fluxos Hidrológico e Eólico na Região Nordeste. In: **XIII Congresso Brasileiro de Energia**, Rio de Janeiro, 2010.

AQUINO, Ronaldo. R. B., et al. Wind Forecasting and Wind Power Generation: Looking for the Best Model Based on Artificial Intelligence. In: **WCCI 2012. IEEE World Congress on Computational Intelligence**, 2012.

AQUINO, R. R. B.; LUDERMIR, T.; NÓBREGA N., O.; FERREIRA, A. A. ; LIRA, M. M. S. ; CARVALHO JR, M. A. Forecasting Models of Wind Power in Northeastern of Brazil. In: **International Joint Conference on Neural Networks**, pages. 1-6, 2013.

BISQUEIRA, R., MARTINEZ, F., SARRIERA, J.C. **Introdução à estatística**, 1ª ed. ARIMED, 2004. 256 p.

COSTA, A. et al. A review on the young history of the wind power short-term prediction. **Renewable & Sustainable Energy Reviews**. v. 12, n. 6, p. 1725-1744, 2008.

CUSTÓDIO, R. S., **Energia Eólica para Produção de Energia Elétrica**, Eletrobrás, 2009. ISBN: 8561325887

FERREIRA, A. A. LUDERMIR, T. B. Investigating the use of Reservoir Computing for forecasting the hourly wind speed in short -term, pages 1649-1656, **Neural Networks**, 2008.

FERREIRA A. A. and LUDERMIR T. B.. Using Reservoir Computing for Forecasting Time Series: Brazilian Case Study. **In International Conference on Hybrid Intelligent Systems-HIS 2008**, pages 602-607, Los Alamitos, CA, USA, 2008.

FERREIRA, A. A. **Desenvolvimento de Metodologia Para Design e Treinamento de Reservoir Computing Aplicado à Previsão de Séries Temporais**. 2011. 107 p. Tese (Doutorado em Ciência da Computação) - Universidade Federal de Pernambuco, Pernambuco, 2011.

GIEBEL, G.; KARINIOTAKIS, G.; BROWNSWORD, R. The State of the art in Short-Term Prediction of Wind Power-A Literature Overview. 36 p. 2003.

Disponível: <http://www.risoe.dk/rispubl/vea/veapdf/ANEMOS_giebel.pdf>. Acesso em: 09 set. 2014.

GLOBAL WIND REPORT: ANNUAL MARKET UPDATE 2013. 80 p. 2013.

Disponível: <http://www.gwec.net/wp-content/uploads/2014/04/GWEC-Global-Wind-Report_9-April-2014.pdf>. Acesso em: 09 set. 2014.

GOUVEIA, H. T. V. **Previsão de Ventos e Geração Eólica do Sistema NE: Analisando Diversos Sítios e Buscando a Melhor Modelagem Através da Inteligência Artificial**. 2011. 132 p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Pernambuco, Recife, 2011.

HAYKIN, Simon. **Redes neurais: princípios e prática**. 2ª ed. Porto Alegre: BOOKMAN, 2001.

JANG, J.R. ANFIS: Adaptive-Network-Based Fuzzy Inference System. **IEEE Transactions on Systems, Man and Cybernetics**, v. 23, n 3, p. 169-176, 1993.

KARINIOTAKIS, G. N., STAVRAKAKIS, G. S., NOGARET, E.F. Wind Power Forecasting Using Advanced Neural Networks Models. **IEEE Transactions on Energy Conversion**, vol. 11, n.4, pages 762-767, 1996.

KOSKO, B. **Fuzzy engineering**.. New Jersey: Prentice Hall, 1997. 549 p. ISBN 0-13-124991-6

LEITE, A. P. **MODELAGEM DE FAZENDAS EÓLICAS PARA ESTUDOS DE CONFIABILIDADE**. 2005. 151 p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2005.

LUDEMIR, Tereza. B., BRAGA, Antônio. P., CARVALHO, André. C. P. L. F. **Redes Neurais Artificiais: Teorias e Aplicações**. Rio de Janeiro: LTC, 2000.

MADDALA, G. S. **Introdução à Econometria**. Rio de Janeiro: LTC, 3ª ed. 2003.

MADSEN, H. et al. **A Protocol for Standardizing the Performance Evaluation of Short-term Wind Power Prediction Models**. 17 p. 2004.

Disponível: < http://hal-ensmp.archives-ouvertes.fr/docs/00/52/72/48/PDF/standardizing_-_00527248.pdf >. Acesso em: 09 set. 2014.

MILIGAN, M., SCHWARTZ, M., WAN, Y. **Statistical Wind Power Forecasting Models: Results for U.S Wind Farms**. **National Renewable Energy Laboratory**, 2003.

OLIVEIRA, J. B. **SISTEMAS INTELIGENTES E WAVELETS PARA PREVISÃO DE VENTO E GERAÇÃO EÓLICA**. 2008. 92 p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Pernambuco, Recife, 2005.

PAVINATTO, E. F. **Ferramenta para Auxílio à Análise de Viabilidade Técnica da Conexão de Parques Eólicos à Rede Elétrica**. 2005. 165 p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2005.

PROINFA, Programa de Incentivo às Fontes Alternativas de Energia Elétrica, Ministério das Minas e Energia, 2002.

Disponível em: <<http://www.mme.gov.br/programas/proinfa/>>. Acesso em: 09 set. 2014.

REZENDE, S. O. **Sistemas inteligentes: fundamentos e aplicações**. Barueri: Manole, 2005. 525 p. 2. ed. ISBN 85-204-1683-7.

SDAO, F., et al. **Landslide Susceptibility Assessment by Using a Neuro – Fuzzy Model: A Case Study in the Rupestrian Heritage Rich Area of Matera**. **Natural Hazards and Earth system Sciences**, p. 395-407, 2013.

SIDERATOS, G., HATZIARGYRIOU N. D. **An Advanced Statistical Method for Wind Power Forecasting**. **IEEE Transactions on Power Systems**, vol. 22, pages 258-265, 2007.

SILVA, R. G. **A Geração de Energia Maremotriz e Suas Oportunidades no Brasil**. **Revista Ciências do Ambiente**, vol. 8, 2012.