

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

JONATA CAMPELO DE ALBUQUERQUE

**AVALIAÇÃO DE CURVAS DE POTÊNCIA EM
MODELOS DE PREVISÃO DE GERAÇÃO EÓLICA
EM CURTO PRAZO**



Recife, Outubro de 2015.

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

**AVALIAÇÃO DE CURVAS DE POTÊNCIA EM
MODELOS DE PREVISÃO DE GERAÇÃO EÓLICA
EM CURTO PRAZO**

por

JONATA CAMPELO DE ALBUQUERQUE

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: OTONI NÓBREGA NETO, D.Sc.

COORIENTADOR: RONALDO RIBEIRO B. DE AQUINO, D.Sc.

Recife, Outubro de 2015.

© Jonata Campelo de Albuquerque, 2015.

Catálogo na fonte
Bibliotecária Margareth Malta, CRB-4 / 1198

A345a	<p>Albuquerque, Jonata Campelo de. Avaliação de curvas de potência em modelos de previsão de geração eólica em curto prazo / Jonata Campelo de Albuquerque. - Recife: O Autor, 2015. 125 folhas, il., gráfs., tabs.</p> <p>Orientador: Prof. Dr. Otoni Nóbrega Neto. Coorientador: Prof. Dr. Ronaldo Ribeiro Barbosa de Aquino. Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Elétrica, 2015. Inclui Referências.</p> <p>1. Engenharia Elétrica. 2. Previsão de geração eólica. 3. Análise de curvas de potência. 4. Inteligência artificial. 5. Redes neurais artificiais. 6. Sistemas de inferência Fuzzy. I. Nóbrega Neto, Otoni. (Orientador). II. Aquino, Ronaldo Ribeiro Barbosa de. (Coorientador). III. Título.</p> <p style="text-align: right;">UFPE</p> <p>621.3 CDD (22. ed.) BCTG/2015-299</p>
-------	--



Universidade Federal de Pernambuco

Pós-Graduação em Engenharia Elétrica

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

JONATA CAMPELO DE ALBUQUERQUE

TÍTULO

***“AVALIAÇÃO DE CURVAS DE POTÊNCIA EM MODELOS DE PREVISÃO
DE GERAÇÃO EÓLICA EM CURTO PRAZO”***

A comissão examinadora composta pelos professores: OTONI NÓBREGA NETO, DEE/UFPE, RONALDO RIBEIRO BARBOSA DE AQUINO, DEE/UFPE, MILDE MARIA DA SILVA LIRA, DEE /UFPE e BENEMAR ALENCAR DE SOUZA, DEE/UFPE, sob a presidência do primeiro, consideram o candidato **JONATA CAMPELO DE ALBUQUERQUE APROVADO.**

Recife, 23 de outubro de 2015.

CECILIO JOSÉ LINS PIMENTEL
Coordenador do PPGEE

OTONI NÓBREGA NETO
Orientador e Membro Titular Interno

BENEMAR ALENCAR DE SOUZA
Membro Titular Externo

RONALDO RIBEIRO BARBOSA DE AQUINO
Coorientador e Membro Titular Interno

MILDE MARIA DA SILVA LIRA
Membro Titular Interno

Dedico este trabalho a todos que acreditam nos seus objetivos e traçam os seus respectivos caminhos para atingi-los, não se intimidando pelas pedras que apareçam nestes traçados, e com isso chegam ao final de sua jornada sem passar por cima de ninguém.

AGRADECIMENTOS

Agradeço primeiramente a Deus pela humildade, paciência e inteligência concedidas, fatores primordiais para atingir qualquer meta discriminada na vida.

Agradeço a meus pais Ezequias e Sônia, por toda condição, apoio e compreensão prestados a mim desde o momento que nasci até hoje. *“Posso dizer que sou um privilegiado pelos pais que tenho”*.

Agradeço aos meus dois Orientadores, Prof. Ronaldo e Prof. Otoni pela oportunidade, por todo apoio, orientação, intuição, direcionamento e motivação cedidos para o desenvolvimento satisfatório deste trabalho. Além da Amizade e confiança dividida de forma coletiva entre todos nós.

Agradeço a Professora Milde pelo apoio e experiência com a Lógica Fuzzy, prestados sempre de forma muito gentil.

Agradeço ao Prof. Manoel Afonso, pela primeira oportunidade em trabalhar no grupo de pesquisa Laboratório Digital de Sistemas de Potência (LDSP), fomentando o interesse pela heurística no desenvolvimento de Técnicas e artifícios que contribuem para o avanço da Engenharia Elétrica na Universidade Federal de Pernambuco.

Agradeço ao Grupo do Laboratório Digital de Sistemas de Potência (LDSP) e a todos os seus professores membros, contribuindo sempre com o repasse de conhecimento ao longo da minha vida acadêmica.

Agradeço ao Conselho Nacional de Desenvolvimento Tecnológico (CNPQ) pela bolsa de estudos oferecida.

Agradeço a todos os meus amigos que me apoiaram de alguma forma ao longo do desenvolvimento deste trabalho.

*“Se pudéssemos primeiro saber onde estamos e para onde estamos sendo levados,
poderíamos julgar melhor o que fazer, e como fazê-lo”.*

(Abraham Lincoln)

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

AVALIAÇÃO DE CURVAS DE POTÊNCIA EM MODELOS DE PREVISÃO DE GERAÇÃO EÓLICA EM CURTO PRAZO

Jonata Campelo de Albuquerque

Outubro/2015

Orientador: Otoni Nóbrega Neto, D.Sc.

Coorientador: Ronaldo Ribeiro Barbosa de Aquino, D.Sc.

Área de Concentração: Processamento de Energia.

Palavras-chave: Previsão de Geração Eólica, Análise de Curvas de Potência, Inteligência Artificial, Redes Neurais Artificiais, Sistemas de Inferência Fuzzy.

Número de Páginas: 125.

RESUMO: Nesta dissertação se propõe modelos de previsão de geração eólica baseados em técnicas de Inteligência Artificial (IA), tais como aplicações de Redes Neurais Artificiais (RNAs) e Sistemas de Inferência Fuzzy (SIFs). Tais previsões foram realizadas de forma horária, sendo os horizontes de 1h à 24h, classificando os modelos como previsores de curto prazo. Arelada à presciência respectiva de cada modelo de entrada, estão as predições de velocidades médias ou velocidades médias e direções médias do vento. Estas são utilizadas como entradas para modelos de curva de potência dos parques eólicos em análise, nos quais dependendo do modelo em questão, esta poderá ser uma RNA ou um SIF. Tal aplicação é feita para dois parques reais descritos ao longo deste trabalho. Ao fim, faz-se uma comparação entre tais modelos, na qual o desempenho obtido revela-se bastante competitivo em termos de acurácia nas previsões de geração eólica dos SIFs em relação às RNAs.

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

POWER CURVES EVALUATION IN SHORT TERM WIND POWER PREDICTION MODELS

Jonata Campelo de Albuquerque

October/2015

Supervisor: Otoni Nóbrega Neto, D.Sc.

Co-Supervisor: Ronaldo Ribeiro Barbosa de Aquino, D.Sc.

Area of Concentration: Energy Processing.

Keywords: Wind Power Prediction, Power Curves Evaluation, Artificial Intelligence, Artificial Neural Networks, Fuzzy Inference System.

Number of Pages: 125.

ABSTRACT: This paper proposes and develops models for wind power prediction, based on Artificial Intelligence concepts with regard to ANN applications (Artificial Neural Networks) and FIS (Fuzzy Inference System). Such models have application time horizon, which is 24 hours, which is why the models are short term denominated. Linked to their foreknowledge of each model are predictions of medium and / or medium speeds directions, which serve as input for a specific power curve of the park in question. Where depending on the model in question, it may be an artificial neural network or Fuzzy inference block, such a study is made for two typical parks described throughout this work. At the end, makes a comparison between these models showing the highly competitive performance in terms of power efficiency in predictions, the Fuzzy inference blocks in relation to neural networks.

Sumário

LISTA DE FIGURAS.....	xi
LISTA DE TABELAS.....	xv
LISTA DE ACRÔNIMOS.....	xvii
CAPÍTULO 1.....	21
1 Introdução	21
1.1 Considerações Iniciais	21
1.2 Objetivos	22
1.3 Citações e pontos de vistas importantes adotados nas referências	23
1.4 Organização estrutural da dissertação	27
CAPÍTULO 2.....	29
2 Conversão Eletromecânica da Energia	29
2.1 Processo de conversão e suas partes constituintes	29
2.1.1 Pás ou Lâminas	29
2.1.2 Controladores aerodinâmicos (“Pitch” ou “Stall”)	30
2.1.3 Caixa de Marchas (caixa conversora de velocidades)	32
2.1.4 Freio mecânico do Rotor	32
2.1.5 Gerador Elétrico	33
2.1.6 Controlador rotacional de posição Horizontal (Yaw)	34
2.1.7 Torre	34
2.1.8 Turbina	34
2.2 Curva de Potência	38
2.2.1 Controlador de potência máxima utilizando rastreamento pontual na curva de potência	40
CAPÍTULO 3.....	43
3 Ferramentas de inteligência artificial	43
3.1 Redes Neurais	43
3.1.1 Modelo de Neurônio Artificial	44
3.1.2 Função de Ativação	45
3.1.3 Topologia de Rede Neural Artificial	47
3.1.4 O algoritmo Backpropagation	48

3.1.5	Algoritmo de Levenberg Marquardt (LM)	49
3.1.6	Algoritmo Resilient Propagation (RP)	51
3.2	Lógica de Inferência Fuzzy	53
3.2.1	Sistema de Inferência Mamdani	55
CAPÍTULO 4		57
4	Modelos Desenvolvidos	57
4.1	Criação, construção e adequação do banco de dados responsável pela alimentação dos modelos	57
4.2	Modelos baseados em RNAs	66
4.2.1	Modelo M1a de previsão de potência	66
4.2.2	Modelo M2a de previsão de potência	74
4.3	Modelos baseados em lógica Fuzzy	83
4.3.1	Modelo M1b de previsão de potência	84
4.3.2	Modelo M2b de previsão de potência	91
CAPÍTULO 5		101
5	Análise dos resultados e comparações entre os modelos	101
5.1	Série Temporal	101
5.1.1	Previsão de séries temporais	101
5.1.2	Coefficiente de correlação e autocorrelação	102
5.2	Comparação com o Método da Persistência	103
5.3	Comparação pelos Erros de Previsão	104
5.4	Critérios para Comparação dos Modelos	104
5.5	(1ª Etapa) Análise intermediária dos modelos previsores	105
5.6	(2ª Etapa) Análise na saída dos modelos previsores e Comparação entre os modelos	109
CAPÍTULO 6		118
6	Conclusões e Propostas para trabalhos futuros	118
6.1	Conclusões	118
6.2	– Propostas para trabalhos futuros.	119
REFERÊNCIAS BIBLIOGRÁFICAS		121

LISTA DE FIGURAS

Figura 2. 1 - <i>Princípio de conversão de energia cinética em mecânica rotacional nas pás de um aerogerador.</i>	30
Figura 2. 2 - <i>Princípio de funcionamento de um controlador Pitch.</i>	31
Figura 2. 3 - <i>Princípio de funcionamento de um controlador Stall.</i>	32
Figura 2. 4 - <i>Acoplagem de um aerogerador a um sistema elétrico.</i>	33
Figura 2. 5 - <i>Respectivamente da esquerda para a direita, turbina de eixo horizontal e turbina de eixo vertical (Darrieus).</i>	36
Figura 2. 6 - <i>Componentes principais de aerogerador (Foto: Bosh Rexroth AG).</i>	36
Figura 2. 7 - <i>Demonstração qualitativa de uma curva de potência.</i>	39
Figura 2. 8 - <i>Controlador de Potência a rastreamento pontual.</i>	41
Figura 3. 1 - <i>Modelo de um Neurônio Artificial (LIMA et. al.2009).</i>	44
Figura 3. 2 - <i>Gráfico da função Sigmoide Logística.</i>	46
Figura 3. 3 - <i>Gráfico da função Tangente Hiperbólica.</i>	47
Figura 3. 4 - <i>Rede alimentada adiante com três camadas de neurônios.</i>	48
Figura 3. 5 - <i>Exemplo de funções de pertinência.</i>	53
Figura 3. 6 - <i>Exemplo de funções de pertinência.</i>	54
Figura 3. 7 - <i>Fluxograma conceitual do sistema Fuzzy.</i>	54
Figura 4. 1 - <i>Curvas de potência do Parque 01 em análise posterior à filtragem.</i>	61
Figura 4. 2 - <i>Curva de potência do Parque 02 em análise posterior à filtragem.</i>	61
Figura 4. 3 - <i>Distribuição histórica da Velocidade média (a) no Parque 01 e (b) no Parque 02.</i>	62
Figura 4. 4 - <i>Distribuição histórica da Direção média (a) no Parque 01 e (b) no Parque 02.</i>	62
Figura 4. 5 - <i>Distribuição histórica da Potência média (a) no Parque. 01 e (b) no Parque 02</i>	63
Figura 4. 6 - <i>Arquitetura de construção do modelo M1a.</i>	67
Figura 4. 7 - <i>Arquitetura da melhor RNA1 para o Parque 01 escolhida com a execução dos treinamentos.</i>	69

Figura 4. 8 - <i>Arquitetura da melhor RNA1 para o Parque 02 escolhida com a execução dos treinamentos.</i>	69
Figura 4. 9 - <i>Comportamento gráfico do MAE referente às simulações para o período de aprendizagem da RNA1 (a) aplicado ao Parque 01 e (b) aplicado ao Parque 02.</i>	70
Figura 4. 10 - <i>Arquitetura da melhor CP-RNAM1a para o Parque 01 escolhida com a execução dos treinamentos.</i>	72
Figura 4. 11 - <i>Arquitetura da melhor CP-RNAM1a para o Parque 02 escolhida com a execução dos treinamentos.</i>	73
Figura 4. 12 - <i>Comparação entre o histórico e a curva CP-RNAM1a treinada pelo modelo M1a (a) para o Parque 01e (b) para o Parque 02.</i>	73
Figura 4. 13 - <i>Comportamento gráfico do MAE referente às simulações para o período de aprendizagem da CP-RNAM1a aplicado em (a) para Parque 01 e em (b) para o Parque 02.</i>	74
Figura 4. 14 - <i>Arquitetura de construção do modelo M2a.</i>	75
Figura 4. 15 - <i>Arquitetura da melhor RNA2 para o Parque 01 escolhida com a implementação dos treinamentos.</i>	77
Figura 4. 16 - <i>Arquitetura da melhor RNA2 para o Parque 02 escolhida com a implementação dos treinamentos.</i>	77
Figura 4. 17 - <i>Comportamento gráfico do MAE da velocidade média referente às simulações para o período de aprendizagem da RNA2 aplicado em (a) para Parque 01 e em (b) para o Parque 02.</i>	78
Figura 4. 18 - <i>Comportamento gráfico do MAE da direção média referente às simulações para o período de aprendizagem da RNA2 aplicado em (a) para Parque 01 e em (b) para o Parque 02.</i>	78
Figura 4. 19 - <i>Gráfico de correlação entre a velocidade média e a direção média, relativas ao banco de dados do Parque01.</i>	80
Figura 4. 20 - <i>Gráfico de auto correlação da velocidade média, relativa ao banco de dados do Parque01.</i>	80
Figura 4. 21 - <i>Arquitetura da melhor CP-RNAM2a para o Parque 01 escolhida com a execução dos treinamentos.</i>	82
Figura 4. 22 - <i>Arquitetura da melhor CP-RNAM2a para o Parque 02 escolhida com a execução dos treinamentos.</i>	82

Figura 4. 23 - Comparação entre o histórico e a curva CP-RNAM2a treinada pelo modelo M2a aplicada em (a) para o Parque 01 e em (b) para o Parque 02.	83
Figura 4. 24 - Comportamento gráfico do MAE referente às simulações para o período de aprendizagem da CP-RNAM2a aplicado em (a) para o Parques01 e em (b) para o Parque 02.	83
Figura 4. 25 - Arquitetura de construção do modelo M1b.	85
Figura 4. 26 - Arquitetura do SIF Fuzzy, Mamdani, referente a CPFuzzyM1b.	86
Figura 4. 27 - Comportamento das funções de pertinência das entradas (Velocidades Médias de vento) nas respectivas regiões abordadas, dos Parques, 01(a) e 02(b).	88
Figura 4. 28 - Comportamento das funções de pertinência das saídas (Potências Médias de vento) nas respectivas regiões abordadas, dos Parques, 01(a) e 02(b).	88
Figura 4. 29 - Comportamento da CP-FuzzyM1b discriminado pelo SIF de inferência Fuzzy, dos Parques, 01(a) e 02(b).	90
Figura 4. 30 - Comportamento gráfico do MAE referente às simulações para o período de aprendizagem da CP-FuzzyM1b aplicado aos Parques01 (a) e 02 (b).	91
Figura 4. 31 - Arquitetura de construção do modelo M2b.	91
Figura 4. 32 - Arquitetura do SIF, Mamdani, referente à CP-FuzzyM2b.	93
Figura 4. 33 - Comportamento individual das variáveis de entrada em relação a variável de saída do SIF Mamdani referente à CP-FuzzyM2b para o Parque 01, mostrando a relação [Velocidade x Potência] (a) e [Direção x Potência] (b).	94
Figura 4. 34 - Comportamento individual das variáveis de entrada em relação a variável de saída do SIF Mamdani referente à CP-FuzzyM2b para o Parque 02, mostrando a relação [Velocidade x Potência] (a) e [Direção x Potência] (b).	94
Figura 4. 35 - Comportamento das funções de pertinência da entrada 1 (Velocidade média do vento) nas respectivas regiões abordadas dos Parques, 01(a) e 02(b).	97
Figura 4. 36 - Comportamento das funções de pertinência da entrada 2 (Direção média do vento) nas respectivas regiões abordadas dos Parques, 01(a) e 02(b).	97
Figura 4. 37 - Comportamento das funções de pertinência da saída nas respectivas regiões abordadas dos Parques, 01(a) e 02(b).	98
Figura 4. 38 - Comportamento da curva de potência do modelo M2b discriminado pelo SIF (CP-FuzzyM2b) dos Parques, 01(a) e 02(b).	100
Figura 4. 39 - Comportamento gráfico do MAE referente às simulações para o período de aprendizagem da CP-FuzzyM2b aplicado aos Parques01 (a) e 02 (b).	100

Figura 5. 1 - <i>Comparação entre os MAE das previsões de velocidade média cometidos pela RNA1, pela RNA2 e pelo Método da persistência para os Parques 01 (a) e 02 (b).</i>	108
Figura 5. 2 - <i>Comparação entre os MAEs das previsões de direção média cometidos pela RNA2 e pelo Método da persistência para os Parques 01 (a) e 02 (b).</i>	108
Figura 5. 3 - <i>Comparação entre os MAE das previsões de Potência Média cometidos pelos modelos M1a, M1b, M2a, M2b e pelo Modelo da Persistência para os Parques 01 (a) e 02 (b).</i>	113
Figura 5. 4 - <i>Comparação entre os NMAE das previsões de Potência Média cometidos pelos modelos M1a, M1b, M2a, M2b para os Parques 01 (a) e 02 (b).</i>	113

LISTA DE TABELAS

Tabela 2. 1 - <i>Comparação entre turbinas de eixo horizontal e eixo vertical.</i>	34
Tabela 2. 2 - <i>Coeficiente de rugosidade para diversos tipos de terreno.</i>	38
Tabela 4. 1 - <i>Bases dos parques após filtragem.</i>	62
Tabela 4. 2 - <i>Divisão dos padrões de alimentação dos modelos.</i>	63
Tabela 4. 3 - <i>Forma do padrão de alimentação dos modelos.</i>	64
Tabela 4. 4 - <i>Estrutura do campo Cod.Data do 1º elemento previsto com 5 dígitos.</i>	64
Tabela 4. 5 - <i>Estrutura do campo Cod.Data do 1º elemento previsto com 3 dígitos.</i>	65
Tabela 4. 6 - <i>Intervalos das variáveis de entradas e saídas por faixa das Regiões da CP-FuzzyM1b, para o Parque 01.</i>	87
Tabela 4. 7 - <i>Intervalos das variáveis de entradas e saídas por faixa das Regiões da CP-FuzzyM1b, para o Parque 02.</i>	87
Tabela 4. 8 - <i>Listas de Regras utilizadas na modelagem da CP-FuzzyM1b, para o Parque 01.</i>	89
Tabela 4. 9 - <i>Listas de Regras utilizadas na modelagem da CP-FuzzyM1b, para o Parque 02.</i>	89
Tabela 4. 10 - <i>Funções de Pertinência disponibilizadas pelo Matlab.</i>	95
Tabela 4. 11 - <i>Intervalos da entrada 1 por faixa das Regiões da CP-FuzzyM2b, para o Parque 01.</i>	95
Tabela 4. 12 - <i>Intervalos da entrada 1 por faixa das Regiões da CP-FuzzyM2b, para o Parque 02.</i>	95
Tabela 4. 13 - <i>Intervalos da entrada 2 por faixa das Regiões da CP-FuzzyM2b, para o Parque 01.</i>	96
Tabela 4. 14 - <i>Intervalos da entrada 2 por faixa das Regiões da CP-FuzzyM2b, para o Parque 02.</i>	96
Tabela 4. 15 - <i>Intervalos da saída por faixa das Regiões da CP-FuzzyM2b, para o Parque 01.</i>	96
Tabela 4. 16 - <i>Intervalos da saída por faixa das Regiões da CP-FuzzyM2b, para o Parque 02.</i>	97
Tabela 4. 17 - <i>Listas de Regras utilizadas na modelagem da CP-FuzzyM2b, Parque 01.</i> .	99
Tabela 4. 18 - <i>Listas de Regras utilizadas na modelagem da CP-FuzzyM2b, Parque 02.</i> .	99
Tabela 5. 1 - <i>Coeficiente de correlação.</i>	102
Tabela 5. 2 - <i>Desempenho das previsões no período de Simulação das redes (RNA1 e RNA2) para o Parque 01.</i>	106
Tabela 5. 3 - <i>Desempenho das previsões no período de Simulação das redes (RNA1 e RNA2) para o Parque 02.</i>	107
Tabela 5. 4 - <i>Desempenho das previsões no período de Simulação dos modelos previsores (M1a, M1b, M2a e M2b) para o Parque 01.</i>	110
Tabela 5. 5 - <i>Desempenho das previsões no período de Simulação dos modelos previsores (M1a, M1b, M2a e M2b) para o Parque 02.</i>	110
Tabela 5. 6 - <i>Desempenho das previsões no período de Simulação dos modelos previsores (M1a, M1b, M2a e M2b) para o Parque 01.</i>	111

Tabela 5. 7 - <i>Desempenho das previsões no período de Simulação dos modelos previsores (M1a, M1b, M2a e M2b) para o Parque 02.</i>	112
Tabela 5. 8 – <i>Ganhos Médios horários percentuais das previsões realizadas no Parque 01</i>	116
Tabela 5. 9 - <i>Ganhos Médios horários percentuais das previsões realizadas no Parque 02</i>	116

LISTA DE ACRÔNIMOS

ANEEL	Agência Nacional de Energia Elétrica
Cj.trn	Conjunto de treinamento
Cj.vld	Conjunto de validação
Cj.tst	Conjunto de teste
Cj.sim	Conjunto de simulação
CP-FuzzyM1b	SIF simulador da curva de potência no modelo M1b
CP-FuzzyM2b	SIF simulador da curva de potência no modelo M2b
CP-RNAM1a	RNA simuladora da curva de potência no modelo M1a
CP-RNAM2a	RNA simuladora da curva de potência no modelo M2a
dir	Direita
EPSO	Otimização evolucionária por enxame de partículas
esq	Esquerda
FIS	<i>Fuzzy Inference System</i>
IA	Inteligência Artificial
IEA	<i>International Electric Association</i>
IEC	<i>International Electrotechnical Commission</i>
ITL	<i>Information Theoretic Learning</i>
kW	Quilowatt
LM	Levenberg Marquardt
M1a	Modelo 1a de previsão de Potência Ativa média horária
M1b	Modelo 1b de previsão de Potência Ativa média horária
M2a	Modelo 2a de previsão de Potência Ativa média horária
M2b	Modelo 2b de previsão de Potência Ativa média horária
MLP	<i>Multi Layer Perceptron</i>
MW	Megawatt
MAE	<i>Mean absolute error</i>
MAPE	<i>Mean absolute percentual error</i>
MSE	<i>Mean squared error</i>
NaN	<i>Not a number</i>
NMAE	<i>Normalized mean absolute error</i>
PROINFA	Programa de Incentivo às Fontes Alternativas de Energia Elétrica.

RNA	Rede Neural Artificial
RNA1	RNA integrante dos modelos M1a e M1b
RNA2	RNA integrante dos modelos M2a e M2b
RMS	<i>Root Mean Squared</i>
RP	<i>Resilient Propagation</i>
SCEE	Sistema de Conversão de Energia Eólica
SIN	Sistema Interligado Nacional
TKS	Takagi-Sugeno-Kang
UFPE	Universidade Federal de Pernambuco
UTC	<i>Coordinated Universal Time</i>
a	Parâmetro de inclinação da função sigmoide logística
A	Área da seção transversal varrida pelo rotor
A_j	Variáveis linguísticas de entrada
b_k	<i>Bias</i>
B_i	Variáveis linguísticas de saída
C_P	Coefficiente de potência do rotor
d_j	Saída desejada
$d(t)$	Direção média de vento no passo t
$d(t - 1)$	Direção média de vento anterior ao passo t
$\hat{d}(t + 1)$	Direção média de vento prevista para o passo $t + 1$
$D^{(k)}$	Coefficiente de disparo
e_j	Erro na saída do neurônio
E	Energia cinética
f_s	Frequência elétrica nominal do estator do gerador elétrico em Hz.
$f(K)$	Função Gaussiana
$F_{w,nominal}$	Força de sustentação nominal da Pá
$F_{w,Stall}$	Força de <i>Stall</i> na Pá
g	Múltiplo do desvio padrão
h	Hora no UTC
i	Índice do i -ésimo elemento sobre análise
h_1	Altura da medição velocidade conhecida
h_2	Altura pretendida para velocidade estimada

H_m	Elevação do local
j	Índice do j-ésimo elemento sobre análise
k	Índice do k-ésimo elemento sobre análise
K	Balizador amostral
m	Massa de ar
n	número de termos da série em análise
$Mês_{Cosseno}(t + 1)$	Mês distribuído de forma cossenoidal
$Mês_{Senoidal}(t + 1)$	Mês distribuído de forma senoidal
n_m	Velocidades das pás do aerogerador em RPM.
n_M	Velocidade do gerador elétrico em RPM.
$N(\mu, \sigma^2)$	Distribuição Normal
p	Número de pares de pólos do gerador elétrico.
p_{w1}	Pressão na região acima da pá
p_{w2}	Pressão na região abaixo da pá
P_{mec}	Potência mecânica
$\hat{P}(t + 1)$	Previsão da potência ativa média para geração do parque eólico
r_{gb}	Fator de relação de velocidades.
s	Relação percentual de escorregamento entre as velocidades n_m e n_M .
S	Variável de tabulação aplicada a uma distribuição Normal
t	Passo temporal da série histórica
u_k	Saída do combinador linear
v	Velocidade do vento
v_0	Velocidade do vento na altura conhecida
$v(h)$	Velocidade do vento na altura h
$v_{nominal}$	Velocidade nominal da pá
v_{w1}	Velocidade de vento superior (acima da pá)
v_{w2}	Velocidade de vento inferior (abaixo da pá)
$v(t)$	Velocidade média de vento no passo t
$v(t - 1)$	Velocidade média de vento no passo anterior ao passo t
$\hat{v}(t + 1)$	Velocidade média de vento prevista para o passo $t + 1$

v_k, v_j	Campo local induzido
$w_{kj}, w_{ji}(n)$	Pesos sinápticos
x_j	Sinal de entrada
$x(t)$	Valor real do dado corresponde ao instante t
$x_{máx}$	Valor máximo de x
$x_{mín}$	Valor mínimo de x
$\tilde{x}(t)$	Valor normalizado correspondente ao instante t
y_k, y_j	Sinal de saída do neurônio
α	Ângulo de ataque da pá
α_p	Ângulo de <i>Pitch</i>
β	Coefficiente que depende da natureza do terreno
$\varepsilon(n)$	Energia total do erro
η	Taxa de aprendizagem
μ	Média estatística de uma distribuição
μ_{A_i}	Função de pertinência
ρ	Densidade do ar
σ	Desvio padrão de uma amostra
$\varphi(.)$	Função de ativação
$\Phi(S)$	Distribuição normal tabulada

CAPÍTULO 1

1 Introdução

O presente capítulo expõe as considerações iniciais, a contribuição desta dissertação e uma breve descrição da organização do texto.

1.1 Considerações Iniciais

A energia dos ventos surge da não uniformidade do aquecimento da crosta terrestre sendo esta variação de temperatura causada pela incidência da radiação solar e pela rotação terrestre, gerando assim diferenças de pressão e como consequência o deslocamento do ar, dando origem aos ventos (PAVINATTO, E. F., 2005). Devido a não lançar gases poluentes na atmosfera, durante a geração de energia elétrica, essa fonte produz baixos níveis de poluição.

Com o desenvolvimento de novas linhas de pesquisa e de equipamentos, os custos de instalação e produção de energia elétrica a partir do vento vêm tornando-se bastante atrativos. Colocando a energia eólica como uma fonte alternativa ao uso extensivo das fontes de geração térmica.

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).

Até o presente momento o Brasil dispõe de uma capacidade eólica fiscalizada, atuante de forma efetiva no sistema, de 6.629MW distribuídos em 273 projetos de comercialização geradora o que corresponde a 4,78% de toda a capacidade de geração do país. Outro dado bastante expressivo diz respeito à quantidade de projetos em construção correspondendo a uma geração outorgada de 3.895MW extras que entrarão em operação nos próximos anos viabilizando um acréscimo de 17,26% da capacidade instalada atual (ANEEL, 2015).

Entretanto a variabilidade dos ventos faz a geração eólica galgar certas desvantagens comparando-a a outras fontes energéticas. A energia gerada em processos eólicos é variável, colocando a sua confiabilidade em questão na comparação com outras fontes energéticas tradicionais (LEITE, A. P., 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. Uma boa previsão dos ventos pode contribuir para: facilitar a comercialização de energia elétrica, melhorar os sistemas de controle dos parques eólicos, e fornecer dados para otimizar a operação do sistema elétrico como um todo.

Atualmente, são numerosos os modelos para previsão eólica como descrito em GIEBEL, G. et al (2003), e em MILIGAN, M. et al (2003). 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 como em FERREIRA A. A. et al (2008); em COSTA, A. et al (2008) e em KARINIOTAKIS, G. N. et al (1996). Os métodos de IA se caracterizam pela sua robustez e capacidade de generalização do aprendizado durante o treinamento.

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

1.2 Objetivos

Este trabalho tem como objetivo o desenvolvimento e avaliação de modelos previsores de geração eólica. Os modelos foram baseados em duas etapas, na primeira etapa o objetivo foi de realizar previsões sobre o vento e na segunda etapa, utilizar os dados para produzir previsões de potências ativas médias. Na segunda etapa se empregou um modelo para curva de potência do parque em análise, sendo esse modelo baseado essencialmente em RNAs ou em SIFs.

Os modelos de previsão desenvolvidos são de curto prazo, para previsões horárias num horizonte de 24h. Para a criação dos modelos desenvolvidos, foram utilizados dois parques eólicos reais como estudo de caso. Porém, os nomes dos parques não serão divulgados devido à regulamentação legal sobre condições de confidencialidade.

Os parques (Parque 01 e Parque 02) estão situados na região nordeste do Brasil, mais especificamente no estado do Ceará, e já se encontram em pleno funcionamento, tendo 28 máquinas no Parque 01 com a capacidade total instalada de 70,56MW e, 60 máquinas no Parque 02 com a capacidade total instalada de 126MW.

Os parques são característicos da região e, portanto, os modelos podem ser aplicados aos demais parques da região sem grandes perdas na precisão das previsões. Desta forma, pode-se ter uma ideia da variação do desempenho dos modelos para parques na mesma região em termos de valores percentuais do erro de previsão da geração.

Espera-se que o conteúdo deste estudo contribua de forma efetiva no que diz respeito às ferramentas e modelos de previsão de geração eólica, já que o país está vivenciando uma alteração brusca em sua matriz energética.

1.3 Citações e pontos de vistas importantes adotados nas referências

A Referência GIEBEL, G. et al (2003) apresenta em termos gerais um levantamento sobre tudo o que já havia sido feito em termos de técnicas de previsão eólica em escala global com horizontes que variam desde minutos até alguns dias. Tais técnicas são adotadas em turbinas eólicas, parques, fazendas ou regiões inteiras de grande potencial eólico. Desta forma, os pontos abordados nesta referência, fomentam de forma bastante plausível, a necessidade de desenvolvimento de modelos previsores, ponto chave desta dissertação.

Esta referência é um relatório que reúne um *know-how* de 15 anos de experiência na previsão eólica de curto prazo. Sendo este documento a primeira grande revisão literária sobre esse assunto, em que, o mesmo fora executado pela primeira vez no projeto de acompanhamento ANEMOS - PLUS, conforme ditado pela referência GIEBEL, G. et al (2003).

Presente na mesma referência esta uma introdução do uso mais extensivo de gráficos, que além de mostrar de forma clara as características da região estudada, ainda adequam de forma excelente o conhecimento prático ao teórico com relação a peculiaridades de cada região, mediante os trabalhos relacionados no relatório.

De forma a seguir um critério padrão, na montagem, desenvolvimento e comparação da eficiência dos modelos previsores abordados, utilizaram-se alguns critérios descritos conforme MADSEN, H. et al (2004). Nesta referência, propõem-se um protocolo

de avaliação preditiva de potência média em curto prazo, sendo no mesmo, desenvolvido um critério de avaliação que leva em consideração no mínimo dois modelos.

Para demonstrar a eficiência do protocolo, a referência testou mais de 10 modelos, sendo um modelo tomado como padrão, e os outros modelos propostos tomados como desafiantes, de forma que a comparação seja feita sempre, entre padrão e desafiante.

Por fim, fica bastante claro na referência que, a toda boa avaliação preditiva está atrelada um modelo previsor confiável, sendo esta confiabilidade medida pelo nível de incerteza da previsão.

Com relação à avaliação no desempenho dos modelos a referência KARINIOTAKIS, G. N. et al (1996) enfatiza que esta avaliação dependerá do critério. Como exemplo o autor cita dois dos critérios mais utilizados sendo eles o valor do MAE da previsão e o valor RMS do erro da previsão.

Em que quando é feita a comparação pelo MAE, a diferença no desempenho é relativamente menor do que a comparação feita pelo valor RMS, já que o critério RMS atribui valores dos pesos maiores para grandes erros, o que faz a diferença de comparação ser bastante significativa quando valor do erro aumenta.

Em SIDERATOS, G. et al (2007) é desenvolvido um modelo de predição de potências num horizonte de até 48h, que atrela métodos estatísticos avançados a ferramentas avançadas de inteligência artificial, sendo elas: a lógica Fuzzy e as redes auto organizáveis de Kohonen. Este artigo foi tomado como uma das referências, devido ao ótimo desempenho obtido pelos modelos propostos no mesmo.

Em que o mérito dos modelos esta na combinação do número de variáveis de entradas correlacionadas num escala temporal anterior, agregado ao forte desempenho de organização das redes de Kohonen e a precisão imposta pela lógica Fuzzy.

Uma das principais diferenças entre os modelos do artigo e os modelos propostos nesta dissertação, diz respeito ao número de entradas e a não utilização da potência como dado de entrada.

Em AQUINO, R. R. B. et al (2013), São propostos dois modelos de previsão, um com horizonte de 6h e o outro com horizonte de 5 dias, os mesmos são baseados em RNAs do tipo MLP e como na referência anterior, também utilizam o histórico de potências ativas numa escala de tempo anterior como entrada para as redes, sendo a outra entrada a velocidade do vento, e esboçam em sua saída uma previsão de potências com os horizontes já descritos anteriormente, correspondendo a uma previsão de geração.

Uma particularidade dos modelos de previsão propostos nesta referência, esta na discretização dos valores, na previsão com horizonte de 6h a velocidade é particionada em faixas de dez minutos. Já no caso da previsão com horizonte de cinco dias, a velocidade é dividida em faixas de 30 minutos.

Em ÜSTÜNTAS, T. et al (2008) são desenvolvidos modelos em Lógica Fuzzy que solucionam um dos principais problemas na modelagem de curvas de potência em parques eólicos, a existência de dados nas regiões de *CUT-in* e *CUT-out*. Este fato é extremamente prejudicial já que a previsão nas saídas dos modelos é bastante afetada pelas distorções de dados presentes nestas áreas da curva da turbina.

Para resolver este tipo de problema, o autor propõe um algoritmo de agrupamento central de classes que escolhe na curva da turbina em questão, centros de dados que não são afetados por estas regiões, livrando assim a previsão destas imperfeições. Neste Artigo, o mesmo mostra, que para uma curva de potência ser bem representada são necessários de 4 a 5 agrupamentos centrais.

Nesta dissertação uma ideia parecida de agrupamento de classes fora utilizada, atrelando faixas de correspondência entre as variáveis de entrada e de saída, em que para resolver o problema das imperfeições realizou-se uma filtragem na base de dados explicada no decorrer deste trabalho. Desta forma, por ter encontrado uma problemática semelhante na base de dados, esta referência também foi tomada como uma das principais.

Em FOCKENA, U. et al (2002), é feito um estudo sobre a redução dos erros de previsão de um conjunto de parques eólicos e um parque individual. No artigo, mostra-se que o erro de predição cai com o aumento da área, fato explicado pelo autor devido aos efeitos de amortecimento espacial.

Porém, para deixar claro qual a área mínima necessária para se ter previsões confiáveis, desenvolve-se um algoritmo de correlação espacial do erro de previsão, e mostra-se como exemplo, que numa região de diâmetro de 370 km, são necessários 50 locais de medição para garantir através do algoritmo desenvolvido uma redução de 63% no erro atrelado à previsão.

Assim, o artigo conclui que para uma boa precisão da previsão eólica de uma área extensa é importante o bom mapeamento, baseado no número de estações de medição da área em questão.

Em DAMOUSIS, I. G. et al (2004), é sugerido um modelo Fuzzy para a previsão da velocidade do vento e da energia elétrica produzida em um parque eólico. O modelo é

treinado utilizando a expertise dos algoritmos genéticos. O conjunto de treinamento inclui a velocidade do vento e dados de direção, medidos em locais vizinhos com até 30 km de distância a partir dos agrupamentos de turbinas eólicas.

Os Resultados das simulações são amplamente mostrados em dois casos de aplicação, fornecendo previsões de velocidade do vento com horizonte de 30 min a 2 h. É demonstrado que o sugerido modelo alcança uma compreensão adequada do problema, enquanto ele exhibe uma melhoria significativa em comparação com o modelo da persistência.

Em EL-FOULY, T.H.M. et al (2008) é apresentada uma nova técnica para a previsão de velocidades e direções do vento. Esta técnica é baseada na utilização de um modelo baseado em séries temporais lineares relacionando o intervalo previsto num horizonte de 1 a 2 anos.

A precisão do modelo predictor de séries temporais é de até 24h, e seu desempenho fora investigado utilizando dois conjuntos de dados gravados durante o inverno e o verão na estação meteorológica de Madison. Os resultados gerados foram comparados com os valores correspondentes quando se utiliza o modelo da persistência. Os quais validaram com eficácia e precisão para as previsões de velocidade e direção do modelo.

Em MIRANDA, C. et al (2006) é aplicada à previsão de potência eólica um novo método de treino de sistemas de inferência Fuzzy ou redes neurais que conduz a uma distribuição dos erros de previsão com entropia mínima, implicando maior frequência de pequenos erros que os sistemas treinados com o clássico critério do Erro Quadrático Médio.

O método combina a definição de Renyi de Entropia com a técnica das janelas de Parzen como medida do conteúdo de informação da distribuição dos erros, num paradigma designado *Information Theoretic Learning*. – *ITL*. Na referência mostra-se um caso prático de aplicação a um parque eólico europeu, com treino de um SIF Takagi-Sugeno com os parâmetros ajustados por um método de otimização evolucionária utilizando enxame de partículas (EPSO), conforme descrito pela mesma referência.

Em SOUSA, J. N. M. S. (2007) apresenta-se um sistema de previsão da produção eléctrica em parques eólicos, para um horizonte temporal de 72 horas, composto por dois modelos de previsão: Auto-Regressivo e Modelo de Curva de Potência. O primeiro, baseado num método Auto-Regressivo de primeira ordem, permite obter um modelo

dinâmico de previsão baseado nas medidas mais recentes da produção do parque, enquanto que o segundo baseia-se nas previsões meteorológicas para converter dados de vento em potência eléctrica, através de diversos modelos matemáticos entre os quais redes neurais.

Os resultados de previsão dos dois modelos são integrados através de um módulo de fusão. Sugerem-se dois métodos de fusão, sendo analisado o desempenho de cada uma das soluções.

1.4 Organização estrutural da dissertação

Esta dissertação é formada por oito capítulos, em que a introdução é o primeiro deles, e os demais seguem os títulos e ordens respectivas conforme é descrito a seguir:

Capítulo 1 – *Introdução*:

Neste capítulo foi apresentada uma descrição sobre o uso atual do potencial eólico do Brasil, assim como uma descrição dos objetivos deste trabalho e a descrição da estrutura do texto, além de uma breve revisão bibliográfica. Nesta revisão são feitos comentários a respeito, de vários trabalhos e artigos científicos os quais serviram como base teórica, no desenvolvimento e execução deste trabalho.

Capítulo 2 – *Conversão Eletromecânica da Energia*:

Neste capítulo é apresentado um resumo objetivo dos principais componentes de um sistema eólico e suas respectivas funções no processo de geração eólica. O resumo concede alicerces necessários para introduzir o leitor no problema da geração eólica, mais precisamente como se dá a conversão eletromecânica da energia.

Capítulo 3 – *Ferramentas de Inteligência Artificial*:

Este capítulo apresenta à heurística e concepção dos métodos de inteligência artificial empregados para a construção dos modelos previsores de potência deste trabalho.

Capítulo 4 – *Modelos desenvolvidos*:

Este capítulo propõe-se a apresentar a criação, construção e adequação dos bancos de dados e dos modelos de previsão de potência abordados nesse trabalho. Nele, evidenciam-se as principais diferenças construtivas dos modelos que utilizam RNAs e SIFs.

Capítulo 5 – *Análise dos Resultados e Comparação Entre os Modelos:*

Este capítulo descreve a metodologia utilizada para avaliação dos modelos previsores de potência mostrando os resultados das previsões referentes aos modelos desenvolvidos. Onde, faz-se uma análise minuciosa dos resultados relativos aos respectivos modelos em duas etapas distintas. Na primeira etapa, uma análise intermediária de cada modelo a respeito das previsões de velocidades médias de vento e direções médias de vento. Na segunda etapa, é realizada uma análise comparativa dos modelos entre si.

Capítulo 6 – *Conclusões e Trabalhos Futuros:*

O capítulo 6 faz uma breve conclusão acerca do trabalho, abordando principalmente os resultados em relação ao desempenho dos modelos desenvolvidos. Além de sugerir novas propostas de implementação dos modelos abordados, que não foram utilizadas nesta dissertação conforme serão descritas no decorrer do capítulo.

CAPÍTULO 2

2 Conversão Eletromecânica da Energia

O capítulo 2 procura resumir de forma clara, os principais componentes e suas respectivas funções no processo de geração eólica, tendo o mesmo, suma importância para o conhecimento do leitor. Além, de ser uma possível base de referência no que diz respeito à adequação dos modelos previsores de potência propostos nesta dissertação.

2.1 Processo de conversão e suas partes constituintes

Um sistema de conversão de energia eólica (SCEE) transforma a energia cinética do vento em energia mecânica utilizando o fluxo de ar incidente nas pás do rotor de um aerogerador. Esta energia é depois transformada em energia elétrica por um gerador, que poderá ser síncrono ou assíncrono, dependendo do tipo de controle associado ao mesmo.

O sistema é constituído por vários componentes, que participam diretamente do processo de conversão, assim, cada um desempenha um papel fundamental tornando o sistema eólico controlado, confiável e eficiente. A seguir, é feita uma breve definição dos principais elementos de uma turbina eólica:

2.1.1 Pás ou Lâminas

São responsáveis pela conversão da energia cinética do vento em energia mecânica de rotação. As mesmas são a parte mais protuberante da turbina e nos dias atuais suas tecnologias têm evoluído bastante. Pois, além do design moderno e aerodinâmico, que aperfeiçoa o aproveitamento da cinética dos ventos, sua composição se encontra baseada em materiais leves, porém, resistentes como: alumínio, fibra de vidro e fibra de carbono.

O princípio de atuação das pás é semelhante ao que acontece nos aviões, sendo esse princípio descrito por Bernoulli, em que o mesmo mostra que quando a velocidade de um fluido aumenta, a sua pressão interna diminui. Isto pode ser visto no design aerodinâmico da pá, que faz com que a velocidade do vento superior (v_{w1}), seja maior do que a

velocidade do vento inferior (v_{w2}). Esta diferença de velocidades gera na pá uma força de sustentação (F_w), proveniente da diferença de pressão entre região acima da pá expressa por (p_{w1}) e a região abaixo ditada por (p_{w2}).

Assim, segundo Bernoulli, têm-se os comportamentos das velocidades e pressões ocorrentes na pá, conforme descrito nas Expressões 2.1 e 2.2:

$$v_{w1} > v_{w2} \quad (2.1)$$

$$p_{w1} < p_{w2} \quad (2.2)$$

Em que a Figura 2.1 ilustra o que foi explanado acima:

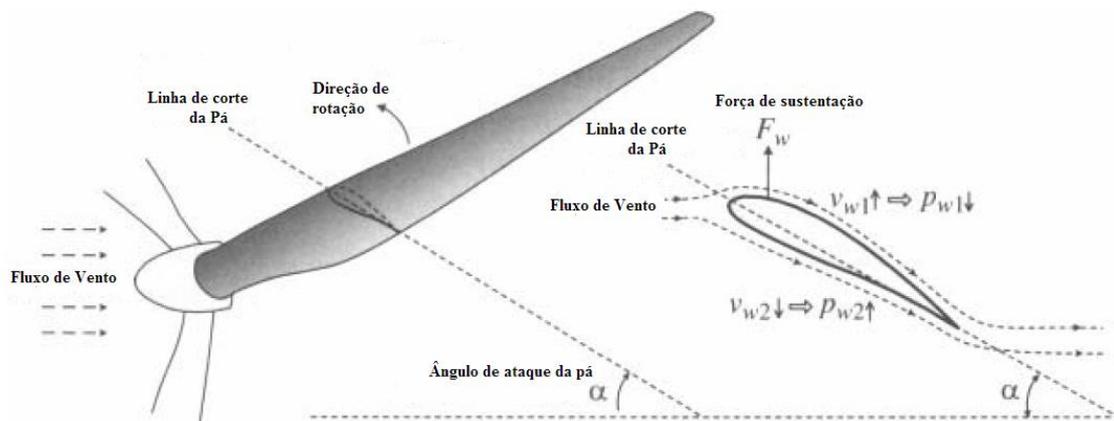


Figura 2.1 - Princípio de conversão de energia cinética em mecânica rotacional nas pás de um aerogerador.

2.1.2 Controladores aerodinâmicos (“Pitch” ou “Stall”)

Quanto ao controle aerodinâmico de conversão eólica, existem duas vertentes, uma ativa, controlador de *Pitch*, e a outra passiva, controlador de *stall*, ambas utilizadas de maneira efetiva, dependendo do local, índice de ventos e filosofia do fabricante.

O Controlador de *Pitch* é um atuador que permite a rotação das pás da turbina em seu eixo longitudinal, sendo com isso possível alterar o ângulo de ataque (α) em relação ao fluxo de vento incidente no cone. Esta característica faz desse equipamento, um controlador ativo, tendo influência significativa sobre a potência entregue pela turbina e assim melhorando a eficiência do processo de conversão.

Sua atuação seguirá os seguintes preceitos: quando a velocidade do vento for igual ou inferior ao seu valor nominal, o ângulo da pá é mantido em um valor controlado (α_p) e a turbina irá operar, capturando o vento e disponibilizando a potência. Quando a

velocidade de vento exceder o seu valor nominal, o mecanismo varia o ângulo de ataque de forma a limitar a potência máxima de saída mantendo-a numa faixa dentro de sua capacidade de projeto.

Na prática, esses valores do ângulo pertencem à faixa de 25° a 30° , e no caso de um aumento súbito da velocidade (Rajada), por questões de segurança o controlador posiciona a pá de forma que a mesma fique colinear com o fluxo de vento incidente. O que retira a turbina de operação, já que o vento deixa de ser capturado pelas pás. Outra característica, é que para garantir esse grau de precisão quanto à posição das pás, os motores desse atuador são do tipo passo, pois, além de serem mais simples em construção, ainda requererem menos manutenção.

A Figura 2.2 mostra o que foi explicado nos dois parágrafos anteriores:

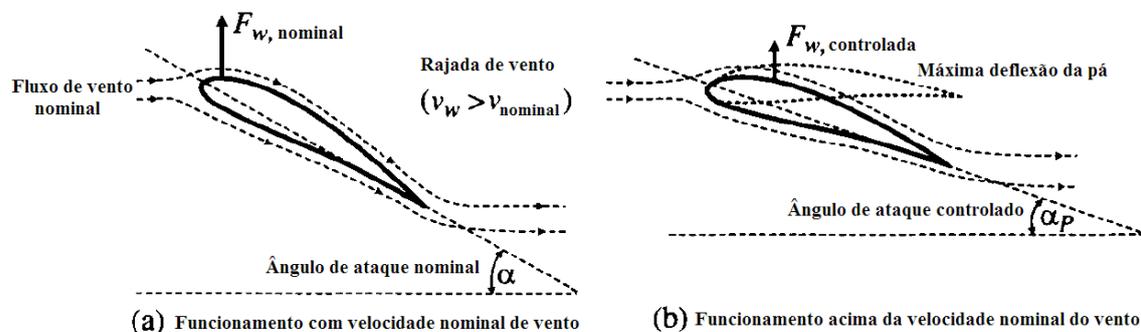


Figura 2.2 - Princípio de funcionamento de um controlador Pitch.

O controlador de *stall* é um controlador que não permite a mudança do ângulo de ataque da pá em relação ao fluxo de vento incidente no cone, assim, sua eficiência é limitada ao design aerodinâmico próprio da pá. Pois, as perdas inerentes com as turbulências e vórtices gerados na colisão do vento com a área da pá, limitam a potência disponibilizada pelo aerogerador.

Devido a essas perdas há menos sustentação da pá e conseqüentemente, menos força rotacional. Assim, a pá é desenhada para obter o máximo de desempenho com velocidades de vento acima do valor nominal. O que não é uma característica desejável devido ao risco associado e as vibrações na estrutura da turbina.

O funcionamento desse controlador é mostrado na Figura 2.3:

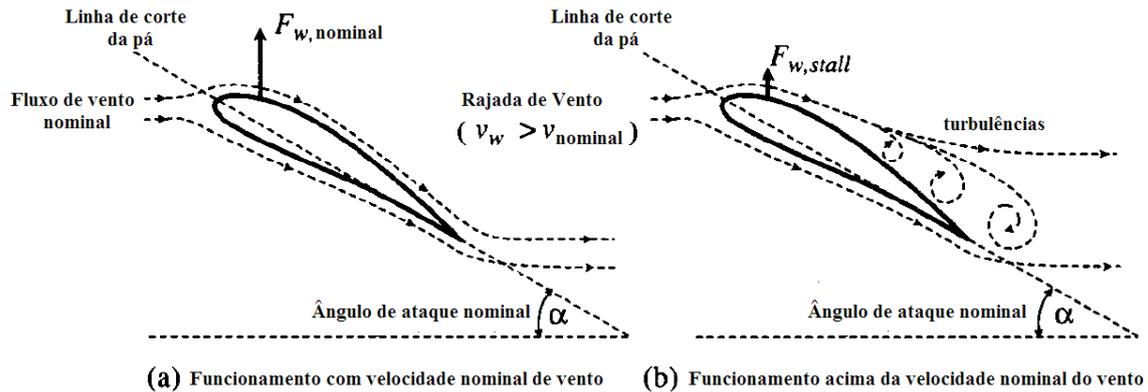


Figura 2.3 - Princípio de funcionamento de um controlador Stall.

2.1.3 Caixa de Marchas (caixa conversora de velocidades)

Consiste em um atuador eletromecânico de ligação entre o cubo da máquina eólica com o gerador elétrico, esta ligação é efetuada através de uma relação de velocidades. Sendo essa relação, controlada pelo atuador, em que o mesmo aplica a Expressão 2.3 à conversão do eixo de entrada para o eixo de saída:

$$r_{gb} = \frac{n_m}{n_M} = \frac{(1-s)*60*f_s}{p*n_M} \quad (2.3)$$

Em que:

r_{gb} : é o fator de relação de velocidades.

n_m : é a velocidades das pás do aerogerador em (RPM).

n_M : é a velocidade do gerador elétrico em (RPM).

s : é a relação de escorregamento entre as velocidades n_m e n_M em (%).

f_s : é a frequência elétrica nominal do estator do gerador elétrico em (Hz).

p : é o número de pares de pólos do gerador elétrico.

2.1.4 Freio mecânico do Rotor

Consiste em um atuador eletromecânico ou hidráulico que tem a função de cessar de forma efetiva o movimento do cubo do aerogerador, seja por parada normal programada ou emergencial. O mesmo pode vir a ser instalado no eixo de alta rotação (gerador elétrico) ou no eixo de baixa rotação (cubo).

Sua atuação é normalmente utilizada para auxiliar a ativação do controle de potência aerodinâmico, seja numa situação de incidência de altas velocidades de vento, ou no caso de quando a máquina estiver no modo estacional, aferindo segurança a uma possível manutenção.

2.1.5 Gerador Elétrico

É um aparelho que tem a função de converter a energia mecânica em energia elétrica, isso é feito através da aplicação das ferramentas e princípios de conversão da energia elétrica e à teoria de máquinas elétricas.

Conforme ditado em WU, B., (2011), o mesmo poderá ser de três tipos distintos: o gerador de indução (Gaiola de esquilo), gerador de indução duplamente alimentado e o gerador síncrono, que poderá ser de rotor bobinado ou a imã permanente.

Vale salientar, que dependendo do tipo do gerador haverá um controle de potência específico, tendo cada modelo de controlador de potência sua utilização para os tipos de geradores citados anteriormente. O crescimento e o desenvolvimento de estudos na acoplagem dos geradores a este tipo de extração energética nos dias atuais consegue despachar por máquina, potências que variam desde [kW] até [MW]. A Figura 2.4, expressa a principal forma de conexão de um aerogerador a um sistema elétrico.

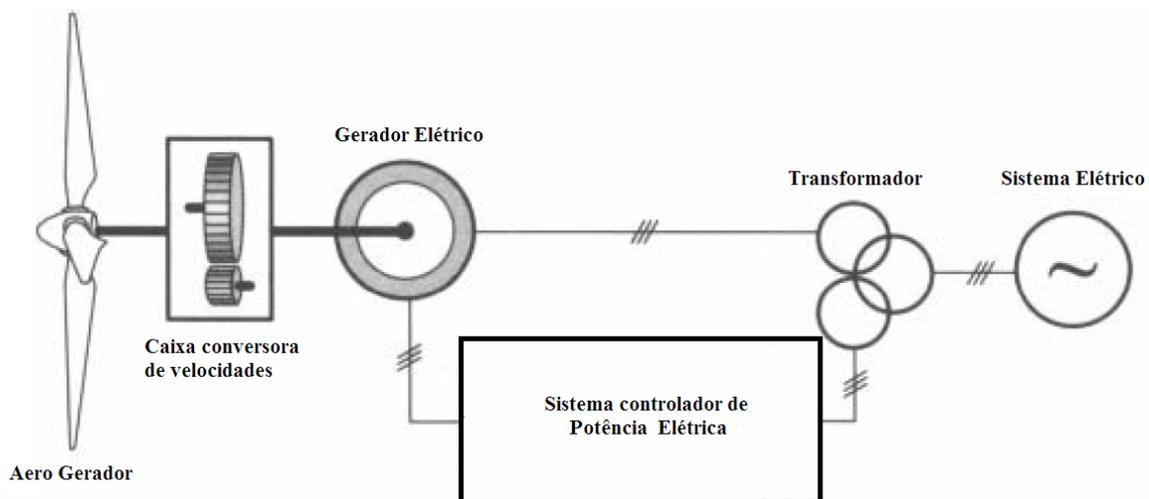


Figura 2. 4 - Acoplagem de um aerogerador a um sistema elétrico.

2.1.6 Controlador rotacional de posição Horizontal (*Yaw*)

Consiste em um controlador que tem a função de direcionar a área efetiva de incidência do fluxo de vento da turbina (cone ou *Hub*) para melhor aproveitar a incidência de ventos. O controle se dá a base de um movimento rotacional sendo o eixo de referência o eixo da torre (vertical), assim a região do cone poderá se movimentar de maneira circular para leste ou para oeste.

A estrutura deste tipo de controlador utiliza de forma combinada motores elétricos e do tipo passo, em que o resultado final é maximizar o aproveitamento de conversão da energia dos ventos. Sua localização geralmente se dá próxima à nacele, no interior da torre.

2.1.7 Torre

Consiste numa estrutura, forte rígida e delgada, que tem a função de sustentar a nacele, estrutura que abriga o cone e os equipamentos controladores da máquina eólica, proporcionando altura suficiente para a livre movimentação das pás. O material que compõe a sua estrutura varia desde aço até o concreto, segundo WU, B. (2011, p. 35) em 2011 a maior torre construída tinha 160 m, em que a mesma sustentava uma máquina de 2,5MW.

2.1.8 Turbina

É a estrutura que engloba o cone e as pás, a mesma poderá seguir duas formas de operação, sendo elas, a operação em eixo vertical e a operação em eixo horizontal. Em que a melhor disposição de operação dependerá de estudos realizados, custos envolvidos e fabricantes escolhidos. Na Tabela 2.1 são mostradas vantagens e desvantagens de uma disposição em relação à outra:

Tabela 2. 1 - Comparação entre turbinas de eixo horizontal e eixo vertical.

Tipo de Turbina	Vantagens	Desvantagens
Eixo Horizontal	<ul style="list-style-type: none"> • Eficiência na conversão com altas velocidades de vento incidentes. 	<ul style="list-style-type: none"> • Alto custo das instalações da torre, devido à altura e o peso da nacele.
	<ul style="list-style-type: none"> • Acesso a ventos com 	<ul style="list-style-type: none"> • Distâncias longas

	<p>melhor qualidade devido à altura do cone.</p>	<p>nas ligações de cabos da parte superior da torre até a terra.</p>
	<ul style="list-style-type: none"> • Regulação de potência por controle de (<i>Pitch</i>) ou (<i>Stall</i>) em altas velocidades de vento. 	<ul style="list-style-type: none"> • Orientação requer um controle rotacional de posição horizontal (<i>Yaw</i>).
Eixo Vertical	<ul style="list-style-type: none"> • Menor custo na instalação e fácil manutenção devido à altura reduzida em relação ao solo da caixa de marchas e do gerador elétrico 	<ul style="list-style-type: none"> • Baixa eficiência no processo de conversão de energia dos ventos.
	<ul style="list-style-type: none"> • Operação independente da direção do vento. 	<ul style="list-style-type: none"> • Flutuações de torque elevadas, operação sujeita a vibrações mecânicas.
	<ul style="list-style-type: none"> • Estrutura superior adequada à incidência de ventos fortes, sem a necessidade de torres. 	<ul style="list-style-type: none"> • Opções limitadas na regulação de Potência em altas velocidades.

E a Figura 2.5 mostra a diferença estrutural de uma turbina de eixo horizontal e uma de eixo vertical:

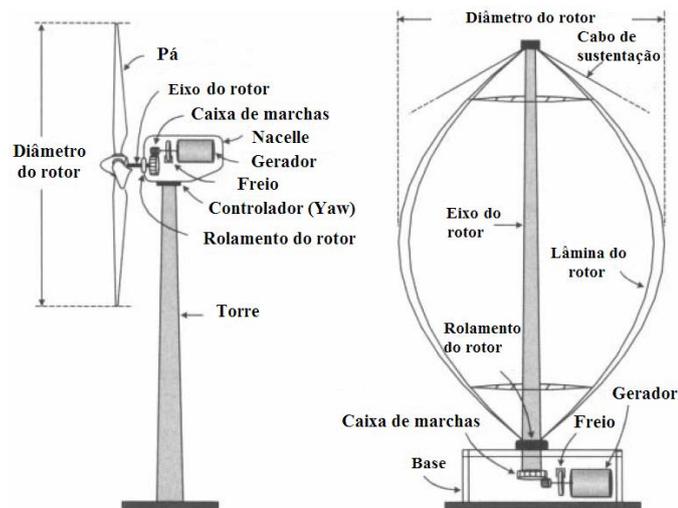


Figura 2. 5 - Respectivamente da esquerda para a direita, turbina de eixo horizontal e turbina de eixo vertical (Darrieus).

Desta forma, após a apresentação dos principais componentes de um aerogerador, a Figura 2.6 mostra a presença de todos os componentes na estrutura de uma máquina eólica.

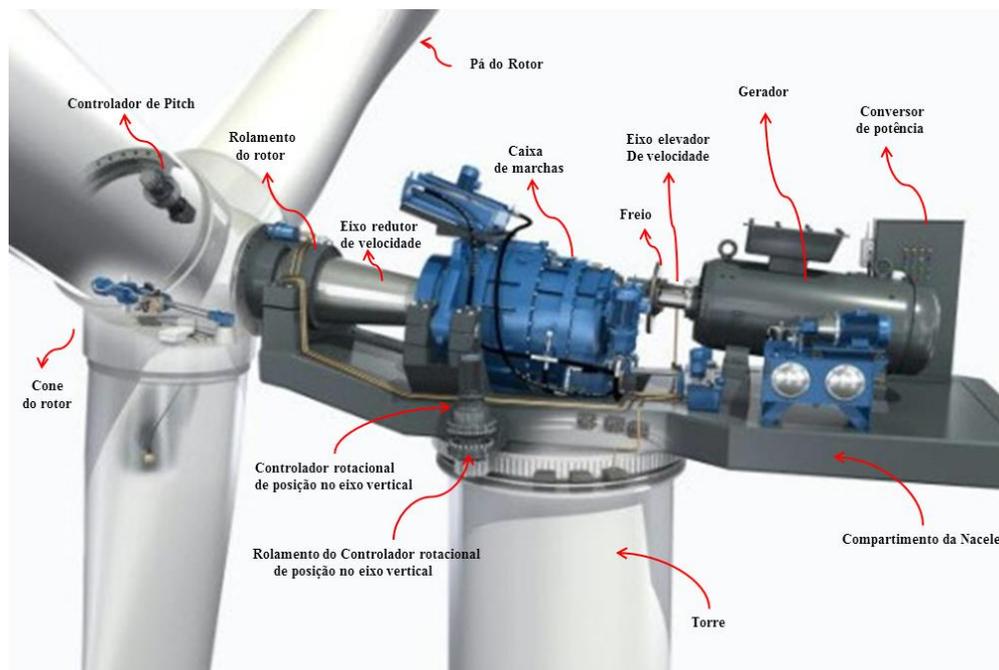


Figura 2. 6 - Componentes principais de aerogerador (Foto: Bosh Rexroth AG).

Como a cinética dos ventos constitui a base para um sistema eólico, a velocidade do vento se apresenta como principal grandeza no processo de conversão, pois a mesma esta

fortemente ligada a Potência elétrica produzida pela turbina eólica. Sendo esta ligação expressa por uma razão cúbica, conforme mostrado pela Expressão 2.4.

$$P_{mec} \sim v_v^3, \quad (2.4)$$

Esta potência inicialmente é provinda de forma mecânica, sendo influenciada por fatores como, a densidade do ar (ρ) medida em $[\text{kg}/\text{m}^3]$, a área de incidência efetiva do cone da turbina (A) em (m^2) , além do coeficiente de extração de potência mecânica da pá (C_P) aferido na escala (Betz). Em que a Potência mecânica disponibilizada no eixo da turbina (P_{mec}), é dada pela Eq.(2.5) a seguir:

$$P_{mec} = \frac{1}{2} \rho A v_v^3 C_P, \quad (2.5)$$

Uma característica importante relacionada ao coeficiente de extração de potência, é que o mesmo tem um valor máximo teórico da ordem de 0,59 de acordo com o limite de Betz, em que tal valor descreve o rendimento máximo da turbina. Atualmente o valor para esse coeficiente varia entre 0,2 a 0,5. Assim, tal rendimento dependerá da velocidade de rotação do cubo, bem como do número de pás agregadas ao mesmo.

Outro fator não menos importante, diz respeito à influência orográfica sobre o deslocamento das massas de ar, pois ao incidir sobre obstáculos naturais ou implantados pelo homem, o vento perde potencial de geração, com as já mencionadas turbulências. Afim, de contornar essa característica, faz-se uma correção dessas velocidades de vento para uma altura desejada, de forma que a orografia diminua a influência negativa sobre o fluxo de vento, assim como mostrado em GOUVEIA, H. T. V. (2011):

$$v_v(h) = v_{v1} * \left(\frac{h}{h_1}\right)^\beta, \quad (2.6)$$

Em que:

v_{v1} : é a velocidade na altura h_1 (conhecida).

$v_v(h)$: é a velocidade na altura h (estimada).

h : é a altura livre da influência da rugosidade.

h_1 : é a altura conhecida (influenciada pela rugosidade).

β : é o coeficiente que depende da natureza do terreno.

De forma a passar uma ideia para o leitor sobre alguns valores de coeficiente de rugosidade, a Tabela 2.2 mostra uma relação entre este coeficiente e o tipo de terreno.

Tabela 2. 2 - Coeficiente de rugosidade para diversos tipos de terreno.

Tipo de Terreno	Coeficiente
Lagos, oceanos e solo liso.	0,10
Gramma.	0,15
Cercas vivas e arbustos.	0,20
Florestas.	0,25
Pequenas cidades com poucas árvores e arbustos.	0,30
Grandes cidades com altos edifícios e construções.	0,40

Até o presente momento este capítulo mostrou características construtivas e algumas leis naturais que ditam o funcionamento do sistema eólico. Desta forma, é mostrado agora, que tipo de característica presente em um sistema eólico controla de forma ótima o desempenho de um aerogerador quanto ao seu potencial de geração.

Para tal são necessários alguns conhecimentos que serão discutidos a seguir, sendo os principais: a Curva de Potência da Máquina eólica e o sistema de controle da máquina em si.

2.2 Curva de Potência

A curva de potência é conhecida como uma tendência física que define as características de geração de uma turbina eólica. Essa curva relaciona a potência mecânica que posteriormente é convertida em potência elétrica, proveniente da incidência da velocidade do vento sobre as pás de um aerogerador. Segundo o *International Energy Association* - I.E.A., a curva de potência é a identidade funcional de uma máquina eólica, sendo definida como um certificado de desempenho garantido pelo fabricante.

Assim, este órgão desenvolveu recomendações que têm sido continuamente melhoradas e adaptadas pelo *International Electrotechnical Commission* - I.E.C., que para normatizar tais indagações sobre o tema, criou a norma IEC61400-12, atualmente aceita como referência mundial na definição, aferição e medição de uma curva de potência.

Uma curva de potência típica é modelada por três características básicas, são elas: a velocidade “*Cut-in*”, a região “*Efetiva*” de velocidades de vento e a velocidade “*Cut-out*”. Estes aspectos são definidos a seguir:

A velocidade “*Cut-in*”: é a velocidade mínima de vento, na altura do cone (*Hub*) do rotor, em regime permanente e sem turbulência, que permite o início de geração de energia elétrica por parte do aerogerador.

A região efetiva: é a faixa média crescente de velocidades de vento, na altura do cone do rotor, em regime permanente e sem turbulência, que permite a geração de energia elétrica. Esta região se estende da velocidade “*Cut-in*” até a velocidade “*Cut-out*”.

Já a velocidade “*Cut-out*”: é a velocidade máxima de vento, na altura do centro do rotor, em regime permanente e sem turbulência, que ainda permite a máquina operar antes de ser desligada. Assim, por se tratar de uma velocidade elevada, testa o limite físico-estrutural do aerogerador, sendo responsável por questões de segurança, pelo corte operacional da máquina eólica.

Estas três peculiaridades delimitam a curva de potência de qualquer turbina, além de estabelecer de forma efetiva qual a faixa de operação da mesma, definindo desta forma, os valores de operação mínimos e máximos de velocidades médias e de potência médias.

A Figura 2.7 mostra o diagrama esquemático de uma curva de potência.

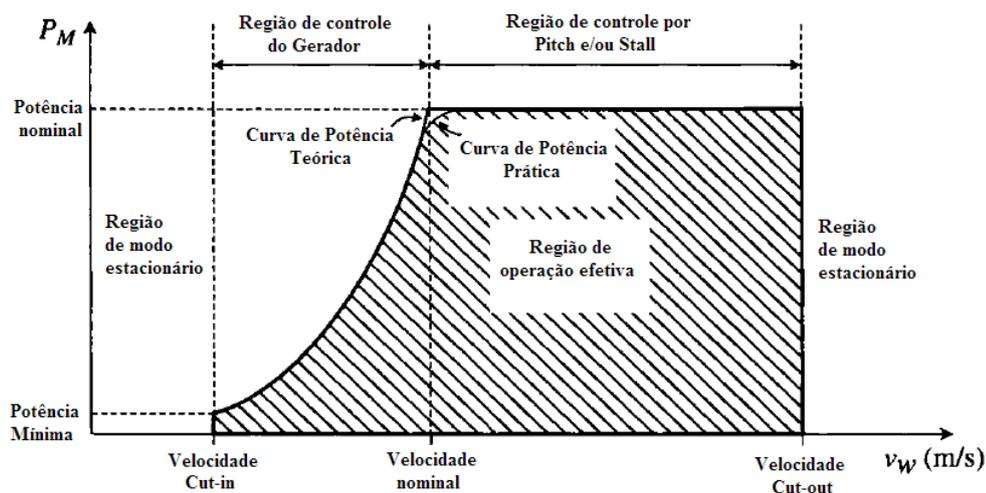


Figura 2.7 - Demonstração qualitativa de uma curva de potência.

Segundo (STIEBLER, M. 2008, p. 23) mais importante do que a capacidade energética de um sistema de geração eólica, é a sua curva de potência. Pois, o levantamento desta, associado ao conhecimento da velocidade média e a distribuições estatísticas, como a de Rayleigh, fornecem informações indispensáveis para a previsão do rendimento anual de energia.

Outro fator importante, também mostrado por STIEBLER, M. (2008), é que a velocidade mínima comum de “*Cut-in*” na maioria dos aerogeradores fica presa à faixa de 3 a 4 [m/s]. Já a velocidade máxima comum de “*Cut-out*”, fica comumente em 25 [m/s] sendo o desligamento da turbina efetuado por um sistema duplo de frenagem independente.

Também é importante salientar o nível de instabilidade da curva com relação à velocidade de operação da máquina na região não linear, sobretudo após a velocidade nominal. Sendo este controle operacional de responsabilidade dos controladores por “*Pitch*” e “*Stall*”, pois nesta região fica claro que uma pequena variação na velocidade incidente na máquina poderá provocar um grande distúrbio no valor de potência gerada pela mesma.

Para ditar como a turbina eólica deve se comportar, existe na mesma um sistema de controle agregado, que logicamente toma por base heurística a curva de potência do aerogerador. Algumas características importantes deste tipo de controlador são mostradas a seguir.

2.2.1 Controlador de potência máxima utilizando rastreamento pontual na curva de potência

Um dos métodos de controle de potência máxima utilizado com frequência é o rastreamento pontual na curva de potência, em que o mesmo é baseado na CP de uma determinada máquina (Relação Velocidade média x Potência média) fornecida pelo fabricante. Esta relação define a potência máxima que pode ser produzida pela turbina eólica em diferentes velocidades de operação.

De forma a ilustrar o que foi dito no parágrafo anterior a Figura 2.8 esboça um controlador em diagrama de blocos simplificado.

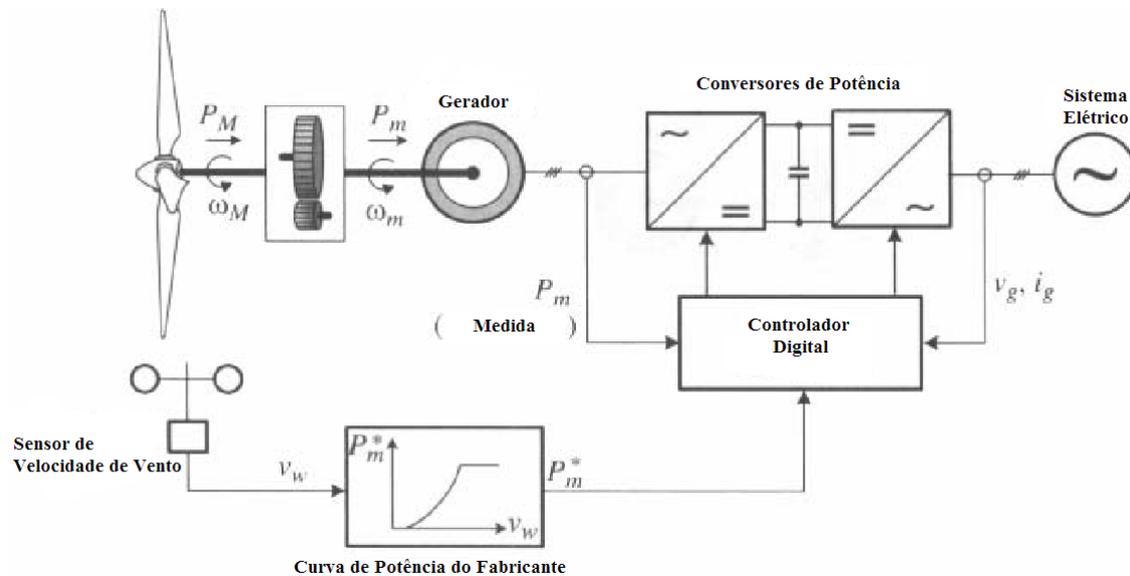


Figura 2. 8 - Controlador de Potência a rastreamento pontual.

Esta técnica tem seu ponto chave, na tendência natural que interliga a velocidade média num determinado instante a um valor de potência média nesse mesmo instante de tempo. Logo, sistemas previsores que utilizam esta curva, além de fornecerem um prognóstico sobre a característica eólica do local, também indicam qual o melhor ajuste que deverá ser feito pelo fabricante do aerogerador de forma a maximizar o despacho energético.

Assim, para entender o funcionamento desse tipo de controlador, mostra-se a seguir como é feita a execução deste tipo de controle.

A velocidade do vento é medida em tempo real por um sensor de velocidade de vento (Anemômetro). O valor medido de velocidade (v_w) é então comparado com o valor condizente na CP do fabricante. Sendo fornecido um valor ótimo de operação (P_m^*) este valor é então fornecido ao controlador digital que opera os conversores de potência que alimentam o sistema elétrico.

Logo, a todo o momento, a potência elétrica fornecida pelo gerador (P_m), esta constantemente sendo supervisionada pelo controlador digital, que poderá aumentar ou diminuir o nível de trabalho do aerogerador, de acordo com a demanda do sistema. Porém, este aumento ocorrerá de forma controlada, sendo este limite imposto pela curva de potência do fabricante.

Assim este capítulo tomou por base, fornecer informações de caráter construtivo e operacional de um sistema eólico, mostrando a importância de fatores controladores, sendo o principal deles, a curva de Potência. Desta forma, fica evidente o fomento pelo desenvolvimento de modelos previsores baseados na filosofia, desta curva que fornece informações preciosas sobre características relativas ao vento do local ou região em questão.

CAPÍTULO 3

3 Ferramentas de 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 4. Este capítulo é composto por duas seções, em que a primeira seção apresenta as Redes Neurais Artificiais, a segunda seção que aborda a Lógica Fuzzy.

3.1 Redes Neurais

Uma Rede Neural Artificial (RNA) é uma tentativa de reproduzir a estrutura e o funcionamento do cérebro humano em um ambiente técnico. 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 adaptar ou aprender, depois generalizar, agrupar ou organizar dados e por fim minimizar os erros atrelados às respostas.

As RNAs são sistemas paralelos 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 possuem pesos associados, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede (LUDERMIR, T. B. *et. al.* 2000).

Hoje, as redes neurais servem de base 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 das disciplinas de redes neurais e inteligência artificial. No artigo proposto por McCulloch e Pitts 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 que estão altamente conectados.

Um neurônio artificial é uma unidade de processamento da informação que é fundamental para a operação de uma rede neural. Em geral, as RNAs são compostas pelas camadas de entrada, camada escondida (que pode ser denominada como intermediária ou oculta e que também pode conter outras subcamadas) e camada de saída.

Apenas a camada de entrada não é composta por neurônios (AFONSO MARQUES, A. C., 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, S., 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).

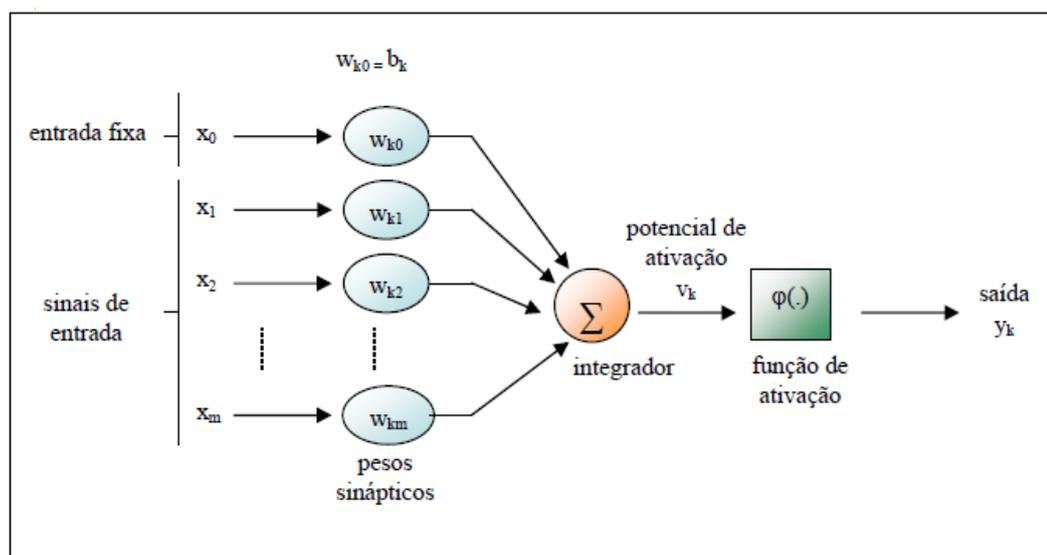


Figura 3.1 - Modelo de um Neurônio Artificial (LIMA et. al.2009).

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 restringe a amplitude do sinal de saída do neurônio artificial a um valor finito. Podendo o peso sináptico assumir valores positivos e negativos. O modelo neural da Figura 3.1 inclui um *bias* aplicado externamente, que é representado por b_k , que 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 Expressões:

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

$$y_k = \varphi(v_k), \quad (3.2)$$

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 (LUDERMIR, T. B. et. al. 2000). Nesta dissertação serão abordados dois tipos de função de ativação que serão utilizadas na confecção dos modelos de previsão de vento a serem descritos no capítulo 6 deste texto.

A primeira função a ser comentada é a função *sigmoide logística*, que é a mais comum das funções de ativação utilizadas e cujo gráfico em forma de “s”. A função sigmoide assume um intervalo contínuo de valores entre [0 e 1] e é diferenciável, conforme se vê na Figura 3.2.

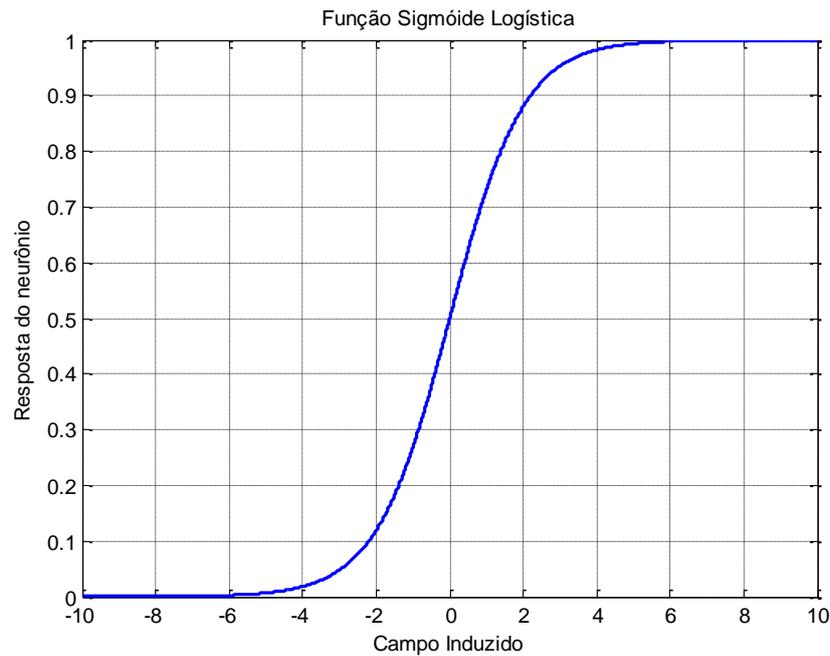


Figura 3.2 - Gráfico da função Sigmoidal Logística.

Matematicamente, podemos definir a função *sigmoide logística* da seguinte forma:

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

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 de saída da função de ativação do neurônio no intervalo $[-1,1]$. A Figura 3.2 mostra o gráfico da função de ativação tangente hiperbólica.

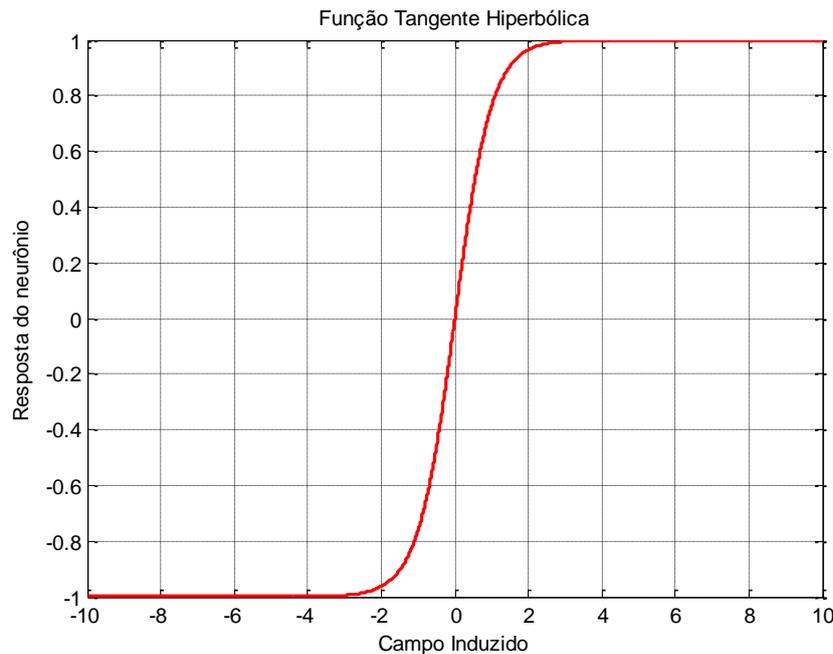


Figura 3.3 - Gráfico da função Tangente Hiperbólica.

Matematicamente, podemos definir a função *tangente hiperbólica* da seguinte forma:

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

3.1.3 Topologia de Rede Neural Artificial

A disposição pela qual 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 adiante com camada única, redes alimentadas diretamente com múltiplas camadas e as redes recorrentes.

Nesta dissertação abordaremos as redes alimentadas diretamente com múltiplas camadas, ou como normalmente é disseminado na literatura *Multilayer Feedforward*, 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 útil (HAYKIN, S., 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.

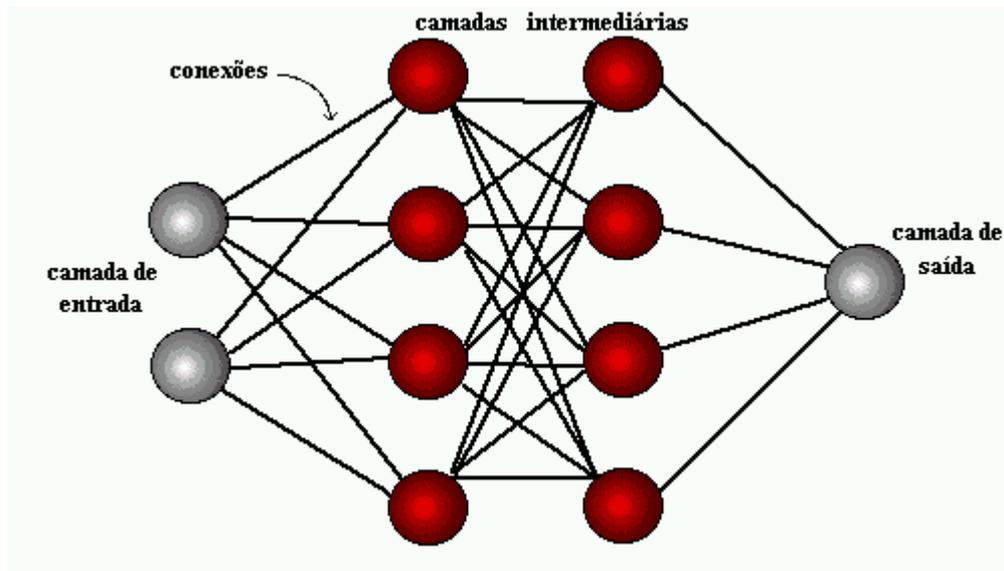


Figura 3. 4 - Rede alimentada adiante com três camadas de neurônios.

De acordo com a Figura 3.4 podemos perceber que a rede é totalmente alimentada, 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, a fase *forward* (para frente) e *backward* (para trás), cada fase percorre um sentido da rede. Na fase *forward* é apresentado a 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 tem a seguinte expressão:

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

em que j é um nó de saída.

A energia total do erro 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. A expressão da energia total do erro é a seguinte:

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

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

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

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 do erro com relação ao peso cuja expressão é:

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

Fez-se necessária a manipulação algébrica das derivadas parciais, com isso obtemos a Expressão 3.11.

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

A correção $\Delta w_{ji}(n)$ aplicada a $w_{ji}(n)$ é segundo a *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 $\varepsilon(n)$.

A correção do peso (3.12) é aplicada à atualização dos pesos:

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

3.1.5 Algoritmo de Levenberg Marquardt (LM)

O algoritmo *Levenberg-Marquardt* é uma técnica iterativa de otimização utilizada para minimizar funções expressas como somas quadráticas de funções não lineares. Este

algoritmo pode ser visto como uma combinação do método do Gradiente Descendente e do método de Gauss-Newton.

Quando a solução corrente se encontra distante da solução ótima, o algoritmo *Levenberg-Marquardt* funciona como o método do Gradiente Descendente: lento, mas com convergência garantida. Quando a solução corrente se aproxima da ótima, o algoritmo *Levenberg-Marquardt* se assemelha ao método de Gauss-Newton.

Quanto à forma da função objetivo, que será minimizada, a mesma é uma soma quadrática dos erros médios cometidos nas previsões expressão 3.14.

$$E(w) = \sum_{i=1}^m e_i^2(w) = \|g(w)\|^2, \quad (3.14),$$

$$\text{Sendo: } e_i^2(w) = (y_{di} - y_i)^2 \quad (3.15)$$

em que: y_{di} é o valor desejado como saída para o i -ésimo neurônio, y_i é o valor de saída referente ao i -ésimo neurônio e $g(w)$ representa uma função contendo os termos de erro individuais. Assume-se que a função $g(w)$ e seu Jacobiano J são conhecidos no ponto w . O objetivo do algoritmo *Levenberg-Marquardt* é calcular o vetor de pesos (w -weight); tal que $E(w)$ seja mínimo.

(como no caso do treinamento de redes progressivas de múltiplas camadas), então, a matriz Hessiana é a seguinte:

$$H = J^T J, \quad (3.16),$$

e o gradiente pode ser calculado pela seguinte expressão:

$$g = J^T r, \quad (3.17),$$

em que, J é a matriz Jacobiana que contém as derivadas de primeira ordem dos erros da rede em relação aos parâmetros, e r é o vetor dos resíduos da rede (erros). A matriz Jacobiana pode ser calculada através de uma técnica padrão de retropropagação, que é bem mais simples do que calcular a matriz Hessiana (HAGAN, M. T., 1994).

O algoritmo *Levenberg-Marquardt* utiliza uma aproximação da matriz Hessiana similar ao método de Gauss-Newton, de modo que a atualização dos parâmetros da rede é conforme seguinte expressão:

$$w_{k+1} = w_k - [J^T J + \mu I]^{-1} J^T r, \quad (3.18),$$

Quando o escalar μ é igual a zero, trata-se do método de Gauss-Newton. Quando μ é um valor grande, ele se torna o método do Gradiente Descendente com um passo pequeno, portanto, o algoritmo *Levenberg-Marquardt* funcionará de modo semelhante ao método de Newton logo que possível. Assim, μ é reduzido a cada iteração bem sucedida

(diminuição da função objetivo) e só é aumentado se o valor da função objetivo para a próxima iteração aumentar.

O tamanho da matriz Jacobiana é $(Q \times n)$, sendo Q , o número de conjuntos de treinamento e n o número de parâmetros da rede. Porém, essa matriz não tem que ser calculada e armazenada como um todo. Por exemplo, pode-se dividir a matriz Jacobiana em duas submatrizes e posteriormente calcular a matriz Hessiana aproximada, conforme mostrado pela Expressão 3.19:

$$H = J^T J = J_1^T J_2^T [J^T J] \begin{bmatrix} J_1 \\ J_2 \end{bmatrix} = J_1^T J_1 + J_2^T J_2, \quad (3.19),$$

Observe que não é necessário calcular a matriz Jacobiana completa de uma só vez. Pode-se calcular a aproximação da matriz Hessiana através de uma série de somas de submatrizes.

3.1.6 Algoritmo Resilient Propagation (RP)

Redes Multilayers (com varias camadas) utilizam funções de ativação do tipo sigmoide, cujo calcanhar de Aquiles, se mostra no treinamento. Pois, nesta fase, o gradiente dessas funções pode ter valor muito pequeno acarretando em alterações muito pequenas, mesmo com estes parâmetros estando longe dos valores ótimos.

Com o algoritmo *Resilient Propagation*, proposto por RIEDMILLER, M., (1993) se eliminam os efeitos indesejados causados pelos pequenos valores das derivadas parciais. Isto é possível graças à utilização de apenas sinal da derivada como meio de direcionamento da atualização nos parâmetros.

Na otimização do algoritmo RP (*Resilient Propagation*), a atualização de cada parâmetro é feita de forma individual por meio de um valor denominado δ_{jl} . Cujas expressões são as seguintes:

$$\delta_{jl}(k) = \left\{ \begin{array}{l} \alpha^+ \delta_{jl}(k-1), \text{ se } \frac{\partial \varepsilon(k-1)}{\partial w_{jl}(k-1)} \frac{\partial \varepsilon(k)}{\partial w_{jl}(k)} > 0, \\ \alpha^- \delta_{jl}(k-1), \text{ se } \frac{\partial \varepsilon(k-1)}{\partial w_{jl}(k-1)} \frac{\partial \varepsilon(k)}{\partial w_{jl}(k)} < 0, \\ \delta_{jl}(k-1), \text{ se } \frac{\partial \varepsilon(k-1)}{\partial w_{jl}(k-1)} \frac{\partial \varepsilon(k)}{\partial w_{jl}(k)} = 0 \end{array} \right\} \quad (3.20),$$

em que, $0 < \alpha^- < 1 < \alpha^+$.

Em que na adaptação prevalecerá a seguinte regra: sempre que a derivada parcial em relação ao peso correspondente w_{jl} mudar de sinal, indicando que a última atualização

foi muito grande e o algoritmo não considerou um mínimo local, então o valor de atualização δ_{jl} é reduzido por um fator α^- . Se a derivada mantiver o sinal, o valor de atualização é ligeiramente aumentado por um fator de α^+ objetivando a aceleração do processo de convergência.

Após ser realizada a adaptação de δ_{jl} , a atualização dos pesos é realizada de acordo com uma regra bastante simples: se a derivada é positiva (indicando um aumento do erro) o respectivo peso é reduzido pelo seu valor de atualização, caso contrário, o peso será aumentado pelo seu valor de atualização, conforme descrito pela Expressão 3.21.

$$\Delta w_{jl}(k) = \begin{cases} -\delta_{jl}(k), & \text{se } \frac{\partial \varepsilon(k)}{\partial w_{jl}(k)} > 0, \\ +\delta_{jl}(k), & \text{se } \frac{\partial \varepsilon(k)}{\partial w_{jl}(k)} < 0, \\ 0, & \text{se } \frac{\partial \varepsilon(k)}{\partial w_{jl}(k)} = 0 \end{cases} \quad (3.21)$$

A atualização de cada parâmetro da rede é demonstrada pela Expressão 3.20 abaixo:

$$w_{jl}(k+1) = w_{jl}(k) + \Delta w_{jl}(k) \quad (3.22)$$

Entretanto, há uma exceção: se a derivada parcial muda de sinal, ou seja, o passo anterior foi muito grande e o mínimo foi “perdido”, a atualização anterior do peso correspondente é revertida. Conforme mostrado pela Expressão 3.23:

$$\Delta w_{jl}(k) = -\Delta w_{jl}(k-1), \text{ se } \frac{\partial \varepsilon(k-1)}{\partial w_{jl}(k-1)} \frac{\partial \varepsilon(k)}{\partial w_{jl}(k)} < 0. \quad (3.23)$$

Com esta reversão da atualização, pode ser que a derivada mude de sinal novamente na próxima iteração. Para evitar uma “dupla punição do valor de atualização”, neste caso, não deve ser realizada a adaptação de δ_{jl} nesta última iteração. Na prática, isto pode ser feito atribuindo-se, na regra adaptativa de δ_{jl} , o valor zero à derivada do passo anterior.

Os valores de atualização e os pesos são modificados após a apresentação de todo o conjunto de padrões à rede, ou seja, após cada “época” de treinamento.

3.2 Lógica de Inferência 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 variam 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 segundo KOSKO, B. (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 aplicado à temperatura. Os gráficos que constam na Figura 3.5 representam quatro variáveis térmicas: frio, conforto, relativamente quente e quente.

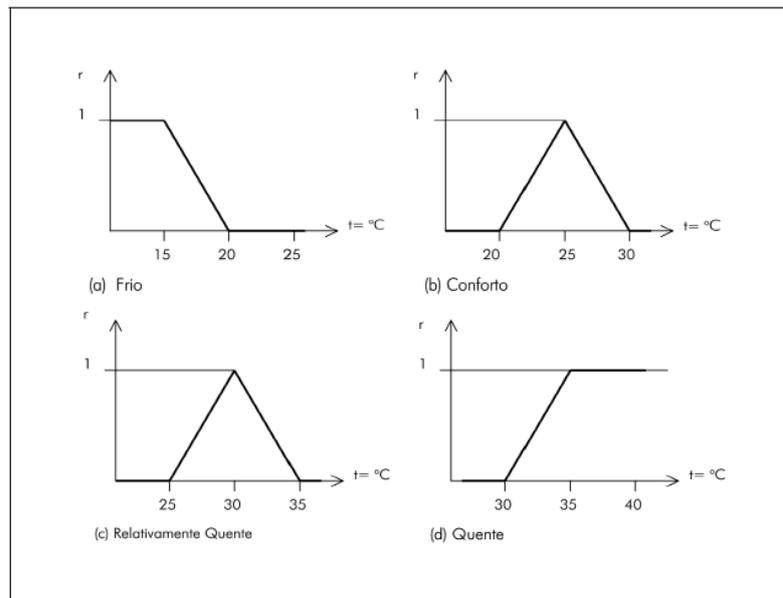


Figura 3.5 - Exemplo de funções de pertinência.

A Figura 3.5 mostra a faixa de pertinência da temperatura em seus respectivos intervalos de consideração: (a) Frio, (b) Conforto, (c) Relativamente quente e (d) Quente.

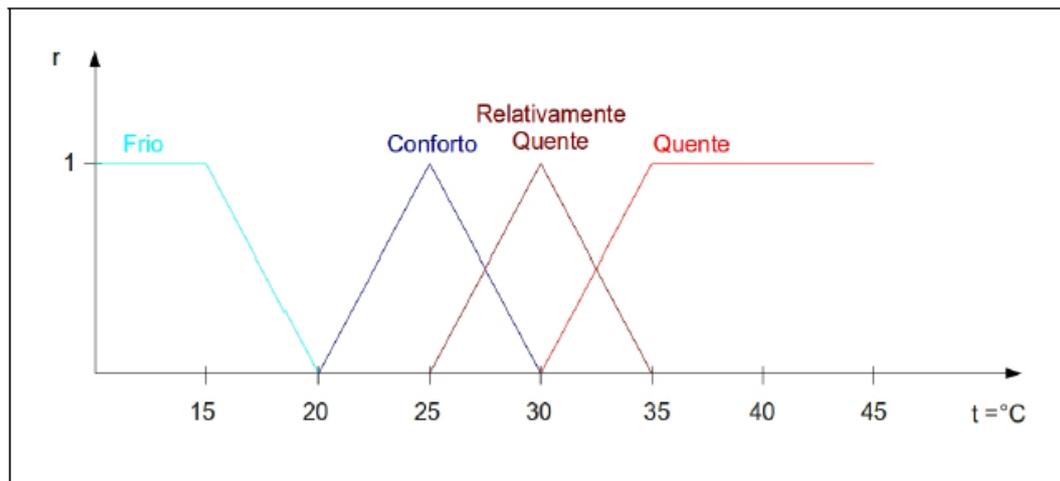


Figura 3.6 - Exemplo de funções de pertinência.

Na Figura 3.6, observa-se com mais nitidez o que vem a ser o limite Fuzzy (nebuloso), demonstrado pela intersecção dos intervalos das respectivas funções de pertinência.

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

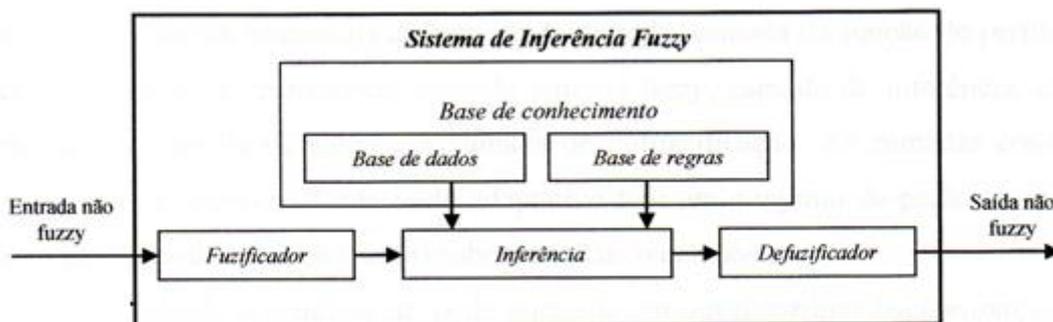


Figura 3.7 - Fluxograma conceitual do sistema Fuzzy.

Fuzificador: 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 como em KOSKO, B., (1997).

Defuzificador: é a etapa em que os valores *Fuzzy* são convertidos me valores reais tendo assim um conjunto de saída matematicamente definido.

3.2.1 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, S. O., 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, S. O., 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:

Etapa 1 - 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:

$$\mu_{A_1}^k(x_1), \mu_{A_2}^k(x_2), \dots, \mu_{A_j}^k \quad (3.22)$$

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

Etapa 2 - 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 Expressão 3.23.

$$D^{(k)} = \min[\mu_{A_1}^k(x_1), \mu_{A_2}^k(x_2), \dots, \mu_{A_j}^k(x_j)], \quad (3.23)$$

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

Etapa 3 -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*.

$$s^{(k)} = \min[D^k, \mu_{B_i}(y)], \quad (3.24)$$

Etapa 4 -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”.

$$\mu_{B'} = \max[s^{(k)}]. \quad (3.25)$$

Etapa 5 -Desfuzzificação

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.

CAPÍTULO 4

4 Modelos Desenvolvidos

Este capítulo propõe-se a descrever e demonstrar a elaboração e construção dos modelos de previsão de potência abordados nesse trabalho, mostrando as principais diferenças construtivas dos modelos que utilizam RNAs e Lógica Fuzzy.

Para tal, foram desenvolvidos quatro modelos, dos quais dois utilizaram as ferramentas de inteligência artificial baseadas nas redes neurais, sendo esses, os modelos M1a e M2a, e os dois últimos, utilizaram as ferramentas de inteligência artificial dos sistemas de inferência Fuzzy, sendo esses os modelos M1b e M2b.

Assim esta descrição será feita em duas etapas, na primeira etapa são abordadas as descrições dos modelos baseados nas RNAs e na segunda são abordadas as descrições dos modelos fundamentados pela Lógica Fuzzy.

Dessa forma esse capítulo tem suma importância para o entendimento das aplicações das ferramentas de IA. No que diz respeito às previsões de potência, objetivo principal dessa dissertação.

4.1 Criação, construção e adequação do banco de dados responsável pela alimentação dos modelos

Anteriormente à construção e a aplicação com análises posteriores dos modelos previsores, foi necessária a utilização de bancos de dados relativos aos parques eólicos típicos utilizados nesta dissertação. Como já descrito na introdução, utilizaram-se dois parques, o Parque 01 e o Parque 02, com características já citadas anteriormente.

Em que a janela temporal utilizada para formação das bases de dados se estendeu de 01/04/2010 até 10/04/2014, ou seja, mais de quatro anos de aferição nos parques, nos quais, os seguintes dados estavam disponíveis:

1) Dados relativos à temporização da base: Dia/ Mês/ Ano/ Hora (*Universal Time Coordinated* - UTC)

2) Dados relativos ao vento: Velocidade Média do vento,

	Direção Média do vento e
	Potência média do vento
3) Dados relativos às Turbinas Eólicas:	Número de Máquinas Geratrizes.

Com relação à montagem dos padrões e posterior alimentação dos modelos, foi necessária uma análise inicial nas bases de dados, buscando incoerências específicas presentes na mesma. Nessa etapa se procurou na base por pontos “Outliers”, ou seja, que não fazem parte da distribuição entre as variáveis do problema abordado. Para tal procura, desenvolve-se um filtro em MATLAB sendo constituído em duas etapas:

(1ª Etapa) Procura por valores negativos de velocidade e potência presentes nos bancos dos Parques 01 e 02.

Nesta etapa os valores incoerentes encontrados nas bases de ambos os parques foram eliminados, e assim as bases livraram-se desse mau condicionamento.

(2ª Etapa) Procura por pontos fora de uma faixa condizente.

Nesta etapa se estabeleceu uma faixa condizente com limites máximo e mínimo para a potência relativa ao vento sobre análise, levando em conta nesta fase a média e o desvio padrão, sendo baseada na utilização da tabulação de uma distribuição normal, encontrada em MEYER, P. L. (2000). Um resumo desta etapa é feito a seguir:

Sendo a variância o parâmetro que descreve como um indivíduo varia em seu grupo, e o desvio padrão uma métrica da dispersão desse grupo, tal dispersão possui uma variância associada, representada pelo quadrado deste desvio. Sendo algumas características importantes dessas duas grandezas descritas a seguir:

1ª) Considerando um conjunto de dados que possui forma semelhante à forma de sino, ou seja, adotando que o conjunto possua distribuição normal ou gaussiana, e calculando-se a média (μ), notasse que a função que delimita o conjunto é simétrica em relação a essa média.

Assim a distribuição é aproximada pela função $f(K) = (K - \mu)^2$ tomando dois valores opostos para o balizador (K) que percorrerá todo o conjunto, conforme mostrado pelas Expressões 4.1 e 4.2 abaixo:

$$K_1 = (\mu + a), e \quad (4.1)$$

$$K_2 = (\mu - a) \quad (4.2)$$

Assim, aplicando ambos os valores do balizador na função $f(x)$ verifica-se a simetria:

$$f(K_1) = f(K_2) \quad (4.3)$$

$$(\mu + a - \mu)^2 = (\mu - a - \mu)^2 \quad (4.4)$$

$$(a)^2 = (-a)^2 \quad (4.5)$$

$$a = a \quad (4.6)$$

2ª) Outra característica importante ainda neste enfoque, diz respeito à interpretação geométrica do desvio padrão (σ).

Desta forma observa-se que para $K = \mu$, o gráfico de $f(K)$ é descendente, concavidade para baixo e quando K aproxima-se dos extremos i.e. $+\infty$ e $-\infty$ $f(k) = 0$ (assintoticamente). Como a função gaussiana é uma função par, ($f(K) \geq 0; \forall K \in R$) então o gráfico de $f(K)$ tem concavidade para cima.

Assim, percebe-se que existem mudanças de concavidade e com isso é notória a presença de pontos de inflexão. De forma que para calcular tais pontos, basta calcular a segunda derivada da função e verificar que a mesma é nula, $f''(K) = 0$. Com isso é possível encontrar pontos de inflexão pertencentes ao seguinte intervalo:

$$K = \mu \pm \sigma \quad (4.7)$$

Desta forma, tal enfoque é passível da seguinte conclusão:

Para σ unidades à esquerda e à direita da média (μ) a concavidade de $f(K)$ mudará, então para um valor de ($\sigma \geq \mu$) o gráfico tenderá ser achatado já para o contrário, ou seja, para ($\sigma \leq \mu$) o gráfico tenderá a ser pontiagudo.

3ª) Outra Característica bastante importante, é quando se deseja calcular o valor da probabilidade numa amostra específica de um conjunto sem necessariamente precisar saber sobre sua média e seu desvio padrão.

Para tal um conceito é relevante e extremamente necessário, a Tabulação, este conceito é útil quando se deseja calcular o valor da função densidade de probabilidade em um intervalo cuja derivada da função não é igual à derivada da função densidade de probabilidade neste mesmo intervalo, assim não é possível aplicar o teorema fundamental do cálculo, e para resolver esse problema, a função terá que ser tabelada.

A fim de mostrar tal artifício, uma nova função densidade de probabilidade é então definida sendo agora considerado apenas o intervalo que se estende de $(-\infty, a)$, cuja nova função é chamada de $\Phi(S)$.

Em que:

$$P(a \leq K \leq b) = \Phi(b) - \Phi(a) \quad (4.8)$$

Com isso a utilidade principal da tabulação acima é devida ao fato de que, se K tiver qualquer distribuição normal $N(\mu, \sigma^2)$, a função tabelada $\phi(S)$ pode ser empregada para calcular probabilidades associadas a K .

Aplicando a definição de uma distribuição normal ao intervalo definido anteriormente, tem-se:

$$P(a \leq K \leq b) = P((a - \mu)/\sigma \leq Y \leq (b - \mu)/\sigma) \quad (4.9)$$

$$P(a \leq K \leq b) = \phi\left(\frac{b-\mu}{\sigma}\right) - \phi\left(\frac{a-\mu}{\sigma}\right) \quad (4.10)$$

Tomando o conceito de probabilidade complementar, tem-se:

$$\phi(-K) = 1 - \phi(K) \quad (4.11)$$

Sendo esta última função bastante útil, pois na maioria das tabulações a função k só é descrita para valores positivos de K .

Finalmente para calcular a probabilidade no intervalo tabulado, procede-se da seguinte maneira:

$$P(\mu - g\sigma \leq K \leq \mu + g\sigma) = P\left(-g \leq \frac{K-\mu}{\sigma} \leq g\right) \quad (4.12)$$

$$\phi(k) = \phi(K) - \phi(-K) \quad (4.13)$$

Desta forma para valores de $g > 0$, tem-se:

$$P(\mu - g\sigma \leq K \leq \mu + g\sigma) = 2\phi(g) - 1 \quad (4.14)$$

Com isso observa-se que a probabilidade acima, após a aplicação da tabulação da distribuição normal é independente da média e do desvio padrão, ou seja, a probabilidade de que uma variável aleatória com distribuição normal $N(\mu, \sigma^2)$ tome valores até g desvios padrões do valor esperado depende de g e é dada pela Expressão acima.

No filtro fora considerado uma área efetiva dos bancos de dados correspondente a 90% dos dados de potência média horária, ou seja, o valor de g , variável que delimita o número de desvios padrões considerados fora de 10%, assim, $g = \pm 0,1$; discriminando a região efetiva de coerência dos dados presa a Expressão 4.15.

$$P(\mu - 0,1\sigma \leq K \leq \mu + 0,1\sigma) = P\left(-0,1 \leq \frac{K-\mu}{\sigma} \leq 0,1\right) \quad (4.15)$$

Outro fator importante, diz respeito ao número mínimo de pontos necessários para que o filtro considere uma faixa de desvio coerente, no script esse limite mínimo foi determinado em 4 pontos, (escolha de caráter totalmente empírico). Assim, para regiões

em que o número de pontos em questão for menor que 4 esses pontos serão descartados pelo filtro, ficando fora dos limites mínimo e máximo da faixa de desvio padrão coerente.

Onde, de forma a demonstrar a efetividade da filtragem sobre as bases de dados, as Figuras 4.1 e 4.2 descrevem o comportamento da velocidade média horária dos parques em função da potência média dos mesmos após a realização da filtragem.

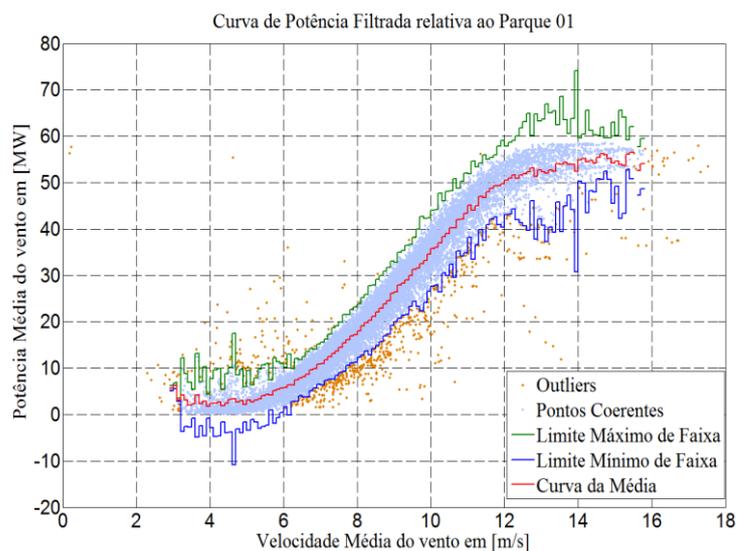


Figura 4.1 - Curvas de potência do Parque 01 em análise posterior à filtragem.

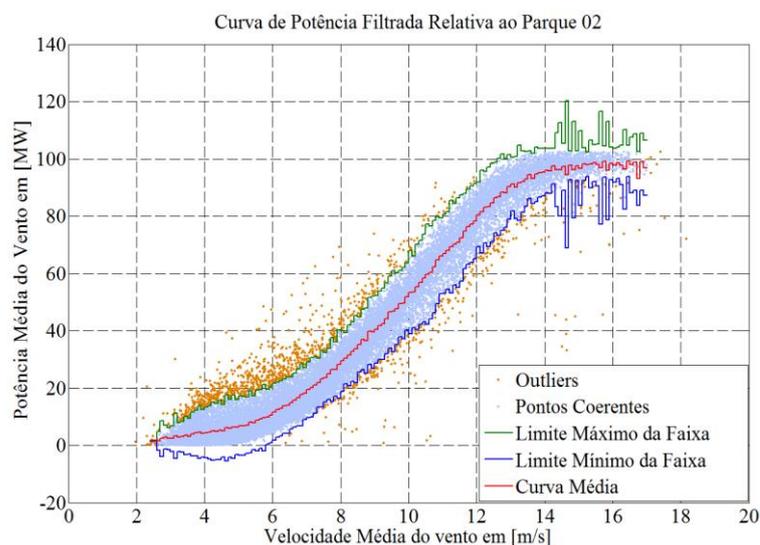


Figura 4.2 - Curva de potência do Parque 02 em análise posterior à filtragem.

As Figuras 4.1 e 4.2 mostram a ação do filtro em relação às bases de dados. Nos gráficos é possível enxergar a região viável das curvas de potência bem como os patamares mínimo e máximo descritos pelo desvio padrão, além da curva média de potência no centro das curvas.

A aplicação do filtro as bases disponíveis reduziu o número de dados conforme pode ser visto pela Tabela 4.1, abaixo:

Tabela 4.1 - Bases dos parques após filtragem.

Base de dados	Temporização (início – término)
Parque 01	(14h) 02/04/2010 – (9h) 10/11/2012
Parque 02	(10h) 05/10/2010 – (0h) 08/04/2014

A seguir, seis figuras mostram a distribuição histórica dos dados dos respectivos parques, as Figuras 4.3(a) e 4.3(b), analisam a velocidade média, já as Figuras 4.4(a) e 4.4(b) analisam a direção média e as Figuras 4.5(a) e 4.5(b), analisam a potência média.

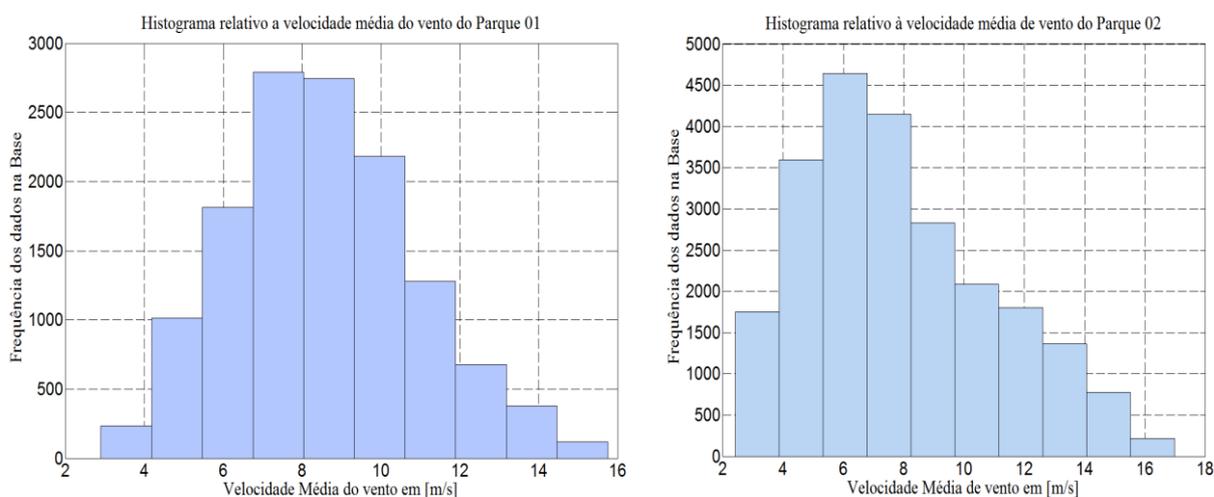


Figura 4.3 - Distribuição histórica da Velocidade média (a) no Parque 01 e (b) no Parque 02.

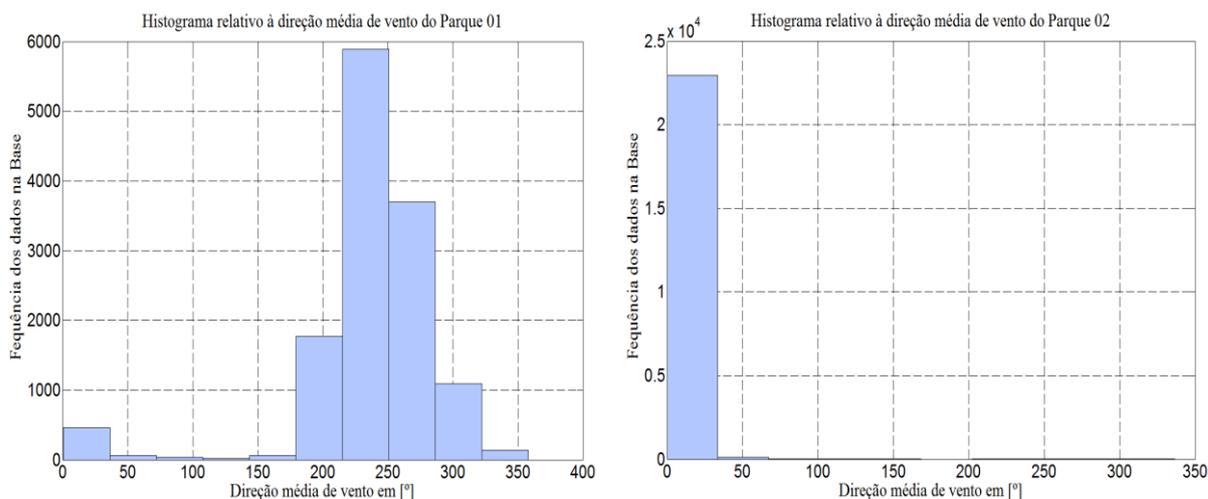


Figura 4.4 - Distribuição histórica da Direção média (a) no Parque 01 e (b) no Parque 02.

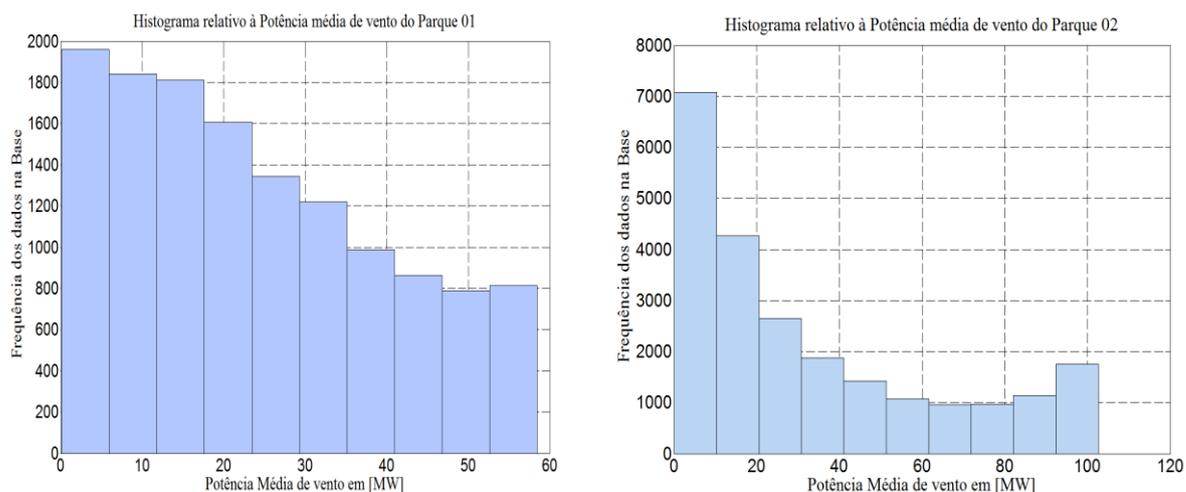


Figura 4. 5 - Distribuição histórica da Potência média (a) no Parque. 01 e (b) no Parque 02

A inserção dos bancos de dados nos modelos fora feita a partir da construção de padrões de condicionamento, em que estes padrões foram divididos em dois conjuntos básicos: o conjunto de aprendizagem, utilizado para o treinamento dos modelos e o conjunto de simulação, utilizado na comparação da eficiência entre os modelos.

O conjunto de aprendizagem fora dividido em subconjuntos menores denominados treinamento, teste e validação sendo a porcentagem discriminada respectivamente para cada um, igual a 60%, 20% e 20% dos dados do conjunto de aprendizagem. Outro dado importante diz respeito à temporização dos conjuntos de aprendizagem e simulação, sendo dispostos nos dois parques, aproximadamente 2 anos no Parque 01 e 3 anos no Parque 02 para o período aprendizagem. Já para o período de simulação fora adotado aproximadamente um ano em ambos os parques.

Tal disposição é mostrada na Tabela 4.2:

Tabela 4. 2 - Divisão dos padrões de alimentação dos modelos.

Conjuntos	Aprendizagem (Nº de Padrões)	Simulação - (Nº de Padrões)
Parque 01	(14h) 02/04/2010 - (22h) 30/12/2011 (2064 padrões)	(23h) 01/01/2012 – (9h) 10/11/2012 (3664 Padrões)
Parque 02	(10h) 05/10/2010 - (23h) 29/03/2013 (3950 Padrões)	(23h) 01/04/2013 - (0h) 08/04/2014 (1390 Padrões)

Pode-se perceber pela Tabela 4.2 que o filtro age de forma muito diferente em ambos os parques, atuando essencialmente nos conjuntos de aprendizagem dos dois parques, o que no capítulo de resultados ficará evidente no desempenho dos modelos relativos a cada parque em questão.

Com relação à montagem dos Padrões que alimentaram os modelos, os mesmos foram formulados de acordo com a Tabela 4.3 a seguir:

Tabela 4.3 - Forma do padrão de alimentação dos modelos.

Padrão de alimentação dos modelos dos Parques (01 e 02)						
Valores de Saída do Padrão				Valores de Entrada do Padrão		
Cod. Data do 1º elemento previsto com 5 dígitos	Pot. Médias Previstas	Vel. Médias Previstas	Dir. Médias Previstas	Cod. Data do 1º elemento previsto com 3 dígitos	Vel. Médias do histórico da base	Dir. Médias do histórico da base

Em que:

O campo [Cod. Data do 1º elemento previsto]: é relativo ao código da data do primeiro elemento previsto, sendo composto pela seguinte estrutura mostrada pela Tabela 4.4:

Tabela 4.4 - Estrutura do campo Cod.Data do 1º elemento previsto com 5 dígitos.

Cod. Data do 1º elemento previsto com 5 dígitos				
Hora na forma decimal de $\hat{v}(t+1)$	Dia de $\hat{v}(t+1)$	Mês de $\hat{v}(t+1)$	Ano de $\hat{v}(t+1)$	Hora (UTC) de $\hat{v}(t+1)$

O campo [Pot. Médias Previstas]: é relativo às 24 séries horárias de Potências médias previstas como mostrado pela Expressão 4.16.

$$\text{Potências Médias Previstas} = \{\hat{P}(t+1), \dots, \hat{P}(t+24)\} [MW] \quad (4.16)$$

O campo [Vel. Médias Previstas]: é relativo às 24 séries horárias de velocidades médias previstas como mostrado pela Expressão 4.17.

$$\text{Velocidades Médias Previstas} = \{\hat{v}(t+1), \dots, \hat{v}(t+24)\} [m/s] \quad (4.17)$$

O campo [Dir. Médias Previstas]: é relativo às 24 séries horárias de direções médias previstas como mostrado pela Expressão 4.18.

$$\text{Direções Médias Previstas} = \{\hat{d}(t+1), \dots, \hat{d}(t+24)\} [^\circ] \quad (4.18)$$

O campo [Cod. Data do histórico da Base]: é relativo ao código da data dos elementos do histórico real sendo composto pela seguinte estrutura mostrada pela Tabela 4.5:

Tabela 4.5 - Estrutura do campo Cod.Data do 1º elemento previsto com 3 dígitos.

Cod. Data do 1º elemento previsto com 3 dígitos		
Hora (UTC) de $\hat{v}(t+1)$	Mês no formato (senoidal) de $\hat{v}(t+1)$	Mês no formato (cossenoide) de $\hat{v}(t+1)$

O campo [Vel. Médias do histórico da base]: é relativo às 24 séries horárias de velocidades médias reais que já aconteceram como mostrado pela Expressão 4.19.

$$\text{Velocidades Médias reais} = \{\hat{v}(t-23), \dots, \hat{v}(t)\} [m/s] \quad (4.19)$$

O campo [Dir. Médias do histórico da base]: é relativo às 24 séries horárias de direções médias reais que já aconteceram no histórico como mostrado pela Expressão 4.20.

$$\text{Direções Médias reais} = \{\hat{d}(t-23), \dots, \hat{d}(t)\} [^\circ] \quad (4.20)$$

Observação:

As séries abordadas nesses padrões foram montadas de forma a não utilizar o primeiro elemento da respectiva série anterior, logo, as séries consequentes terão (n-1) elementos enquanto as séries antecedentes terão (n) elementos. Logo, para ilustrar o que foi dito mostra-se como exemplo as Expressões 4.21, 4.22, 4.23, 4.24, 4.25 e 4.26.

$$v_{1h} = \{v(t-23), \dots, v(t+n)\}. \quad (4.21)$$

$$v_{2h} = \{v(t+1), v(t+2), \dots, v(t+n)\}. \quad (4.22)$$

.

.

.

$$v_{24h} = \{v(t+23), v(t+24), \dots, v(t+n)\}; \quad (4.23)$$

e

$$d_{1h} = \{d(t), d(t+1), \dots, d(t+n)\}. \quad (4.24)$$

$$d_{2h} = \{d(t+1), d(t+2), \dots, d(t+n)\}. \quad (4.25)$$

.

.

.

$$d_{24h} = \{d(t+23), d(t+24), \dots, d(t+n)\}. \quad (4.26)$$

4.2 Modelos baseados em RNAs

Para a previsão de potência, foram desenvolvidos dois modelos, nos quais só são utilizadas redes neurais artificiais em que, para a formação dos mesmos procedeu-se da seguinte forma:

Inicialmente, procurou-se escolher de forma adequada as entradas e as saídas dos modelos que só utilizaram RNAs na sua estrutura. Como o objetivo foi a previsão de potência, tais modelos estão fundamentados na curva de potência do respectivo parque utilizado. Assim, esta curva estabelece uma relação particular entre as velocidades médias de vento e as direções médias de vento com as respectivas potências médias extraídas pela turbina, de acordo com o vento incidente nas pás da mesma.

Para melhorar a relação entre velocidades e direções médias previstas, foram utilizadas mais três entradas, sendo elas características do 1º elemento previsto, Sendo escolhidos como entradas: tais horas, mês em formato senoidal, mês em formato cossenoide, velocidades médias horárias e direções médias horárias e tais potências médias horárias como saídas.

Para a criação de tais modelos previsores, foram utilizadas duas redes neurais ordenadas em cascata. Estando a primeira RNA na entrada dos modelos, que objetivou a previsão de velocidades médias e/ou direções médias, e a segunda RNA localizada na saída dos modelos, objetivando assim a previsão horária de potências médias de vento.

Desta forma, os valores de saída previstos pela segunda rede estão altamente associados aos valores previstos de saída da primeira rede, pois os valores de saída, i.e. as previsões da primeira RNA servem de entrada para a segunda rede neural.

O horizonte de análise escolhido foi um horizonte de 24h, logo, as previsões desses modelos terão passo horário iniciando na hora um e finalizando na hora 24.

Nessa dissertação foram desenvolvidos dois modelos que só utilizam RNAs na sua estrutura, tais modelos foram denominados de M1a e M2a, e a diferença entre os mesmos esta só no número de entradas, esses modelos serão descritos a seguir:

4.2.1 Modelo M1a de previsão de potência

O modelo M1a consiste de duas RNAs postas em cascata, sendo a primeira a RNA1 com vinte e sete variáveis de entrada ($[h(t+1)]+[Mês(t+1)(seno)]+[Mês(t+1)(cosseno)] +$

[vinte e quatro séries horárias de velocidades médias do vento reais]) e vinte e quatro variáveis de saída (séries horárias de velocidades médias do vento previstas).

Já a segunda RNA que simula as curvas de potências de previsão das respectivas horas em questão, é denominada CP-RNAM1a com uma variável de entrada para cada hora respectiva (séries horárias de velocidades previstas da RNA1) e uma variável de saída para cada hora respectiva (séries horárias de potências previstas pela CP-RNAM1a da hora em questão), em que, cada rede neural disposta neste modelo será descrita posteriormente.

Demonstrando de uma melhor forma como foi montado o modelo M1a, sua arquitetura de construção é mostrada abaixo pela Figura 4.6.

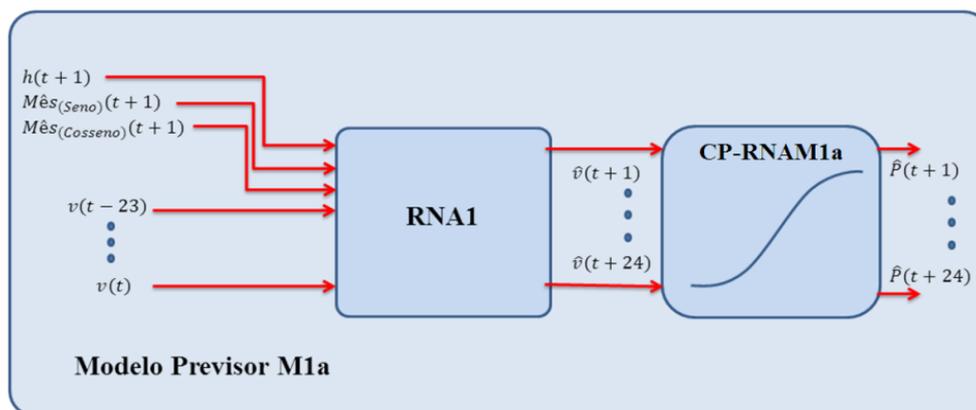


Figura 4. 6 - Arquitetura de construção do modelo M1a.

4.2.1.1 Definindo a RNA1

Como o objetivo inicial desse modelo foi uma previsão horária de velocidades médias de vento, a RNA1 ficou responsável por esta previsão, tendo a tarefa de alimentar a CP-RNAM1A do modelo M1a com suas previsões.

Para tal, a mesma consistiu de uma rede neural de previsão de velocidades médias de vento com horizonte de 24h, ou seja, o passo de previsão variou da hora um até a hora vinte e quatro. Assim, para um valor de entrada $v(t)$ a RNA1 irá prever valores conforme descrito pela Expressão 4.27.

$$\text{Previsões} = \{\hat{v}(t+1), \hat{v}(t+2), \dots, \hat{v}(t+24)\} \quad (4.27)$$

No que diz respeito à preparação da RNA1, o tamanho dos conjuntos utilizados dentro do padrão montado, seguiu o que fora descrito no conjunto de aprendizagem. Para garantir uma igualdade de influências entre todas as variáveis no treinamento da rede, foi

necessária a normalização dos conjuntos de entrada e saída. Para entender tal fato, é preciso lembrar que as funções de ativação em um neurônio artificial são definidas em faixas limitadas. Assim, normalizando os conjuntos, estes valores de entrada e saída são definidos nestas funções em seus extremos segundo GOUVEIA, H. T. V. (2011).

Com base no que foi dito acima, neste trabalho utilizou-se a função de normalização conforme descrito pela Expressão 4.28, com valores definidos no intervalo amostral fechado de [0,1].

$$x_{Norm} = \frac{x(t) - x_{Min.}}{x_{Máx.} - x_{Mín.}} \quad (4.28)$$

Quanto à escolha da RNA1 e sua respectiva parametrização, escolheu-se uma rede do tipo MLP (*Multi layer perceptron*), que utiliza retro propagação do erro (*Feed -forward backpropagation error*), com a seguinte arquitetura: [27 – 14:34 -24], conforme descrito abaixo:

- 27 entradas
- [14 até 34 neurônios] na camada oculta.
- [24 neurônios] na saída

Sobre a escolha dessa arquitetura, foi adotado o procedimento definido em AQUINO, R. R. B. et.al (2009), em que, o número de nodos da camada oculta, é discriminado através de um processo de tentativas, nas quais, busca-se um melhor desempenho por parte da rede. Em que tal procedimento é discriminado a seguir:

- 1) Primeiramente, foi criada uma rede com quatorze neurônios na camada oculta;
- 2) Foram atribuídos pesos aleatórios para todas as conexões da rede, e realizou-se o treinamento da rede através do algoritmo RP (*Resilient Propagation*) e foi calculado o MSE para o conjunto de treinamento, validação e teste;
- 3) O passo anterior foi repetido dez vezes. Após a décima repetição foi calculada a média do MSE para cada conjunto (treinamento, validação e teste);
- 4) Outro neurônio foi adicionado à camada oculta, e os passos 2, 3 e 4 foram repetidos, até a rede possuir trinta e quatro nodos na camada oculta;

Assim, foi escolhida a arquitetura que apresentou menor MSE para o conjunto de validação.

Sobre o método de treinamento que adequou os valores das entradas às suas respectivas saídas, validando assim a aprendizagem por parte da RNA1, utilizou-se o algoritmo “*Resilient Propagation*”, conhecido comumente no simulador como “*Train RP*”. Enfatizando que, o mesmo só foi adotado em preferência ao outro método, “*Train LM*”, que utiliza o algoritmo de Levenberg Marquardt, e é tecnicamente mais preciso que o seu anterior, por questões de esforço computacional.

Tal fato pôde ser notado nas tentativas de implementação das simulações relativas ao treinamento da RNA1, em que as mesmas resultaram em sucessivos erros com a seguinte mensagem, “*Out of Memory*”. Logo, concluiu-se que, seria necessário mais memória para tal nível de precisão, e assim tomou-se a escolha de trocar o algoritmo de treinamento.

Em que, as melhores RNA1, denominadas “RNA1_BEST”, obtida nas inicializações que simularam os treinamentos, nas bases dos Parques 01 e 02 são mostradas nas Figuras 4.7 e 4.8 respectivamente:

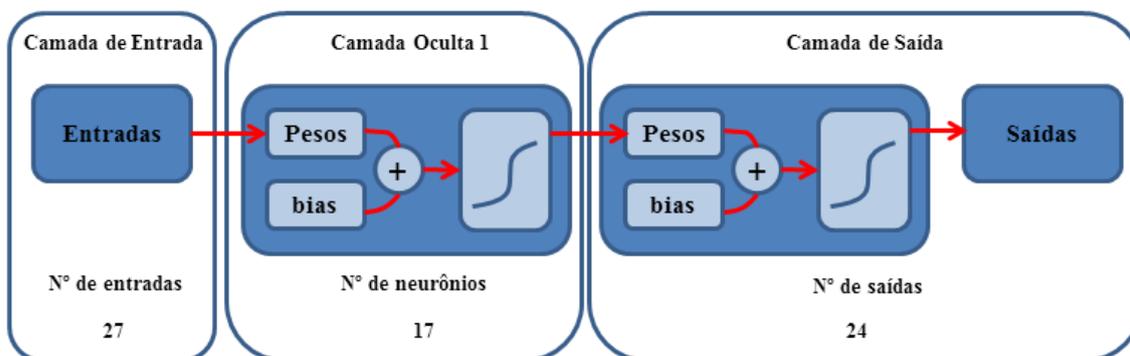


Figura 4.7 - Arquitetura da melhor RNA1 para o Parque 01 escolhida com a execução dos treinamentos.

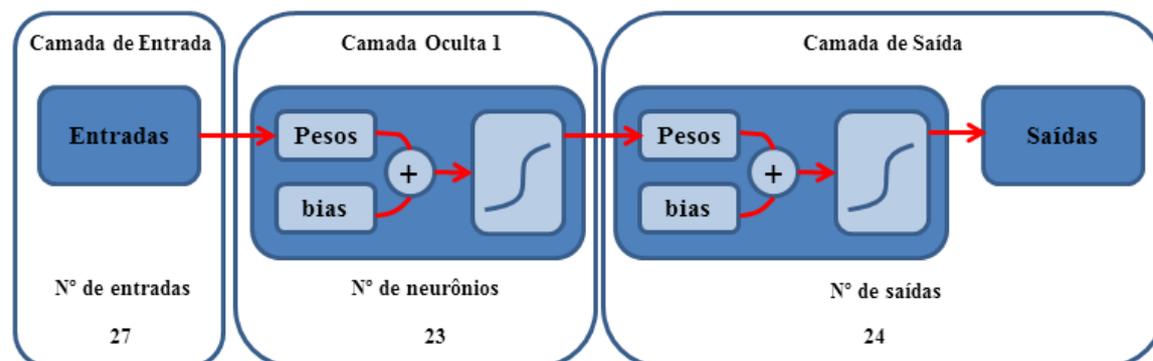


Figura 4.8 - Arquitetura da melhor RNA1 para o Parque 02 escolhida com a execução dos treinamentos.

Das Figuras 4.7 e 4.8, pode-se notar que, para a melhor inicialização, o número de neurônios definidos pela camada oculta foi de 17 para o Parque 01 e 23 para o Parque 02, descrevendo assim a arquitetura da RNA1 após os treinamentos.

Outros resultados importantes relativos a estes treinamentos são descritos pela Figura 4.9 que descreve o desempenho do erro médio absoluto cometido para ambos os parques nas previsões das respectivas RNA1 dos Parques 01 e 02.

Onde os mesmos são mostrados a seguir.

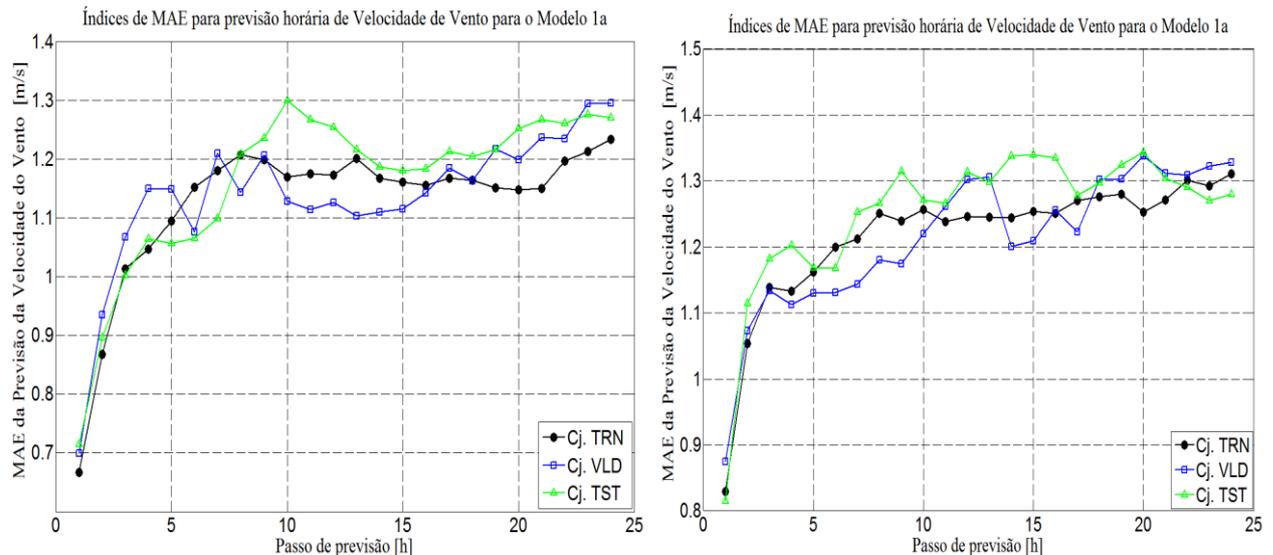


Figura 4.9 - Comportamento gráfico do MAE referente às simulações para o período de aprendizagem da RNA1 (a) aplicado ao Parque 01 e (b) aplicado ao Parque 02.

Para simulação das RNAs foi utilizado o Software MATLAB versão R2013b, e cujo micro computador utilizado possui a seguinte configuração: cpu Inte(R) Core(TM) I7-3770, 3,4GHz, com uma memória total instalada de 8GB de RAM.

4.2.1.2 Definindo a curva de potência do modelo M1a (CP-RNAM1a)

Como já definido anteriormente, a CP é uma RNA que simula a curva de potência nos modelos abordados. Em se tratando do Modelo M1a, a mesma foi denominada CP-RNAM1a. Tal RNA é alimentada pelas saídas da RNA1, em que cada entrada corresponde à série horária de velocidades médias de vento previstas, que através da curva de potência da hora respectiva, terá uma saída que corresponde a série horária de potências médias previstas da hora em questão.

Para a montagem desta CP, foram utilizados os mesmos bancos de dados, visto que os modelos são relativos aos mesmos parques utilizados (Parque01 e Parque 02). Outro

fato importante é que diferentemente do treinamento da RNA1 foram utilizadas uma entrada e uma saída, sendo estas respectivamente velocidades médias do vento e suas correspondentes potências médias. Uma justificativa para isso é que uma curva de potência só necessita de velocidades pareadas com potências, não importando assim a ordem de aparecimento desses dados, seguindo esses preceitos foram executados os treinamentos.

Procedendo a montagem da CP-RNAM1a houve também a definição do tamanho dos conjuntos de aprendizagem abordados dentro do padrão montado a partir dos bancos de dados, em que de forma semelhante seguiu-se o que foi discriminado para o conjunto de aprendizagem na montagem dos bancos de dados.

De forma semelhante, para garantir uma igualdade de influências entre todas as variáveis no treinamento da CP-RNAM1a, foi necessária a normalização dos conjuntos de entrada e saída. Desta forma foi utilizado o mesmo critério de normalização descrito por GOUVEIA, H. T. V. (2011) e mostrado pela Expressão 4.28.

Quanto à escolha das redes que simulam a CP-RNAM1a e sua parametrização, escolheu-se uma rede do tipo MLP (*Multi layer perceptron*), que utiliza retro propagação do erro (*Feed -forward backpropagation error*), com a seguinte arquitetura: [1 – 3:8 – 3:8 – 1], conforme descrito abaixo:

- 1 entrada
- [3 até 8 neurônios] na camada oculta 1
- [3 até 8 neurônios] na camada oculta 2
- [1 neurônio] na saída

Sobre a escolha dessa arquitetura, foi adotado o procedimento definido em AQUINO, R. R. B. et al (2009), onde, o número de nodos das camadas escondidas, foi discriminado através de um processo de tentativas, nas quais, buscou-se um melhor desempenho por parte da CP-RNAM1a. Tal procedimento é discriminado a seguir:

- 1) Primeiramente, foi criada uma rede com duas camadas ocultas tendo em cada uma destas, três neurônios;
- 2) Foram atribuídos pesos aleatórios para todas as conexões da rede, e realizou-se o treinamento da rede através do algoritmo RP (Resilient Propagation) e foi calculado o MSE para o conjunto de treinamento, validação e teste;

- 3) O passo anterior foi repetido trinta vezes. Após a trigésima repetição foi calculada a média do MSE para cada conjunto (treinamento, validação e teste);
- 4) Outro neurônio foi adicionado à camada oculta 2 sendo conservado o número de neurônios da camada oculta 1, e os passos 2, 3 e 4 foram repetidos, até a rede possuir oito nodos na camada oculta 2;
- 5) Outro neurônio foi adicionado à camada oculta 1, e os passos 2,3 e 4 foram repetidos até a rede possuir oito neurônios na camada 1.

Assim, foi escolhida a arquitetura que apresentou menor MSE para o conjunto de validação.

Sobre o método de treinamento que adequou os valores das entradas às suas respectivas saídas, no aprendizado por parte da CP-RNAM1a, utilizou-se o algoritmo “Levenberg Marquardt”, conhecido comumente no simulador como “Train LM”. Enfatizando que o mesmo só foi adotado em preferência ao método “Resilient Propagation” comumente conhecido no simulador como “Train RP” por ser tecnicamente mais preciso e assim atrelar a previsão a melhor precisão possível já que essas redes localizam-se na saída do modelo M1a.

Uma diferença importante notada na construção dessa rede foi o número de inicializações, que neste caso foram divididas em duas etapas. Na primeira etapa foram feitas 10 inicializações, com o intuito de estabelecer a melhor arquitetura para a CP-RNAM1a. Assim, com a melhor arquitetura definida procedeu-se a segunda etapa, em que foram realizadas 100 inicializações, com o objetivo de escolher-se a melhor das redes com melhor a arquitetura definida.

Após os treinamentos, as melhores CP-RNAM1a, denominadas “CP-RNAM1a_BEST”, obtidas nas inicializações que simularam os treinamentos, nas bases dos Parques 01 e 02 são mostradas nas Figuras 4.10 e 4.11 respectivamente:

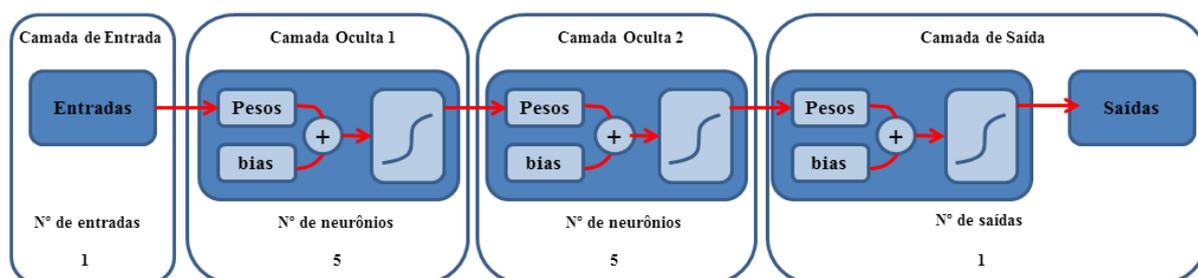


Figura 4. 10 - Arquitetura da melhor CP-RNAM1a para o Parque 01 escolhida com a execução dos treinamentos.

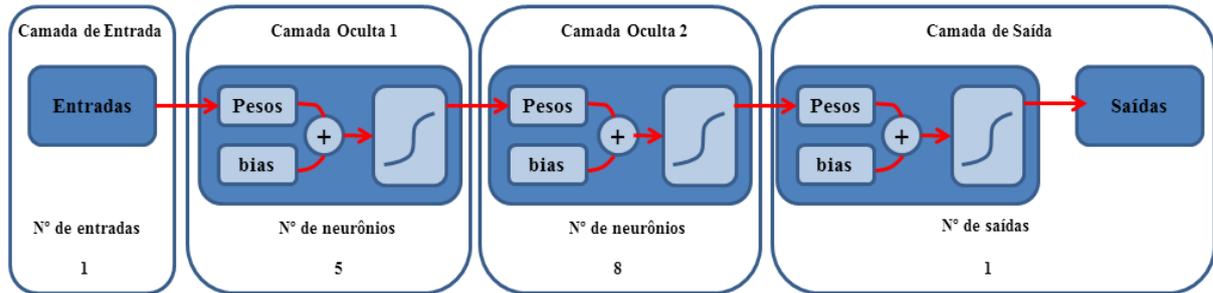


Figura 4.11 - Arquitetura da melhor CP-RNAM1a para o Parque 02 escolhida com a execução dos treinamentos.

Nas Figuras 4.10 e 4.11, pode-se notar que, para a melhor inicialização, o número de neurônios das camadas ocultas 1 e 2 foram respectivamente 5 e 5 para o Parque 01 e 5 e 8 para o Parque 02, descrevendo assim a arquitetura da CP-RNAM1a após os treinamentos.

A Figura 4.12 mostra uma comparação entre o histórico existente e o conjunto efetivamente treinado para ambos os parques 01 e 02, assim pode-se ter uma ideia da eficiência do treinamento.

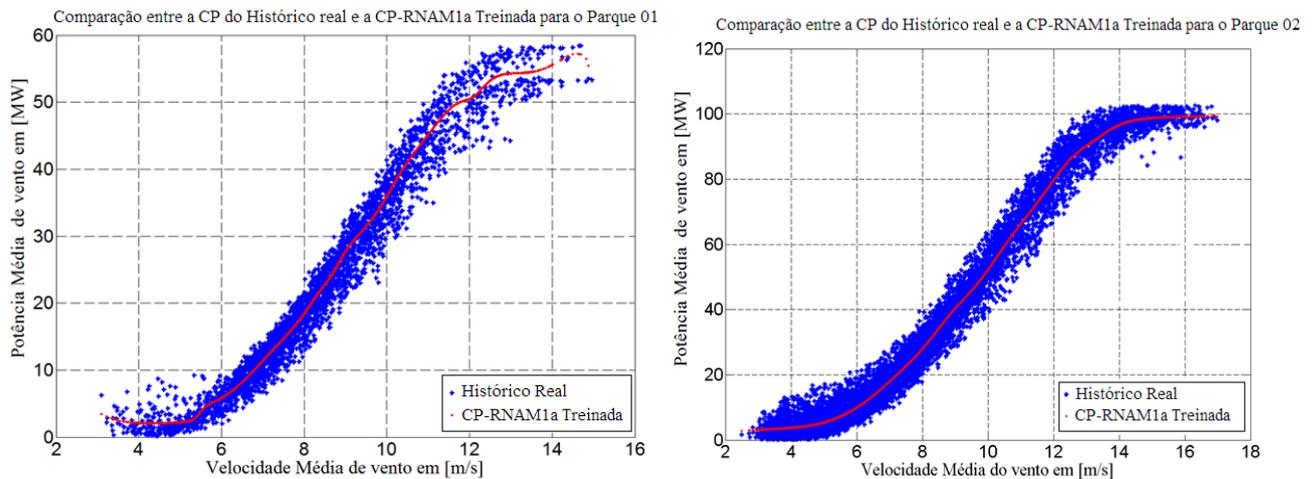


Figura 4.12 - Comparação entre o histórico e a curva CP-RNAM1a treinada pelo modelo M1a (a) para o Parque 01 e (b) para o Parque 02.

Outros resultados importantes relativos a estes treinamentos são descritos Figura 4.13 que apresentam o desempenho do erro médio absoluto cometido para ambos os parques nas previsões das respectivas CP-RNAM1a em que os mesmos são mostrados a seguir:

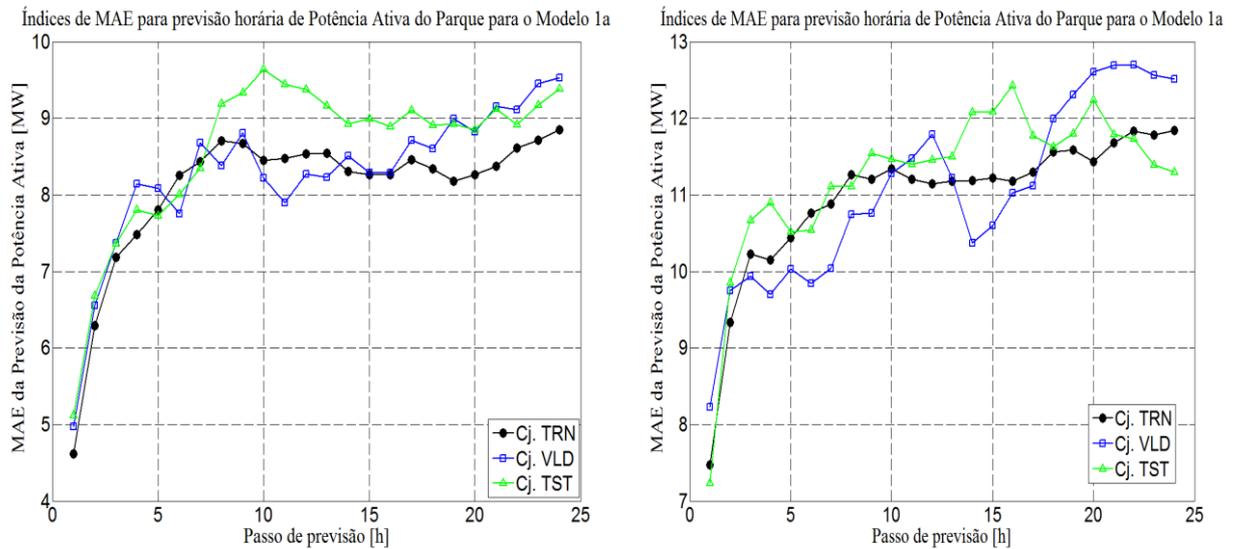


Figura 4.13 - Comportamento gráfico do MAE referente às simulações para o período de aprendizagem da CP-RNAM1a aplicado em (a) para Parque 01 e em (b) para o Parque 02.

4.2.2 Modelo M2a de previsão de potência

O modelo M2a consiste em duas RNAs postas em cascata, sendo a primeira a RNA2 com cinquenta e um conjuntos de variáveis de entrada, sendo estas ($[h(t+1)] + [Mês(t+1)(seno)] + [Mês(t+1)(cosseno)] + [vinte e quatro séries horárias de velocidades médias do vento reais] + [vinte e quatro séries horárias de direções médias do vento reais]$) e 48 variáveis de saída, sendo estas ($[vinte e quatro séries horárias de velocidades médias do vento previstas] + [vinte e quatro séries horárias de direções médias do vento previstas]$).

A segunda RNA, que simula as curvas de Potência de previsão das respectivas horas em questão, denominada CP-RNAM2a com duas variáveis de entrada para cada hora respectiva, sendo elas: as séries horárias respectivas de velocidades e direções médias previstas pela RNA2 e uma variável de saída para cada hora respectiva, sendo esta, a série horária de Potências Previstas pela CP-RNAM2a da hora em questão. Cada RNA disposta neste modelo será minuciosamente descrita posteriormente.

De forma a expressar a ideia de como foi montado o modelo M2a, sua arquitetura de construção é mostrada pela Figura 4.14.

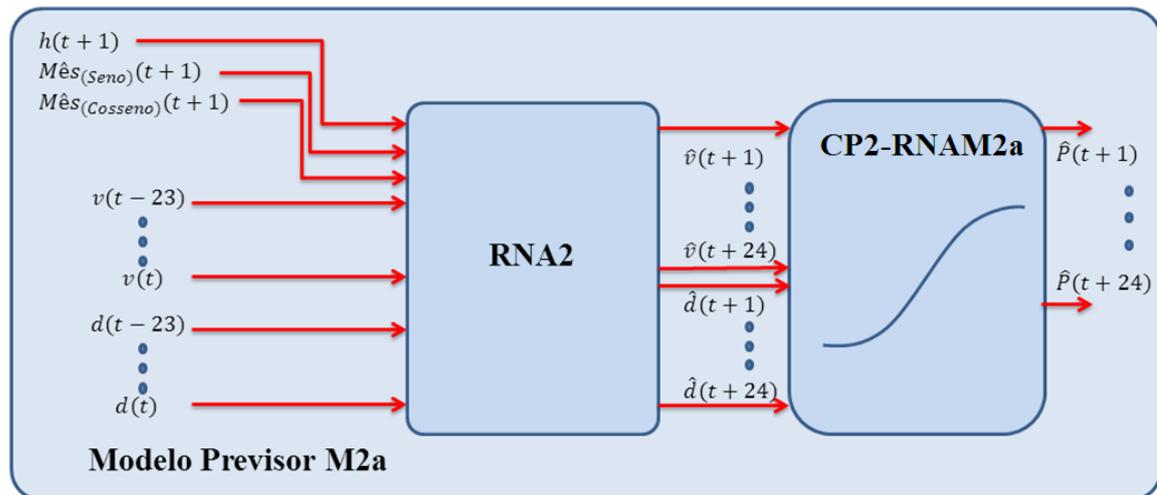


Figura 4.14 - Arquitetura de construção do modelo M2a.

Dessa forma, pode-se perceber que, uma das principais diferenças do modelo M2a em relação ao modelo M1a é o número de entradas, fator este, responsável pela desigualdade em termos de desempenho entre os dois modelos. Isso será mostrado posteriormente no capítulo de resultados deste trabalho.

4.2.2.1 Definindo a RNA2

Como o objetivo inicial desse modelo foram previsões horárias de velocidades médias de vento e direções médias de vento, a RNA2 ficou responsável por esta predição, tendo a tarefa de alimentar a RNA posterior do modelo M2a com suas previsões.

Para tal, a mesma consistiu de uma rede neural de previsão de velocidades e direções médias de vento com horizonte de 24h, ou seja, o passo de previsão variou da hora um até a hora 24. Assim para valores de entrada $v(t)$ e $d(t)$ a RNA2 irá prever valores de velocidades e direções médias, conforme descrito pela Expressão 4.29:

$$\text{Previsões} = \{\hat{v}(t+1), \hat{v}(t+2), \dots, \hat{v}(t+24), \hat{d}(t+1), \hat{d}(t+2), \dots, \hat{d}(t+24)\} \quad (4.29)$$

De forma semelhante ao definido anteriormente no período de aprendizagem tamanho dos conjuntos, adotou-se a mesma divisão estabelecida para os subconjuntos deste período sendo eles os conjuntos de treinamento, validação e teste.

Da mesma forma que foi feito na RNA1, para garantir uma igualdade de influências entre todas as variáveis no treinamento da RNA2, foi necessária a normalização dos conjuntos de entrada e saída. Sendo utilizado o mesmo critério de normalização que fora discriminado anteriormente na parametrização da RNA1.

Quanto à escolha da RNA2 e sua parametrização, escolheu-se uma rede do tipo MLP (*Multi layer perceptron*), que utiliza retro propagação do erro (*Feed -forward backpropagation error*), com a seguinte arquitetura: [51 – 14:40 -48], conforme descrito abaixo:

- 51 entradas
- [38 até 58 neurônios] na camada oculta.
- [48 neurônios] na saída

Sobre a escolha dessa arquitetura, também foi adotado o procedimento definido em AQUINO, R. R. B. et al (2009), em que, o número de nodos da camada oculta, é discriminado através de um processo de tentativas, nas quais, busca-se um melhor desempenho por parte da rede. Em que tal procedimento é discriminado a seguir:

- 1) Primeiramente, foi criada uma rede com quatorze neurônios na camada oculta;
- 2) Foram atribuídos pesos aleatórios para todas as conexões da rede, e realizou-se o treinamento da rede através do algoritmo RP (*Resilient Propagation*) e foi calculado o MSE para o conjunto de treinamento, validação e teste;
- 3) O passo anterior foi repetido dez vezes. Após a décima repetição foi calculada a média do MSE para cada conjunto (treinamento, validação e teste);
- 4) Outro neurônio foi adicionado à camada oculta, e os passos 2, 3 e 4 foram repetidos, até a rede possuir quarenta e oito nodos na camada oculta;

Sobre o método de treinamento que adequou os valores das entradas às suas respectivas saídas, validando assim a aprendizagem por parte da RNA2, utilizou-se o algoritmo “*Resilient Propagation*”, representado no simulador como “*Train RP*”. Enfatizando que o mesmo só foi adotado em preferência ao, “*Train LM*”, que utiliza o algoritmo de Levenberg Marquardt, tecnicamente mais preciso, por questões de esforço computacional.

Tal fato, assim como ocorrido na RNA1 também pôde ser notado nas tentativas de implementação da simulação relativa ao treinamento da RNA2, em que as mesmas resultaram em sucessivos erros com a seguinte mensagem “*Out of Memory*”. Logo, concluiu-se que seria necessária mais memória para tal nível de precisão, e assim tomou-se a escolha de trocar o algoritmo de treinamento.

As melhores RNA2, denominadas “RNA2_BEST”, obtidas nas inicializações que simularam os treinamentos, nas bases dos Parques 01 e 02 são mostradas pelas Figuras 4.15 e 4.16 respectivamente:

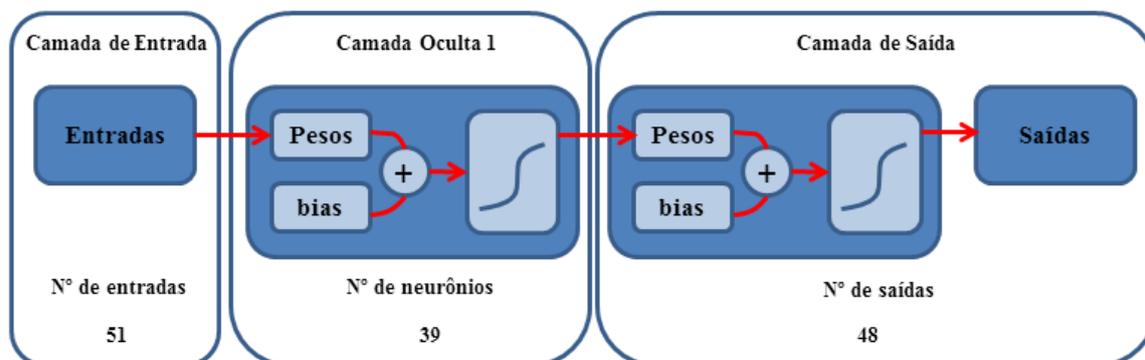


Figura 4.15 - Arquitetura da melhor RNA2 para o Parque 01 escolhida com a implementação dos treinamentos.

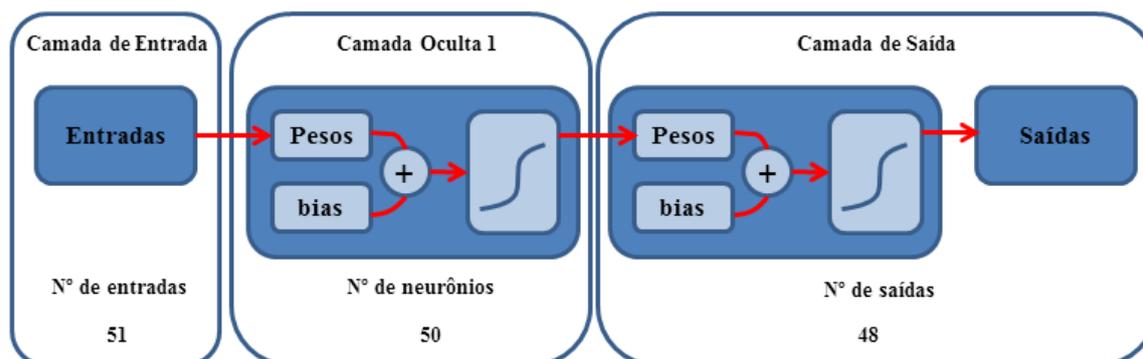


Figura 4.16 - Arquitetura da melhor RNA2 para o Parque 02 escolhida com a implementação dos treinamentos.

Das figuras acima, pode-se notar que, para a melhor inicialização, o número de neurônios definidos pela camada oculta foi de 39 para o Parque 01 e 50 para o Parque 02, descrevendo assim a arquitetura da RNA2 após os treinamentos.

Os resultados do treinamento são mostrados pela Figura 4.17 que descreve o desempenho do erro médio absoluto realizado em ambos os parques nas previsões da respectiva RNA2.

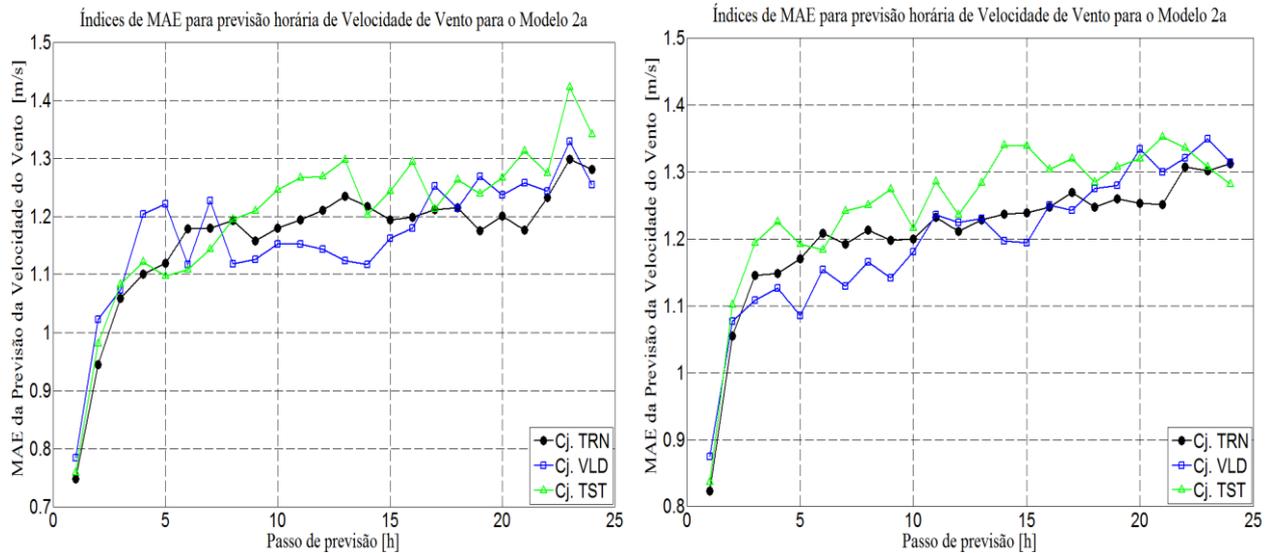


Figura 4. 17 - Comportamento gráfico do MAE da velocidade média referente às simulações para o período de aprendizagem da RNA2 aplicado em (a) para Parque 01 e em (b) para o Parque 02.

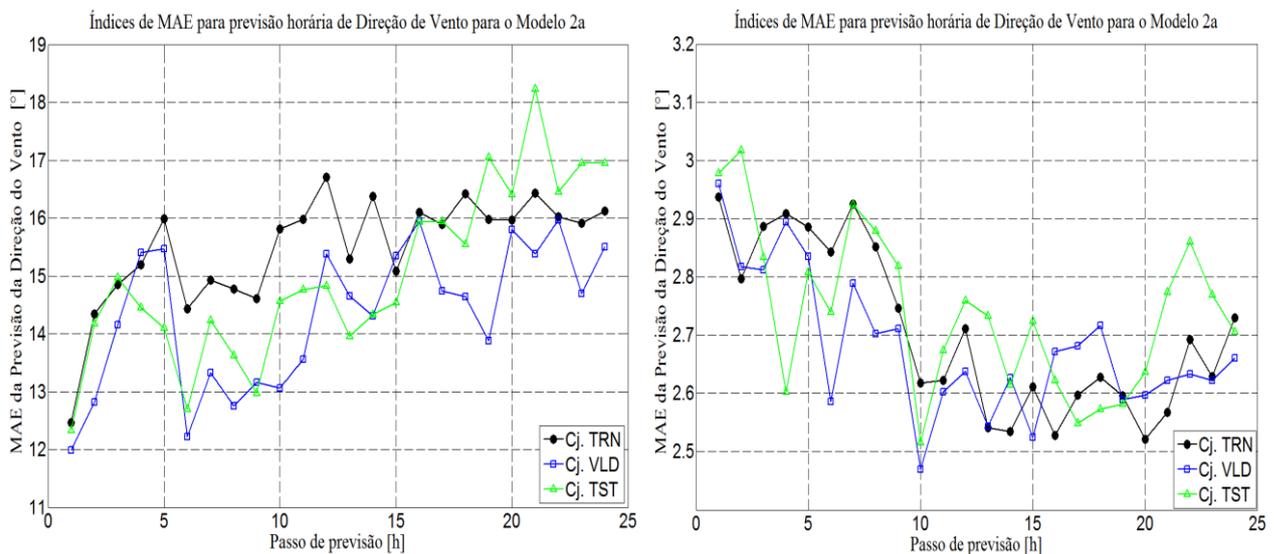


Figura 4. 18 - Comportamento gráfico do MAE da direção média referente às simulações para o período de aprendizagem da RNA2 aplicado em (a) para Parque 01 e em (b) para o Parque 02.

Na Figura 4.17 pode-se ver que o comportamento respectivo nos Parques em questão no período de aprendizagem não possui muita diferença com relação à previsão de velocidades. Com respeito à previsão de direções o comportamento é bastante distinto verificando-se um crescimento do MAE à medida que o passo de previsão cresce no Parque 01 e um decréscimo do MAE para o mesmo horizonte no parque 02.

Analisando a Figura 4.18 é possível perceber a diferença no comportamento do MAE, pois no Parque 01 o erro aumenta ao longo do horizonte de previsão, enquanto que no Parque 02 o erro diminui. Outro fator perceptível é a diferença no patamar do erro

sendo 12° na 1ª hora e subindo até um patamar de 18° no fim do horizonte. Já o Parque 02 o erro é da ordem de 2,9° na 1ª hora e decai para 2,7° no final do horizonte.

4.2.2.2 Definindo a curva de potência do modelo M2a (CP-RNAM2a)

Como já definido anteriormente, uma CP consiste numa RNA que simula a curva de potência nos modelos abordados. Em se tratando do Modelo M2a, a mesma foi denominada CP-RNAM2a, tal RNA é alimentada pelas saídas da RNA2, em que as entradas da CP-RNAM2a correspondem às séries horárias de velocidades médias e direções médias de vento previstas, e suas saídas à série horária de potências médias da hora em questão.

Para a montagem destas CPs foi utilizado o mesmo banco de dados, afinal o modelo é relativo aos mesmos parques utilizados (Parque 01 e Parque 02). Outro fato importante, é que diferentemente da RNA2 não foi utilizado um padrão horário de treinamento, e sim um Padrão simplório com apenas velocidades e direções médias e suas correspondentes potências médias.

Quanto à escolha das entradas do modelo M2a, foi utilizado o critério da correlação para estabelecer qual seria a grandeza presente no banco de dados que melhor se adequaria a velocidade. Já que essa grandeza é intrínseca aos modelos previsores e serve de entrada em ambos os modelos.

Nesse estudo foram analisadas as seguintes grandezas: A velocidade média do vento e a direção média do vento, em que as Figuras 4.19 e 4.20 a seguir mostram tais comparações. Como exemplo, são mostrados graficamente os resultados do estudo para o Parque 01:

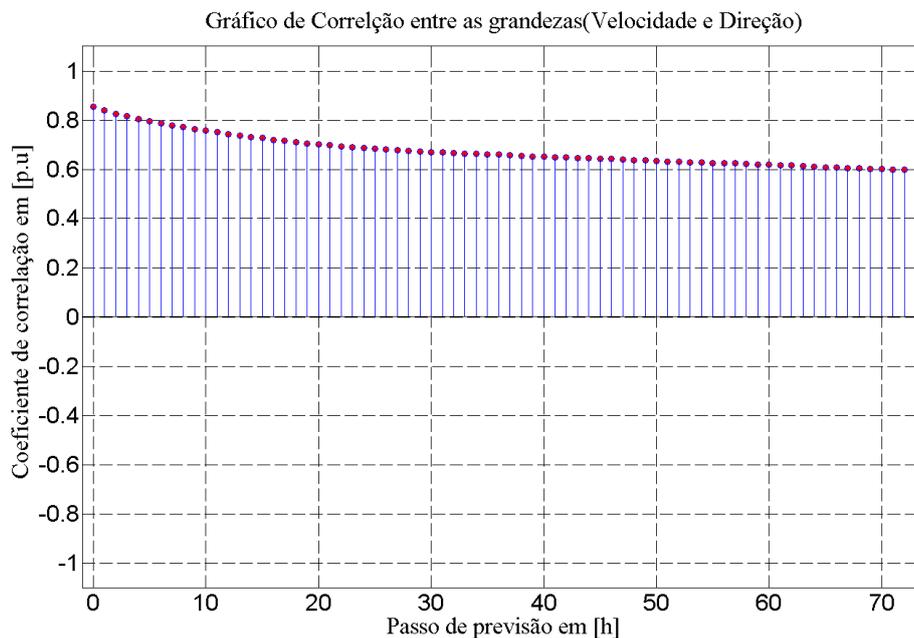


Figura 4. 19 - Gráfico de correlação entre a velocidade média e a direção média, relativas ao banco de dados do Parque01.

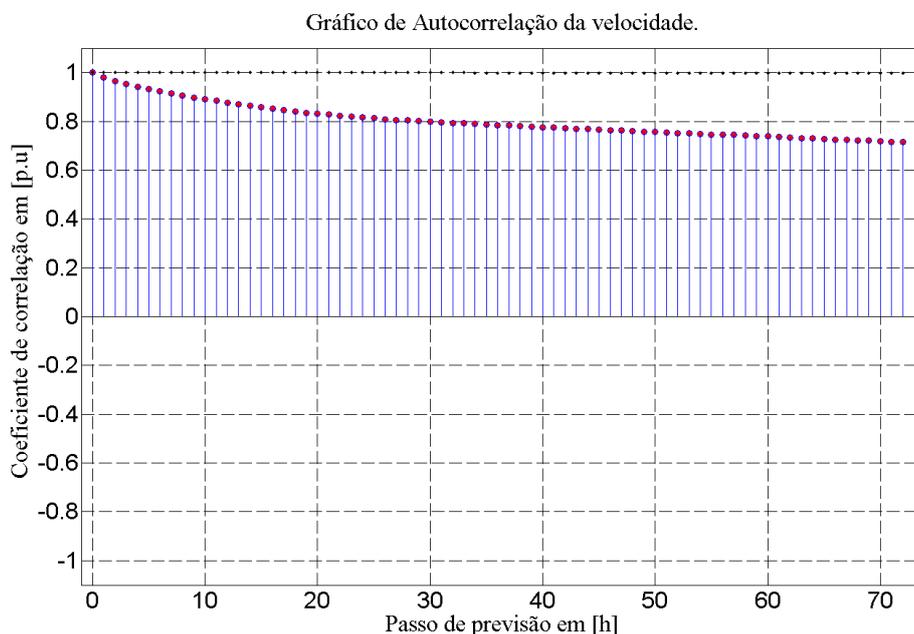


Figura 4. 20 - Gráfico de auto correlação da velocidade média, relativa ao banco de dados do Parque01.

Logo, pelos gráficos mostrados, nas Figuras 4.19 e 4.20, verifica-se dentre as grandezas escolhidas para o estudo que, as que apresentam melhor correlação são as velocidades médias e as direções médias, isso pode ser notado na Figura 4.19, em que a correlação apresentada pela primeira hora é superior a 0,8 p.u. isto é, maior que 80%, valor

condizente para uma boa relação entre as grandezas abordadas, levando-se em consideração o critério que será mostrado no capítulo 5 pela Tabela 5.1.

Assim, pelos resultados obtidos no critério de correlação, escolheram-se essas duas grandezas como entrada, velocidades médias e direções médias, diferenciando com isso o modelo M1a do modelo M2a.

Procedendo à montagem da CP-RNAM2a houve também a definição do tamanho dos conjuntos abordados, os quais também seguiram os mesmos parâmetros discriminados para o período de aprendizagem. E da mesma forma, que na montagem da CP-RNAM1a, os conjuntos de entrada e saída foram normalizados, por razões já discutidas nesta dissertação.

Quanto à escolha das redes que simulam as CPs do modelo M2a e sua respectiva parametrização, escolheu-se uma rede do tipo MLP (*Multi layer perceptron*), que utiliza retro propagação do erro (*Feedforward backpropagation error*), com a seguinte arquitetura: [2 – 3:8 – 3:8 – 1], conforme descrito abaixo:

- 2 entradas
- [3 até 8 neurônios] na camada oculta 1
- [3 até 8 neurônios] na camada oculta 2
- [1 neurônio] na saída

Em que para a montagem desta arquitetura, utilizou-se o mesmo critério utilizado na montagem da CP-RNAM1a, conforme já fora descrito nesta dissertação.

Sobre o método de treinamento que adequou os valores das entradas às suas respectivas saídas, validando assim a aprendizagem por parte da CP-RNAM2a, utilizou-se o algoritmo “Levenberg Marquardt”, conhecido comumente no simulador como “*Train LM*”. Enfatizando que o mesmo só foi adotado em preferência ao “*Resilient Propagation*” comumente conhecido no simulador como “*Train RP*”, por ser tecnicamente mais preciso que o “*Resilient Propagation*” e assim atrelar à previsão a melhor precisão possível já que essas redes localizam-se na saída do modelo M2a.

Uma diferença importante notada na construção dessa rede foi o número de inicializações, que neste caso foram divididas em duas etapas. Em que na primeira foram feitas 10 inicializações, com o intuito de estabelecer a melhor arquitetura para a CP-RNAM2a. Assim, com a melhor arquitetura definida procedeu-se a segunda etapa, em que foram realizadas 100 inicializações, com o objetivo de se escolher a melhor das redes com melhor a arquitetura definida.

Procedidos aos treinamentos, as melhores CP-RNAM2a, denominadas “CP-RNAM2a_BEST”, obtidas nas inicializações que simularam os treinamentos, nas bases dos parques 01 e 02 são mostradas nas Figuras 4.21 e 4.22 respectivamente:

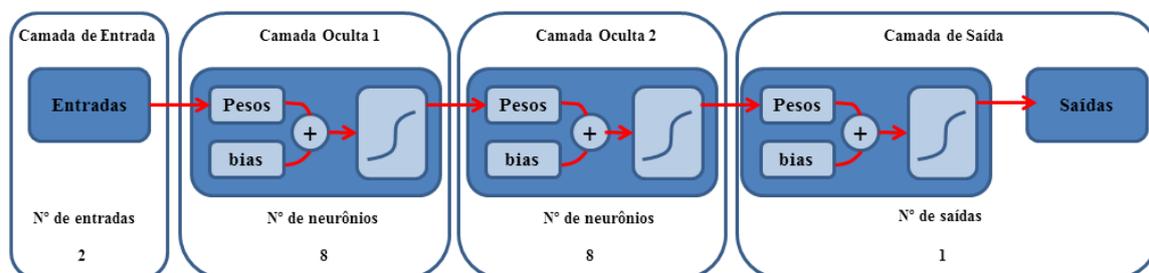


Figura 4. 21 - Arquitetura da melhor CP-RNAM2a para o Parque 01 escolhida com a execução dos treinamentos.

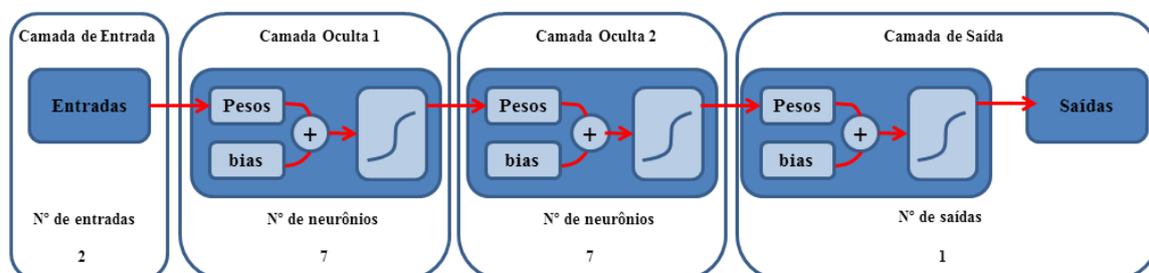


Figura 4. 22 - Arquitetura da melhor CP-RNAM2a para o Parque 02 escolhida com a execução dos treinamentos.

Das Figuras 4.21 e 4.22 dispostas acima, pode-se notar que, para a melhor inicialização, o número de neurônios definidos pelas camadas ocultas 1 e 2 foram respectivamente de 8 e 8 para o Parque 01 e 7 e 7 para o Parque 02, descrevendo assim a arquitetura da CP-RNAM2a após os treinamentos.

A figura 4.23, mostra uma comparação entre o histórico existente e as respostas obtidas pelos modelos treinados para ambos os Parques 01 e 02:

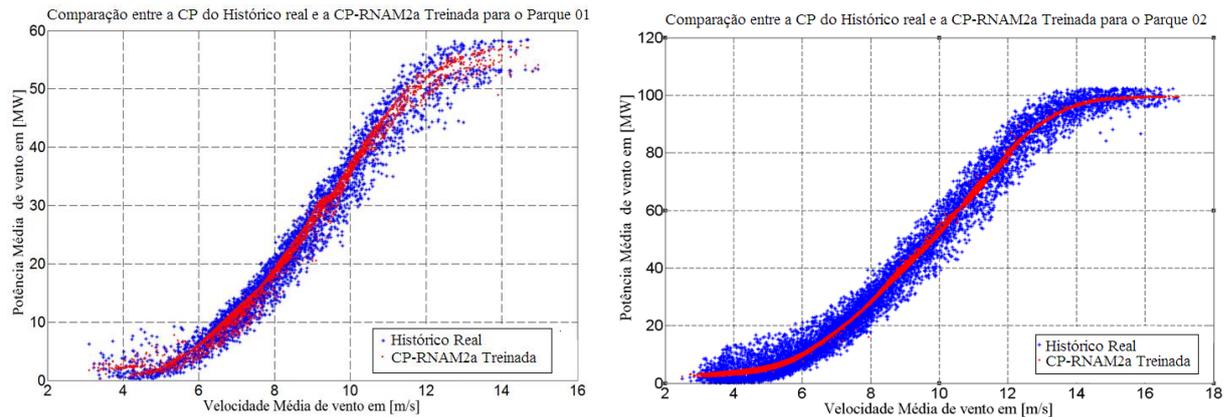


Figura 4. 23 - Comparação entre o histórico e a curva CP-RNAM2a treinada pelo modelo M2a aplicada em (a) para o Parque 01 e em (b) para o Parque 02.

Em que a Figura 4.24 mostra a performance relativa ao período de aprendizagem da CP-RNAM2a para os Parques 01 e 02.

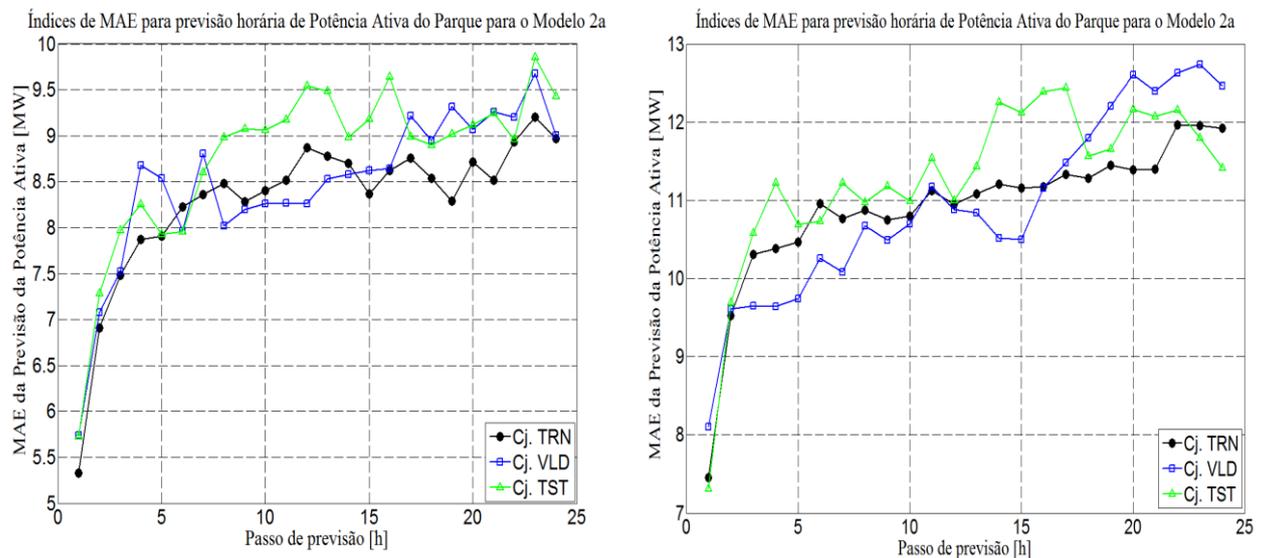


Figura 4. 24 - Comportamento gráfico do MAE referente às simulações para o período de aprendizagem da CP-RNAM2a aplicado em (a) para os Parques 01 e em (b) para o Parque 02.

4.3 Modelos baseados em lógica Fuzzy

Com o objetivo similar de prever potência, mostrando as diferenças nos desempenhos e na forma de ação em relação às RNAs, foram desenvolvidos dois modelos mistos nos quais são utilizadas redes neurais artificiais e SIFs.

Porém, apesar de os modelos serem mistos, a resposta de cada modelo respectivo dependerá fortemente dos SIFs associados. Já que tais SIFs discriminam as previsões de potências.

De forma semelhante ao que foi feito nos modelos só com RNAs, foi realizado a mesma escolha com relação às entradas e as saídas destes, pois os mesmos também foram baseados na curva de potência dos parques utilizados.

Também foram escolhidas as velocidades médias e direções médias como entradas e as potências médias como saídas, objetivando a criação de um sistema de inteligência artificial cuja aprendizagem associa as respectivas entradas as suas respectivas saídas.

Uma característica crucial, que diferencia de forma sucinta os modelos baseados em RNAs dos modelos baseados em Lógica Fuzzy, é de onde partem as previsões. Assim, nos modelos ditados pelas redes, as previsões são feitas pelas RNAs, já nos modelos ditados pela inferência Fuzzy, as previsões são discriminadas pelos SIFs.

Para a criação de tais modelos previsores foi utilizada uma abordagem mista, sendo esta composta de uma rede neural e um SIF, ordenados em cascata. Estando a RNA na entrada dos modelos, com o objetivo de prever velocidades médias e/ou direções médias, e o SIF, localizado na saída dos modelos, objetivando assim a previsão horária de potências médias de vento.

O horizonte de análise escolhido foi um horizonte de 24h, logo, as previsões desses modelos terão passo horário iniciando na hora um e finalizando na hora vinte e quatro.

Nessa dissertação foram desenvolvidos dois modelos que utilizam de forma mista, para a previsão de potência, RNAs e SIFs na sua estrutura, tais modelos foram denominados de M1b e M2b, e a diferença entre os mesmos esta apenas no número de entradas, tais modelos serão descritos a seguir.

4.3.1 Modelo M1b de previsão de potência

O modelo M1b, consiste de dois elementos postos em cascata, sendo o primeiro elemento a RNA1, já definido anteriormente. Já o segundo elemento é o SIF, que simula as curvas de Potência de previsão nas respectivas horas em questão, sendo o mesmo denominado CP-FuzzyM1b.

Em que o mesmo possui vinte e quatro conjuntos de variáveis de entrada para cada hora respectiva [vinte e quatro Séries horárias de velocidades previstas da RNA1] e vinte e quatro conjuntos de variáveis de saída para cada hora respectiva [vinte e quatro séries horárias de Potências Previstas pela CP-fuzzyM1b da hora em questão], em que o SIF disposto neste modelo será descrito posteriormente.

Demonstrando de forma mais clara como foi montado o modelo M1b, sua arquitetura de construção é mostrada pela Figura 4.25.

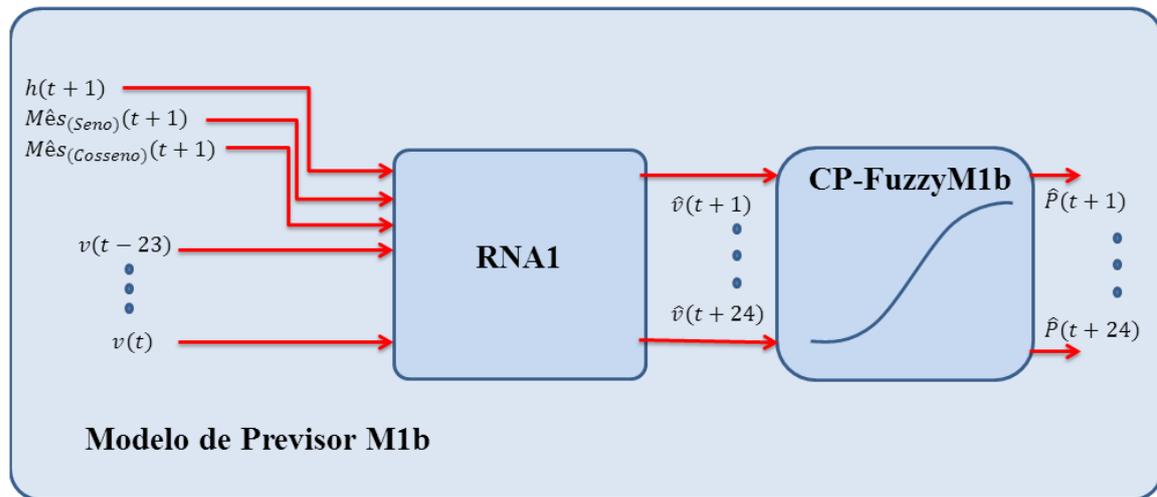


Figura 4.25 - Arquitetura de construção do modelo M1b.

4.3.1.1 Definido as curvas de potência do modelo M1b, intituladas (CP-FuzzyM1b)

Igualmente ao que fora definido nos modelos M1a e M2a, as CPs são RNAs que simulam curvas de potência nos modelos abordados. Em si tratando do Modelo M1b, as mesmas foram denominadas CP-FuzzyM1b. Tais curvas são na verdade SIFs que tem a função de simular as respectivas curvas de potência da hora prevista em questão.

As mesmas são alimentadas pelas saídas da RNA1, em que cada entrada corresponde à série horária de velocidades médias de vento previstas, que através da CP-FuzzyM1b, terá uma saída que corresponde a série horária de potências médias da hora em questão.

Quanto à parametrização para tais curvas, inicialmente foi determinada a faixa de atuação das grandezas, nesse caso, a faixa de velocidades e a faixa de potências, pois a parametrização do modelo deve estar presa à faixa de grandezas efetivas. Para isso, os dados de entrada que compõem essas faixas, já se encontravam filtrados e livres de inconsistências.

Quanto ao tipo de modelo Fuzzy escolhido para a simulação de tais curvas, utilizou-se o tipo Mamdani conforme descrito no Capítulo 4 desta Dissertação.

Outro ponto importante, diz respeito ao período de aprendizagem, sendo discriminado o mesmo período de aprendizagem empregado no treinamento das RNAs conforme mostrado pela Tabela 4.2. Em que tal período foi de suma importância para a montagem da inferência (Relação heurística entre entrada e saída) do respectivo SIF.

Para tal, são definidas faixas de correspondência associando as variáveis de entrada as suas respectivas variáveis de saída. Em que a ligação de correspondência entre estas faixas é estabelecida por funções matemáticas intrínsecas à lógica Fuzzy, chamadas de funções de pertinência.

Com relação aos tipos de funções de pertinência, oferecidas, nesse trabalho foram utilizadas funções do tipo: trapezoidal, sigmoide e gaussiana. Em que o tipo de função fora escolhido de acordo com a distribuição das grandezas no intervalo de análise abordado. Outro fato não menos crucial nesta parametrização foi a criação de uma lista de regras, tendo esta, a função de estabelecer de forma efetiva o peso da ligação entre os dados de entrada e os dados de saída.

Ainda falando sobre a parametrização, foi importante estabelecer um número de intervalos para a análise em questão, já que o objetivo do SIF foi de simular uma curva de potência. Então após sucessivos testes chegou-se ao número de 5 intervalos. Ou seja, para cada curva foram tomadas cinco regiões de parametrização, em que para cada região foi definida uma curva de correspondência ($P \times v$) específica.

Assim, adotando os parâmetros definidos anteriormente, foi montada a arquitetura do modelo da CP-FuzzyM1b, mostrada na Figura 4.26.

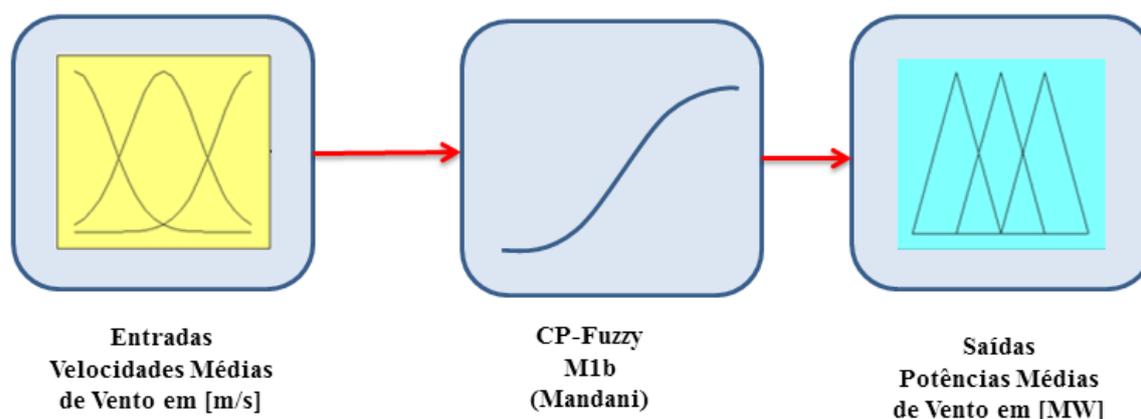


Figura 4. 26 - Arquitetura do SIF Fuzzy, Mamdani, referente a CP-FuzzyM1b.

Analisando cada um dos cinco intervalos relativos às cinco regiões de aproximação da CP-FuzzyM1b, parametrizaram-se tais intervalos da seguinte forma:

Inicialmente estabeleceram-se as faixas das regiões compreendendo a região um até a região cinco, definindo para cada uma, intervalos de velocidades médias e potências médias, assim discriminados: Faixa de Velocidades Médias (0...18)[m/s] e Faixa de

Potências Médias (-14,9182 ... 78,63)[MW] para o Parque 01 e Faixa de Velocidades Médias (0...19)[m/s] e Faixa de Potências Médias (-64,89 ... 169,9)[MW] para o Parque 02

Continuando, estipularam-se intervalos de análise para cada região, em que após sucessivas simulações referentes ao período de aprendizagem, foram discriminados os melhores intervalos das entradas em relação às saídas, bem como suas respectivas funções de pertinência.

Desta forma, é mostrada nas Tabelas 4.6, e 4.7, os melhores intervalos de parametrização da CP-FuzzyM1b, bem como as suas funções de pertinência para entradas e saídas para os Parques 01 e 02 respectivamente.

Tabela 4.6 - Intervalos das variáveis de entradas e saídas por faixa das Regiões da CP-FuzzyM1b, para o Parque 01.

Regiões de aproximação	Função de pertin. da (entrada)	Velocidade Média de Vento[m/s]	Função de pertin. da (saída)	Potência Média de Vento[MW]
Região 1	Sigmoide	(0,7898 – 7,8)	Trapezoide	(-6,5; -6,2; 2,5; 4,7)
Região 2	Sigmoide	(1,1699 – 10,6689)	Sigmoide	(0,079 – 78,63)
Região 3	Sigmoide	(1,1399 – 13)	Sigmoide	(16 – 66)
Região 4	Sigmoide	(1,9899 – 11,5)	Sigmoide	(11,9999 – 69,4499)
Região 5	Sigmoide	(1,8999 – 17,3799)	Sigmoide	(53,5 – 74,85)

Tabela 4.7 - Intervalos das variáveis de entradas e saídas por faixa das Regiões da CP-FuzzyM1b, para o Parque 02.

Regiões de aproximação	Função de pertin. da (entrada)	Velocidade Média de Vento[m/s]	Função de pertin. da (saída)	Potência Média de Vento[MW]
Região 1	Sigmoide	(0,89 – 7,94)	Trapezoide	(-15,99; -8,8; 15,1; 18,788)
Região 2	Sigmoide	(1,1779 – 10,7319)	Sigmoide	(0,0691 – 55,88)
Região 3	Sigmoide	(1,21 – 12,11)	Sigmoide	(30 – 66)
Região 4	Sigmoide	(1,9899 – 14,416)	Sigmoide	(20 – 75,3499)
Região 5	Sigmoide	(3,9999 – 18,3799)	Sigmoide	(-21 – 165)

As Figuras 4.27 e 4.28 mostram os comportamentos respectivos de cada função de pertinência das entradas (Séries de velocidades Médias de vento) e, de cada função de pertinência das saídas (Séries de Potências Médias de vento), em cada uma das regiões abordadas nos parques respectivos:

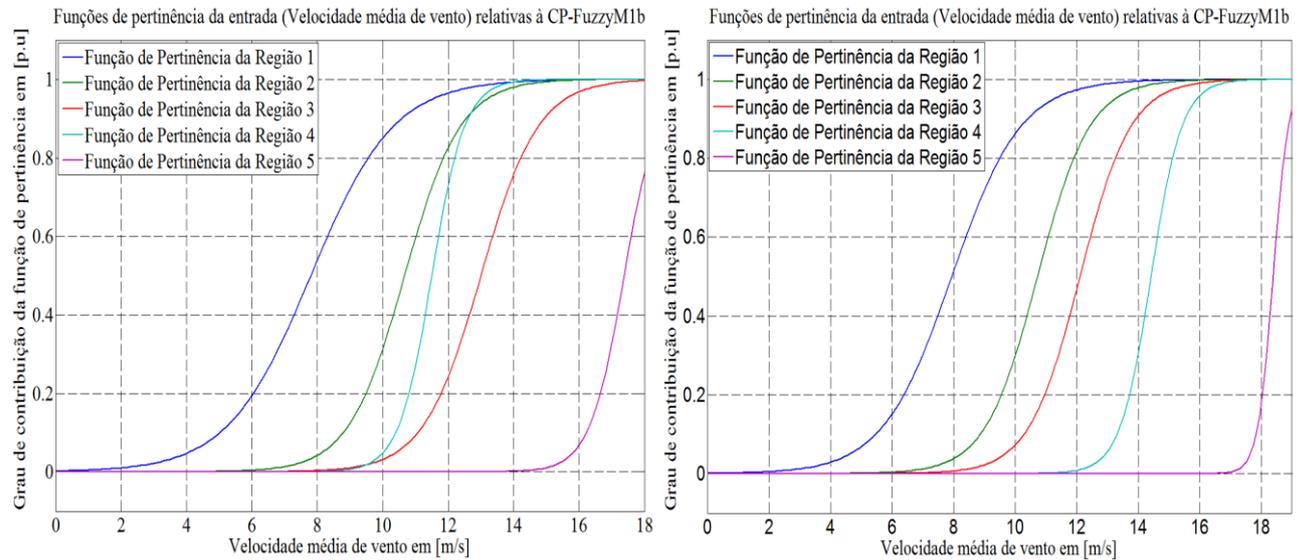


Figura 4. 27 - Comportamento das funções de pertinência das entradas (Velocidades Médias de vento) nas respectivas regiões abordadas, dos Parques, 01(a) e 02(b).

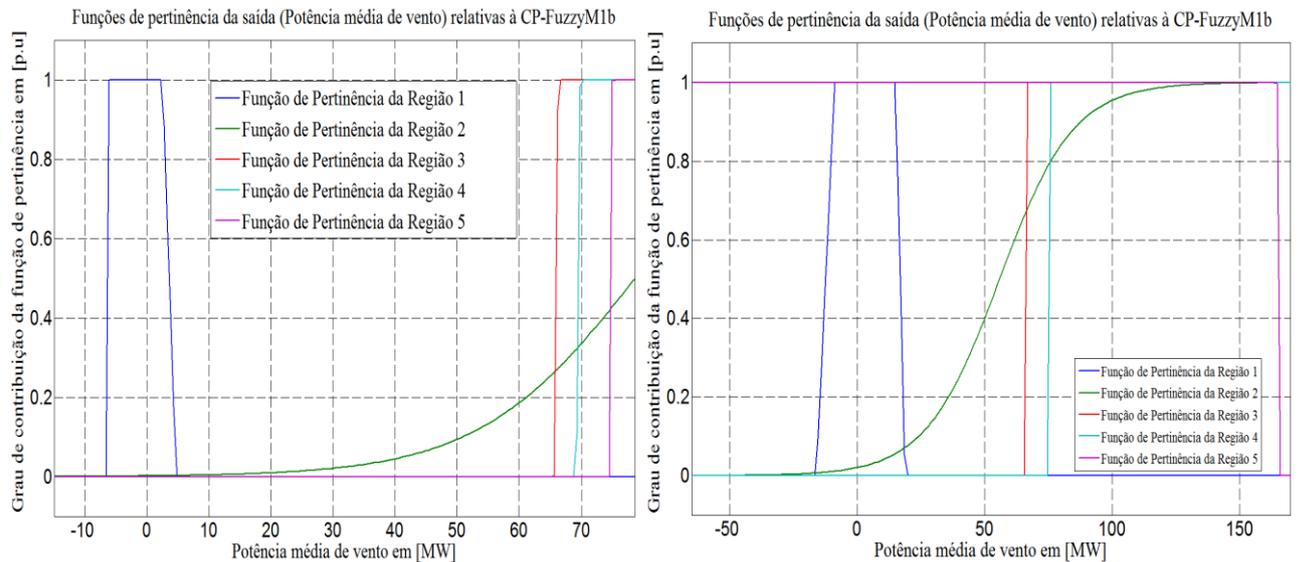


Figura 4. 28 - Comportamento das funções de pertinência das saídas (Potências Médias de vento) nas respectivas regiões abordadas, dos Parques, 01(a) e 02(b).

Outro fator importante foi a questão da intervenção do especialista, já que após cada simulação no período de aprendizagem, quando o resultado não era satisfatório, foram feitos sucessivos ajustes nos parâmetros do SIF, em específico com relação à lista de regras, a mesma é uma lista que discrimina qual o peso da regra em porcentagem que

interliga a entrada e a saída, fato que não é possível, quando a previsão final é feita por RNAs.

Logo, com este artifício pode-se levar o SIF a seguir a melhor modelagem da curva de potência em questão, e esta é uma das principais vantagens da abordagem com lógica Fuzzy em relação à abordagem feita com RNAs. Contudo é importante ressaltar que encontrar a forma de discriminação de cada região não foi uma tarefa muito simples, e como todo evento empírico levou um tempo considerável.

As Tabelas 4.8 e 4.9 a seguir mostram as listas de regras utilizadas nas CP-FuzzyM1b para os Parques estudados (Parque 01 e Parque 02):

Tabela 4.8 - Listas de Regras utilizadas na modelagem da CP-FuzzyM1b, para o Parque 01.

Região Abordada	Antecedente	Peso utilizado[%]	Consequente
Região 1	Vel. Méd. Reg1	30	Pot. Méd. Reg1
Região 2	Vel. Méd. Reg.2	41,52	Pot. Méd. Reg.2
Região 3	Vel. Méd. Reg.3	65	Pot. Méd. Reg.3
Região 4	Vel. Méd. Reg.4	100	Pot. Méd. Reg.4
Região 5	Vel. Méd. Reg.5	1	Pot. Méd. Reg.5

Tabela 4.9 - Listas de Regras utilizadas na modelagem da CP-FuzzyM1b, para o Parque 02.

Região Abordada	Antecedente	Peso utilizado[%]	Consequente
Região 1	Vel. Méd. Reg1	45,79	Pot. Méd. Reg1
Região 2	Vel. Méd. Reg.2	48,99	Pot. Méd. Reg.2
Região 3	Vel. Méd. Reg.3	100	Pot. Méd. Reg.3
Região 4	Vel. Méd. Reg.4	58,9	Pot. Méd. Reg.4
Região 5	Vel. Méd. Reg.5	1	Pot. Méd. Reg.5

Em que após, sucessivas simulações e ajustes, a curva de potência CP-FuzzyM1b, representada pelo SIF Mamdani do modelo M1b fora parametrizada tendo por fim a seguinte tendência, que é mostrada na Figura 4.29.

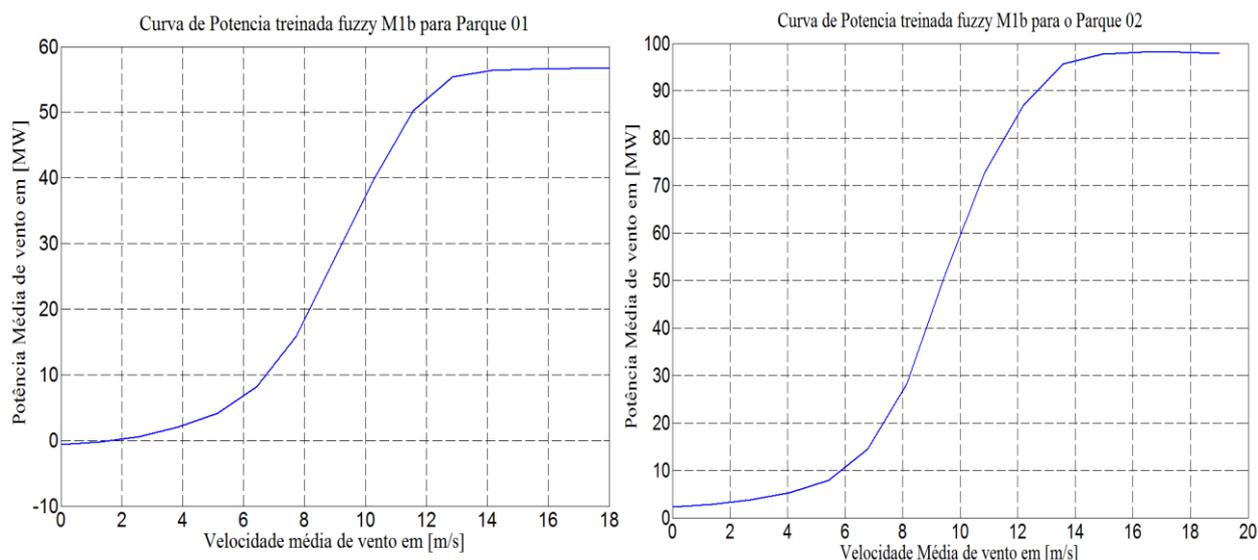


Figura 4. 29 - Comportamento da CP-FuzzyM1b discriminado pelo SIF de inferência Fuzzy, dos Parques, 01(a) e 02(b).

Assim, pela Figura 4.29 mostrada, é possível notar que o SIF que simula a curva de potência para o modelo M1b cumpriu muito bem o seu papel, pois a curva de tendência do mesmo enquadra-se dentro da curva de potência para o parque em questão.

Também é importante ressaltar que, há uma pequena melhora no desempenho das previsões da CP simulada pelo SIF em relação à CP simulada pela RNA, comparando o desempenho das CPs geradas pelos sistemas de I.A. (CP-FuzzyM1b e CP-RNAM1a). Pois, ambas dispõem das mesmas informações, ou seja, o mesmo número de entradas e o mesmo número de saídas. Fato explicado anteriormente pela adição nos modelos Fuzzy da análise do especialista, que assim, melhor adequa o modelo de previsão.

Assim, será mostrado no Capítulo 5, que devido a essa característica, o modelo baseado em lógica Fuzzy leva uma ligeira vantagem em relação ao modelo baseado em RNA, no que diz respeito a algumas horas na previsão de potências médias.

Para mostrar a efetividade do aprendizado foi analisado o MAE do conjunto de aprendizagem, conforme é mostrado na Figura 4.30:

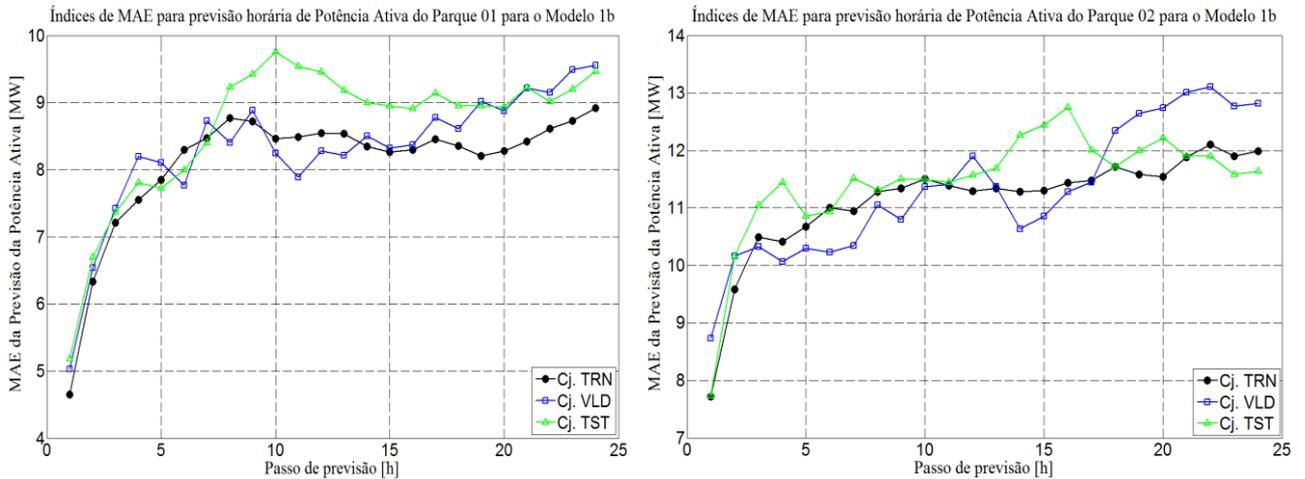


Figura 4. 30 - Comportamento gráfico do MAE referente às simulações para o período de aprendizagem da CP-FuzzyM1b aplicado aos Parques01 (a) e 02 (b).

4.3.2 Modelo M2b de previsão de potência

O modelo M2b também consiste de dois elementos postos em cascata, porém trata-se de um modelo misto, sendo o primeiro elemento a RNA2 já definida anteriormente. Já o segundo elemento um SIF, que simula as curvas de Potência de previsão das respectivas horas em questão, denominada (CP-FuzzyM2b) com duas variáveis de entrada para cada hora respectiva, sendo estas, (vinte e quatro séries horárias de velocidades médias previstas da RNA2 e vinte e quatro séries horárias de direções médias previstas da RNA2) e uma variável de saída para cada hora respectiva sendo esta: (vinte e quatro Séries horárias de Potências Previstas pela CP-FuzzyM2b da hora em questão), em que o SIF disposto neste modelo será descrito posteriormente.

Demonstrando de forma mais clara como foi montado o modelo M2b, sua arquitetura de construção é mostrada abaixo pela Figura 4.31.

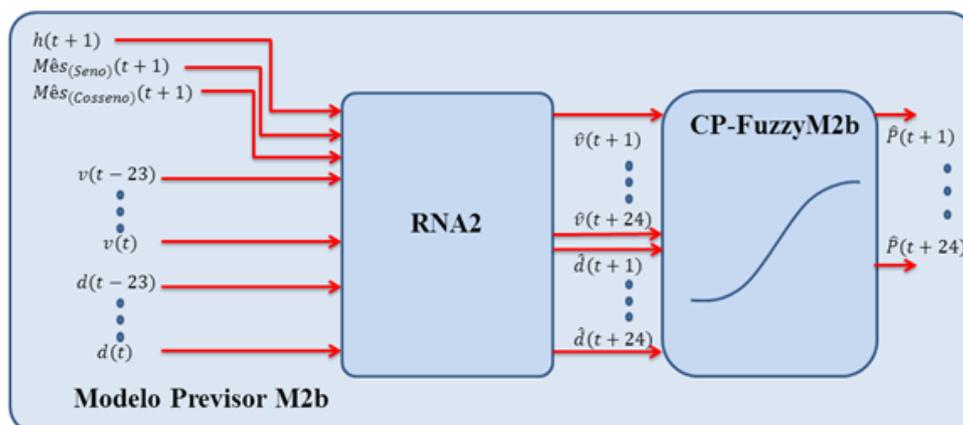


Figura 4. 31 - Arquitetura de construção do modelo M2b.

4.3.2.1 Definindo as curvas de potência do modelo M2b, intituladas (CP-FuzzyM2b)

De forma semelhante ao que já fora definido, nos modelos M1a e M2a, as CPs são RNAs que simulam curvas de potência nos modelos abordados. Em si tratando do Modelo M2b, as mesmas foram denominadas CP-FuzzyM2b. Tais curvas são na verdade SIFs que tem a função de simular as respectivas curvas de potência da hora prevista em questão.

As mesmas são alimentadas, pelas saídas da RNA2, em que cada entrada corresponde às séries horárias de velocidades médias de vento previstas e às séries de direções médias previstas, que através da curva de potência da hora respectiva, terá uma saída que corresponde a série horária de potências médias previstas da hora em questão.

Quanto à parametrização para tais curvas, inicialmente foram determinadas as faixas de atuação das grandezas, nesse caso, a faixa de velocidades, a faixa de direções e a faixa de potências, pois a parametrização do modelo deve estar presa à faixa de grandezas efetivas. Para isso, os dados de entrada que compõem essas faixas, assim como no modelo Fuzzy anterior, já se encontravam filtrados e livres de inconsistências.

Quanto ao tipo de modelo Fuzzy escolhido para a simulação de tais curvas, também se utilizou o tipo Mamdani.

Outro ponto importante, diz respeito a aprendizagem, sendo utilizado o mesmo critério adotado para o modelo Fuzzy M1b.

Com relação aos tipos de funções de pertinência oferecidas, nesse trabalho foram utilizadas funções do tipo: trapezoidal, sigmoide e gaussiana. Em que o tipo de função fora escolhido de acordo com a distribuição das grandezas no intervalo de análise abordado. Outro fato não menos crucial nesta parametrização, foi à criação de uma lista de regras, tendo esta, a função de estabelecer de forma efetiva o peso da ligação entre os dados de entrada e os dados de saída.

Ainda sobre a parametrização, foi importante estabelecer um número de intervalos para a análise em questão, já que o objetivo do SIF foi de simular uma curva de potência. Então após sucessivos testes, chegou-se ao número de cinco e sete intervalos. Ou seja, para a entrada um (velocidades médias) e para a saída (Potências médias) consideraram-se cinco intervalos ou regiões de análise. Já para a entrada dois (direções médias) consideraram-se sete intervalos ou regiões.

Assim, adotando os parâmetros definidos anteriormente, foi montada a arquitetura do modelo da CP-FuzzyM2b, em que a mesma é mostrada na Figura 4.32.

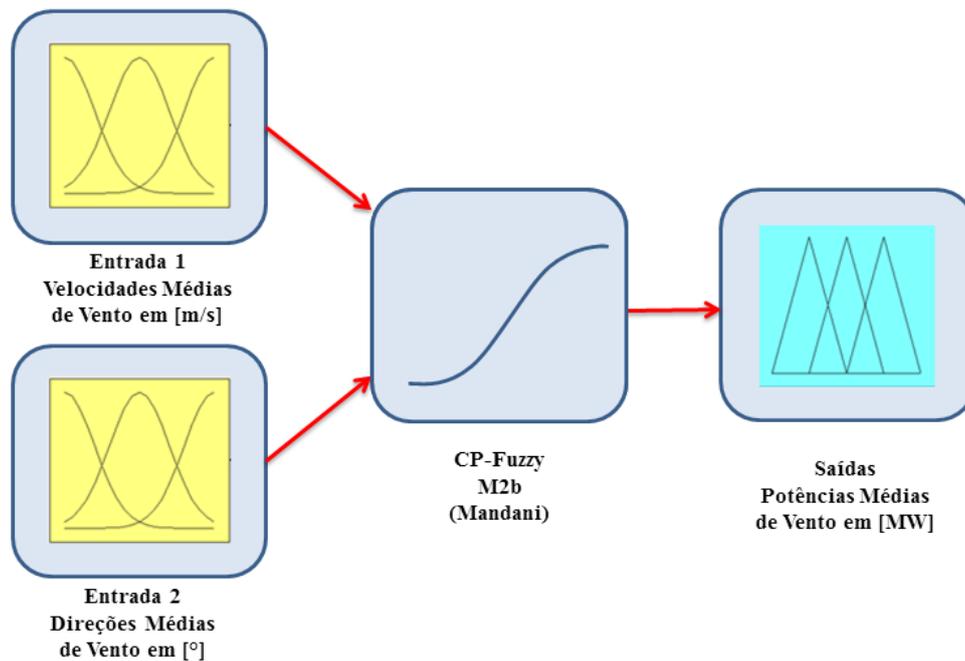


Figura 4. 32 - Arquitetura do SIF, Mamdani, referente à CP-FuzzyM2b.

Analisando cada um dos cinco ou sete intervalos relativos as cinco ou sete regiões de aproximação da CP-FuzzyM2b, parametrizaram-se tais intervalos da seguinte forma:

Inicialmente, estabeleceram-se as faixas das regiões consideradas no problema, definindo para cada uma, intervalos de velocidades médias, direções médias e potências médias, discriminados a seguir:

Faixa de Velocidades Médias (0...18)[m/s], Faixa de direções médias (0,...,360)[°] e Faixa de Potências Médias (-14,9182 ... 78,63)[MW] para o Parque 01, e, Faixa de Velocidades Médias [0...19](m/s), Faixa de direções médias (0,...,360)[°] e Faixa de Potências Médias (-64,89 ... 169,9)[MW] para o Parque 02.

Estipularam-se intervalos de análise para cada região, em que após sucessivas simulações foram discriminados os melhores intervalos das entradas em relação às saídas, bem como suas respectivas funções de pertinência. Para chegar a um resultado satisfatório, foi analisado o MAE do conjunto de simulação, que será mostrado posteriormente no capítulo de resultados.

Outro ponto determinístico para um bom desempenho da previsão é a escolha do melhor tipo de função de pertinência. Para a escolha de tais funções de pertinência foram analisados os comportamentos das variáveis de entrada com a respectiva saída, em que tal comportamento é mostrado nas Figuras 4.34 e 4.35.

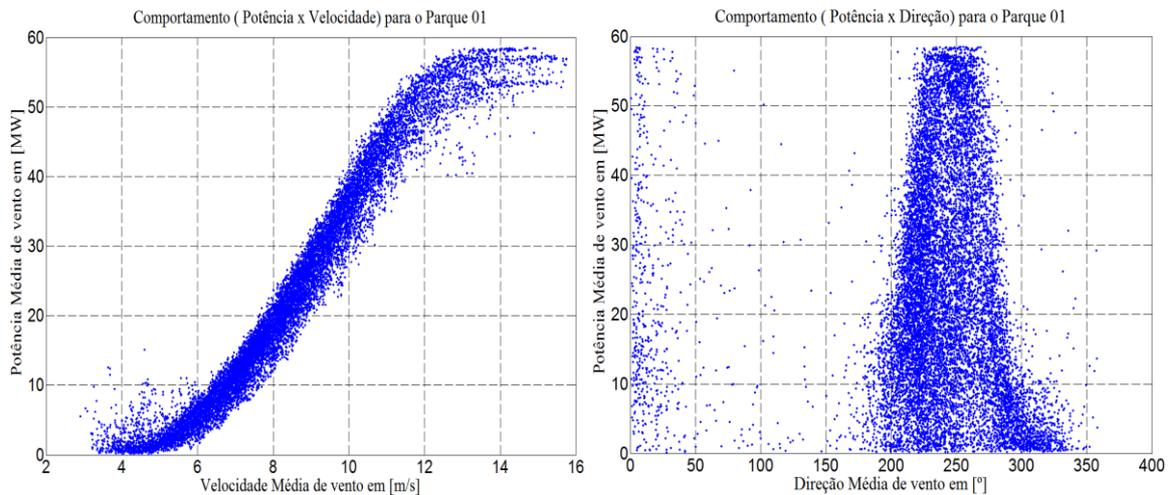


Figura 4. 33 - *Comportamento individual das variáveis de entrada em relação a variável de saída do SIF Mamdani referente à CP-FuzzyM2b para o Parque 01, mostrando a relação [Velocidade x Potência] (a) e [Direção x Potência] (b).*

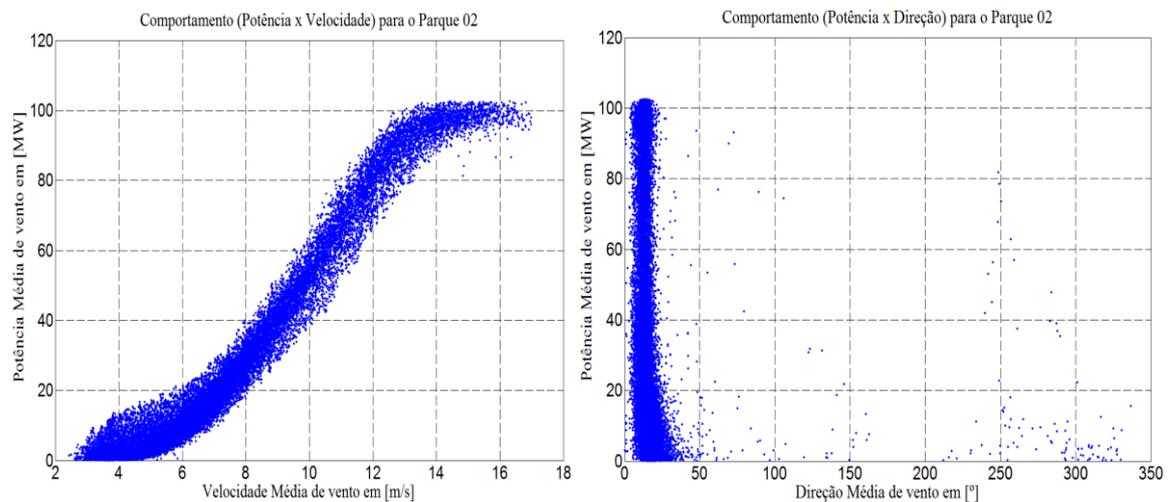


Figura 4. 34 - *Comportamento individual das variáveis de entrada em relação a variável de saída do SIF Mamdani referente à CP-FuzzyM2b para o Parque 02, mostrando a relação [Velocidade x Potência] (a) e [Direção x Potência] (b).*

Logo, percebe-se nas Figuras 4.33 e 4.34, que a velocidade se relaciona com a potência através de um comportamento aproximado de uma função sigmoide logística, nas figuras isso é mostrado com o índice (a). Já a direção se relaciona com a potência através de um comportamento aproximado de uma função gaussiana, na figura isso é mostrado na figura com o índice (b).

Porém é preciso atentar para a forma da distribuição da direção média no Parque 02 em que a Figura 4.35 encontra-se menos distribuída ao longo dos 360°, fato que contribui para a piora nas previsões atreladas a esse parque.

Com isso, o tipo da função de pertinência escolhido para representar a velocidade, foi a sigmoide logística. Já para a direção, escolheu-se uma gaussiana.

Com relação ao tipo de função escolhida para a saída, o mesmo foi determinado empiricamente, testando os tipos de funções disponibilizados pelo Matlab, tais funções são mostradas na Tabela 4.10.

Tabela 4. 10 - Funções de Pertinência disponibilizadas pelo Matlab.

Nome	Tipo
dsigmf	Diferença sigmoide
gauss2mf	Gaussiana tipo 2
gaussmf	Gaussiana tipo 1
gbellmf	Sinusoide
pimf	Pico seifado
psigmf	Produto sigmoide
SMF	Forma de S
sigmf	Sigmoide logística
trapmf	Trapezoide
trimf	Triangular
ZMF	Forma de Z

Desta forma, são mostrados nas Tabelas 4.11, 4.12, 4.13, 4.14, 4.15 e 4.16 os intervalos de parametrização da CP-FuzzyM2b, bem como as suas funções de pertinência para entradas e saídas para os Parques 01 e 02.

Tabela 4. 11 - Intervalos da entrada 1 por faixa das Regiões da CP-FuzzyM2b, para o Parque 01.

Regiões de aproximação	Função de pertin. da (entrada 1)	Velocidade média de vento[m/s]
Região 1	Sigmoide	(0,8999 – 7,89)
Região 2	Sigmoide	(1,1699 – 10,69)
Região 3	Sigmoide	(3,1399 – 13,1)
Região 4	Sigmoide	(1,9899 – 11,216)
Região 5	Sigmoide	(1,9 – 17,3799)

Tabela 4. 12 - Intervalos da entrada 1 por faixa das Regiões da CP-FuzzyM2b, para o Parque 02.

Regiões de aproximação	Função de pertin. da (entrada 1)	Velocidade média de vento[m/s]
Região 1	Sigmoide	(0,8564 – 7,9999)
Região 2	Sigmoide	(1,1155 – 10,7999)
Região 3	Sigmoide	(1,666 – 12,251)

Região 4	Sigmoide	(2,121 – 14,405)
Região 5	Sigmoide	(4,9999 – 18,2799)

Tabela 4. 13 - Intervalos da entrada 2 por faixa das Regiões da CP-FuzzyM2b, para o Parque 01.

Regiões de aproximação	Função de pertin. da (entrada 2)	Direção média de vento[°]
Região 1	Gaussiana2	(150-175-200)
Região 2	Gaussiana2	(150-200-250)
Região 3	Gaussiana2	(200-225-250)
Região 4	Gaussiana2	(200-250-300)
Região 5	Gaussiana2	(250-275-300)
Região 6	Gaussiana2	(250-296,1-342,2)
Região 7	Gaussiana2	(300-321,1-342,2)

Tabela 4. 14 - Intervalos da entrada 2 por faixa das Regiões da CP-FuzzyM2b, para o Parque 02.

Regiões de aproximação	Função de pertin. da (entrada 2)	Direção média de vento[°]
Região 1	Gaussiana2	(10-40-110)
Região 2	Gaussiana2	(5-10-110)
Região 3	Gaussiana2	(6-10-25)
Região 4	Gaussiana2	(20-35-40)
Região 5	Gaussiana2	(30-25-30)
Região 6	Gaussiana2	(15-27-35)
Região 7	Gaussiana2	(10-22-25)

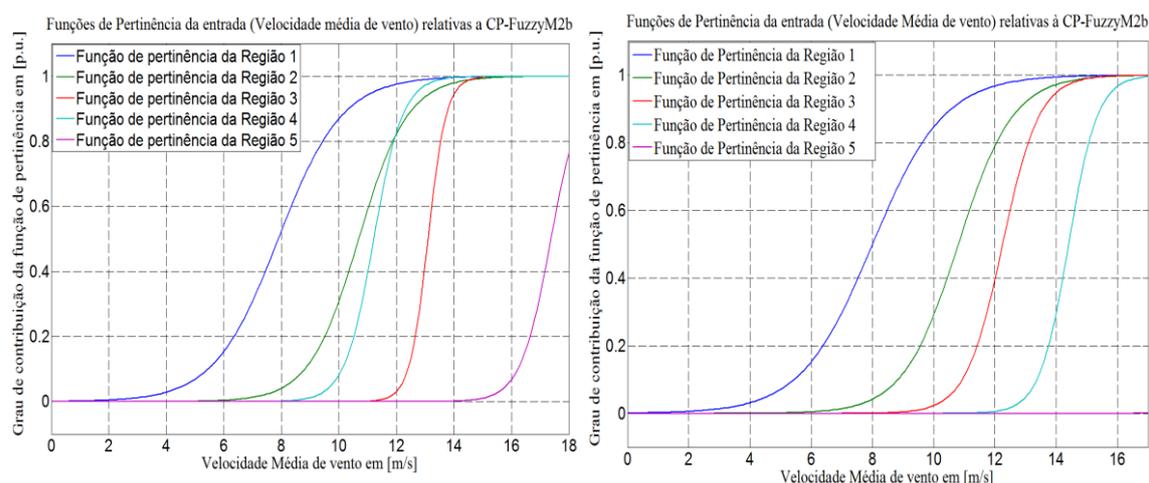
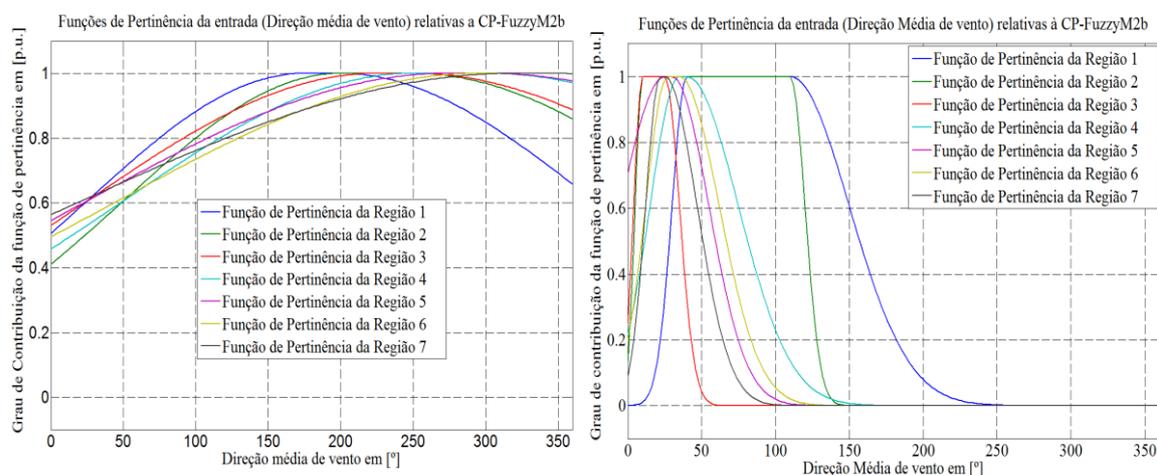
Tabela 4. 15 - Intervalos da saída por faixa das Regiões da CP-FuzzyM2b, para o Parque 01.

Regiões de aproximação	Função de pertin. da (entrada 1)	Potência média de vento[MW]
Região 1	Trapesoide	(-6,5; -6,2; 2,5; 4,7)
Região 2	Sigmoide	(0,079 – 78,63)
Região 3	Sigmoide	(16 – 66)
Região 4	Sigmoide	(11,9999 – 69,4499)
Região 5	Sigmoide	(53,5 – 74,85)

Tabela 4. 16 - Intervalos da saída por faixa das Regiões da CP-FuzzyM2b, para o Parque 02.

Regiões de aproximação	Função de pertin. da (Saída)	Potência média de vento[MW]
Região 1	Trapessoide	(-16,018; -8,8; 14,1; 18,71)
Região 2	Sigmoide	(0,0678 – 57,81)
Região 3	Sigmoide	(30 – 70)
Região 4	Sigmoide	(25 – 76,3499)
Região 5	Sigmoide	(-20 – 100)

Em que as Figuras 4.35, 4.36 e 4.37 mostram os comportamentos respectivos de cada função de pertinência das entradas (Séries de velocidades Médias e direções médias de vento) e, de cada função de pertinência das saídas (Séries de Potências Médias de vento), em cada uma das regiões abordadas:

**Figura 4. 35** - Comportamento das funções de pertinência da entrada 1 (Velocidade média do vento) nas respectivas regiões abordadas dos Parques, 01(a) e 02(b).**Figura 4. 36** - Comportamento das funções de pertinência da entrada 2 (Direção média do vento) nas respectivas regiões abordadas dos Parques, 01(a) e 02(b).

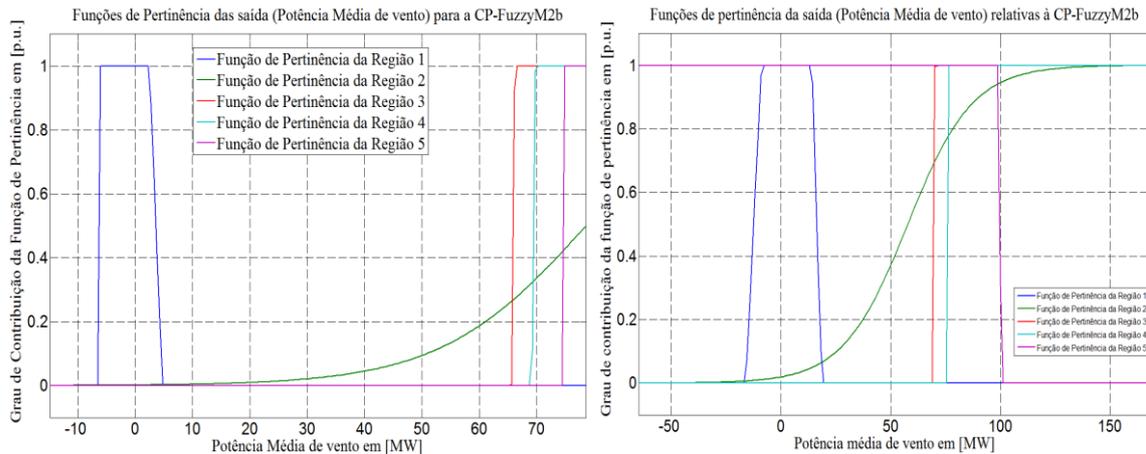


Figura 4. 37 - Comportamento das funções de pertinência da saída nas respectivas regiões abordadas dos Parques, 01(a) e 02(b).

Após a parametrização das funções de pertinência do SIF, o mesmo fornece em sua saída a potência média prevista. Porém a previsão se encontra na forma fuzzyficada, ou seja, a variável prevista é limitada pelas faixas relativas à interseção dos graus de contribuição de suas funções de pertinência. Tal processo é conhecido como *fuzzificação*.

Assim, necessita-se de uma conversão para faixas reais da grandeza em análise, realiza-se então, a *defuzzificação*, que é um processo de transferência da variável do plano Fuzzy para o plano real. Isso é feito através de um método de aproximação, para este problema o método utilizado foi o método do centroide.

Outro fator importante, diz respeito à intervenção do especialista, já que após cada simulação referente ao período de aprendizagem, quando o resultado não era o esperado, foram feitos sucessivos ajustes nos parâmetros do SIF, em específico com relação à lista de regras. Em que, a mesma é uma lista que discrimina qual o peso de ligação em porcentagem da entrada com relação à saída, fato que não é possível, quando a previsão final é feita por RNAs, já que esse processo no caso das redes neurais é aleatório.

Logo, com este artifício pode-se levar o SIF a seguir a modelagem da curva de potência em questão, e esta, é uma das principais vantagens da abordagem com lógica Fuzzy em relação à abordagem feita com RNAs. Contudo, é importante ressaltar que encontrar uma boa forma de discriminação de cada região não foi uma tarefa muito simples, e como todo evento empírico levou um tempo considerável.

As Tabelas 4.17 e 4.18 mostram tais listas de Regras utilizadas:

Tabela 4. 17 - Listas de Regras utilizadas na modelagem da CP-FuzzyM2b, Parque 01.

	Peso utilizado em [%]				
	R1-A1	R2-A1	R3-A1	R4-A1	R5-A1
R1-A2	31,009	31,10	31,04	23	10
R2-A2	1	41,52	1	1	1
R3-A2	30	41,1	65	48,88	1
R4-A2	29	30	59,99	100	1
R5-A2	1	1	1	1	1
R6-A2	1	1	1	1	1
R7-A2	20	1	10	60	75
	R1-C	R2-C	R3-C	R4-C	R5-C
R# = região #	A# = antecedente #		C# = consequente #		

Tabela 4. 18 - Listas de Regras utilizadas na modelagem da CP-FuzzyM2b, Parque 02.

	Peso utilizado em [%]				
	R1-A1	R2-A1	R3-A1	R4-A1	R5-A1
R1-A2	46,87	21,10	11,04	53	1
R2-A2	27	11,52	86,9	99,99	79,99
R3-A2	40	39,93	35,9	58,88	10
R4-A2	39	24,8	49,99	70	50
R5-A2	28,79	10	49,99	39,99	29,99
R6-A2	20	20	20	19	80
R7-A2	10	10	20	1	30
	R1-C	R2-C	R3-C	R4-C	R5-C
R# = região #	A# = antecedente #		C# = consequente #		

Após, sucessivas simulações e ajustes, a curva de potência CP-FuzzyM2b representada pelo SIF Mamdani do modelo M2b fora parametrizada tendo por fim a seguinte tendência que é mostrada pela Figura 4.38.

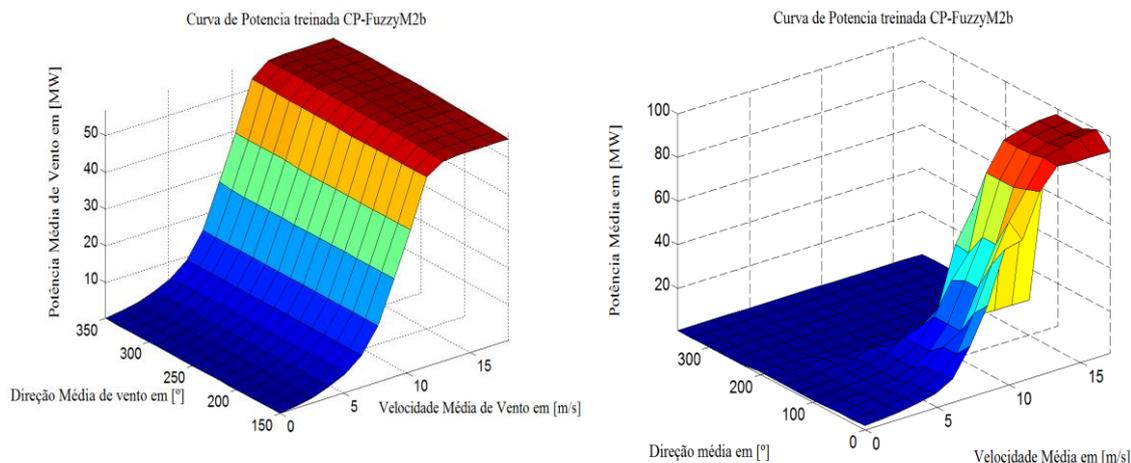


Figura 4. 38 - Comportamento da curva de potência do modelo M2b discriminado pelo SIF (CP-FuzzyM2b) dos Parques, 01(a) e 02(b).

Para mostrar a efetividade do aprendizado foi analisado o MAE do conjunto de aprendizagem, conforme mostrado pela Figura 4.39:

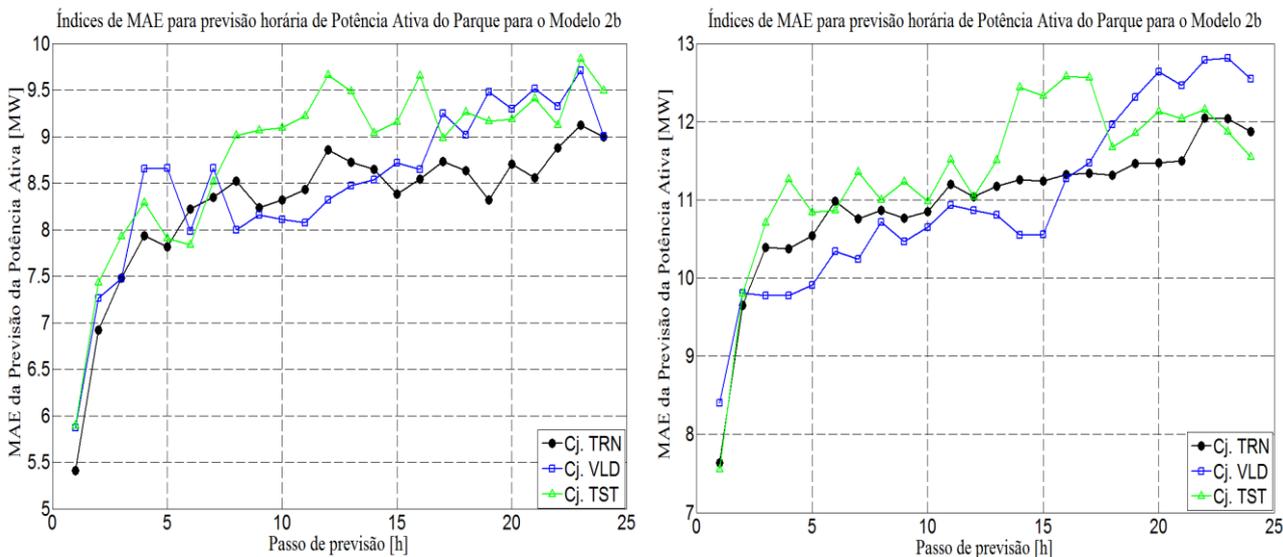


Figura 4. 39 - Comportamento gráfico do MAE referente às simulações para o período de aprendizagem da CP-FuzzyM2b aplicado aos Parques01 (a) e 02 (b).

CAPÍTULO 5

5 Análise dos resultados e comparações entre os modelos

Este capítulo se designa a mostrar os resultados das previsões referentes aos modelos M1a, M2a, M1b e M2b, para tal faz-se uma análise minuciosa dos resultados relativos aos respectivos modelos em duas etapas distintas, sendo a 1ª etapa, uma análise intermediária de cada modelo dizendo respeito apenas às previsões de Velocidades Médias de vento e Direções Médias de Vento, e a 2ª etapa uma Análise comparativa dos modelos entre si.

É importante enfatizar que a comparação entre os modelos não será feita apenas na 2ª etapa, pois, ao final de cada etapa poderá ser feita uma análise comparativa das respostas obtidas, havendo assim conclusões intermediárias que serão referenciadas e consolidadas na última etapa deste capítulo.

5.1 Série Temporal

Uma série temporal é uma sequência de dados numéricos no qual cada item é associado há um instante particular no tempo de acordo com MADDALA, G. S. (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 sua 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.

5.1.1 Previsão de séries temporais

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.

5.1.2 Coeficiente de correlação e autocorrelação

Os coeficientes de correlação e autocorrelação podem ser interpretados como a relação existente entre duas variáveis conforme BISQUEIRA, R. et al (2004). As expressões dos coeficientes autocorrelação e correlação, são respectivamente.

$$C_i = \frac{\sum_{t=1}^{N-i} (X(t) - \bar{X})(X(t+1) - \bar{X})}{\sum_{t=1}^N (X(t) - \bar{X})^2}, \quad (5.1)$$

$$\rho_i = \frac{\sum_{t=1}^{N-i} (X(t) - \bar{X})(Y(t) - \bar{Y})}{[\sum_{t=1}^{N-1} (X(t) - \bar{X})^2 \cdot \sum_{t=1}^{N-1} (Y(t) - \bar{Y})^2]^{1/2}}, \quad (5.2)$$

A interpretação relacionada aos coeficientes de autocorrelação e correlação está descrita na Tabela 5.1. 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 5.1 - Coeficiente de correlação.

Coeficiente	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

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).

5.2 Comparação com o Método da Persistência

Os modelos de referência resultam de considerações simples e não exigem esforços de modelagem. Portanto, só é vantajoso desenvolver e implementar uma ferramenta avançada de previsão de geração eólica 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 da referência MADSEN, H. 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 medida no instante tempo $t + k$ é igual ao último valor medido (em t), ou seja,

$$\hat{v}_{pers}(t + k|t) = v(t). \quad (5.3)$$

Apesar de sua aparente simplicidade, este modelo pode ser difícil de ser batido para os primeiros passos de previsão (em torno de quatro até às seis horas), pois a escala de mudanças na atmosfera é lenta (MADSEN, H. et al, 2004). Uma generalização do Modelo da Persistência é obtida ao substituir o último valor medido pela média dos últimos n valores medidos:

$$\hat{v}_{MM,n}(t + k|t) = \frac{1}{n} \sum_{i=0}^{n-1} v(t - i), \quad (5.4)$$

Às vezes, tais modelos são referidos como previsores de média móvel. Assintoticamente (quando n tende ao infinito), eles tendem à média global:

$$\hat{v}_0(t + k|t) = \overline{v(t)}. \quad (5.5)$$

Este último modelo também pode servir como um modelo de referência, mas como ele não é muito dinâmico, o seu desempenho pode ser ruim para horizontes de previsão curtos. No entanto, para horizontes mais longos, a sua habilidade de previsão é melhor do que a do Modelo da Persistência (MADSEN, H. et al, 2004).

5.3 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 definido como:

$$e_v(t + k|t) = v(t + k) - \bar{v}(t + k|t), \quad (5.6)$$

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, H. et al., 2004).

$$e = \mu_e + \varepsilon_e, \quad (5.7)$$

Em que, μ_e é um valor constante, enquanto que ε_e é uma variável 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 Expressão:

$$\hat{\mu}_e(k) = \overline{e(k)} = \frac{1}{N} \sum_{t=1}^N e(t + k|t), \quad (5.8)$$

Os dois tipos básicos de erros utilizados nesta dissertação para medir o desempenho de um modelo de previsão são: o erro absoluto médio (*Mean Absolut Error – MAE*) e o erro absoluto médio normalizado (*Normalized Mean Absolut Error – NMAE*).

As Expressões utilizadas para calculá-los são definidas a seguir:

$$MAE_v(k) = \frac{1}{N} \sum_{t=1}^N |e_v(t + k|t)|, \quad (5.9)$$

$$NMAE_P(k) = \frac{1}{P_{(Máx-Instal)}N} \sum_{t=1}^N |e_P(t + k|t)|, \quad (5.10)$$

5.4 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 (MADSEN, H. et al., 2004). A fórmula utilizada para calcular estes ganhos percentuais para cada passo de previsão é a seguinte:

$$G_{ref,CA}(k) = 100 \left(\frac{CA_{ref}(k) - CA(k)}{CA_{ref}(k)} \right), \quad (5.11)$$

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 ou NMAE. Obviamente, ao calcular o ganho, o mesmo critério deve ser utilizado para os dois modelos que estão sendo comparados.

Outro fator de bastante relevância é a utilização dos conceitos relativos a os métodos e parâmetros comparativos estabelecidos nas seções iniciais deste capítulo, tais como:

- O Erro Médio Absoluto (MAE)
- O Erro Médio Absoluto Normalizado (NMAE)
- O Método da Persistência (Mod. Per)

5.5 (1ª Etapa) Análise intermediária dos modelos previsores

Objetivando aferir a eficiência em caráter inicial dos modelos de previsão foram analisadas as RNAs de previsão de velocidade média de vento RNA1 e de previsão de velocidade média de vento e direção média do vento RNA2, ambas, presentes na entrada dos modelos em questão e cruciais para uma boa resposta na saída de cada modelo.

Mostrando os resultados obtidos na primeira etapa dos experimentos relativos ao período de simulação para ambos os Parques 01 e 02, em que o objetivo foi uma predição de velocidades no que diz respeito a RNA1 e de velocidades e direções no que diz respeito a RNA2, ambas treinadas para um horizonte de 24h.

De forma a demonstrar a eficiência das Redes intermediárias dos modelos previsores (RNA1 e RNA2) as Tabelas (5.2 e 5.3) expõem os resultados relativos ao período de simulação para tais RNAs inferindo previsões nos Parques (01 e 02). Para isso as Tabelas 5.2 e 5.3 fazem uso do método da persistência, que como é de conhecimento, serve como parâmetro de avaliação nas primeiras horas da previsão.

Tabela 5. 2 - Desempenho das previsões no período de Simulação das redes (RNA1 e RNA2) para o Parque 01.

MAE da RNA1 em [m/s]												
Horizonte	1h	2h	3h	4h	5h	6h	7h	8h	9h	10h	11h	12h
RNA1.	0,7569	1,0016	1,1732	1,1923	1,2734	1,2997	1,3693	1,3879	1,4359	1,4161	1,3924	1,3879
Mod.Per	0,7144	1,1208	1,4139	1,6524	1,8581	2,0438	2,2078	2,3388	2,4270	2,4847	2,5240	2,5388
Horizonte	13h	14h	15h	16h	17h	18h	19h	20h	21h	22h	23h	24h
RNA1.	1,4165	1,4284	1,4249	1,4415	1,4012	1,4073	1,3685	1,3819	1,4154	1,3828	1,3988	1,4094
Mod.Per	2,5221	2,4833	2,4285	2,3428	2,2415	2,1238	2,0110	1,8993	1,7779	1,6694	1,5868	1,5603
MAE da RNA2 em [m/s]												
Horizonte	1h	2h	3h	4h	5h	6h	7h	8h	9h	10h	11h	12h
RNA2.	0,7984	1,0449	1,1575	1,2225	1,2430	1,2939	1,3392	1,3296	1,3163	1,3514	1,3704	1,3783
Mod.Per	0,7144	1,1208	1,4139	1,6524	1,8581	2,0438	2,2078	2,3388	2,4270	2,4847	2,5240	2,5388
Horizonte	13h	14h	15h	16h	17h	18h	19h	20h	21h	22h	23h	24h
RNA2.	1,3618	1,3804	1,3878	1,3811	1,4293	1,4575	1,3504	1,3765	1,3727	1,4127	1,4710	1,4329
Mod.Per	2,5221	2,4833	2,4285	2,3428	2,2415	2,1238	2,0110	1,8993	1,7779	1,6694	1,5868	1,5603
MAE da RNA2 em [°]												
Horizonte	1h	2h	3h	4h	5h	6h	7h	8h	9h	10h	11h	12h
RNA2.	11,9779	13,3570	16,1980	15,2005	15,0883	12,5283	12,7632	12,9194	12,8972	13,8040	15,0162	14,1159
Mod.Per	6,9712	12,4501	17,3000	21,6489	25,5776	29,0097	31,8689	34,2129	36,0089	37,3164	38,1023	38,3684
Horizonte	13h	14h	15h	16h	17h	18h	19h	20h	21h	22h	23h	24h
RNA2.	12,9085	13,7793	13,1237	14,3205	13,8271	14,7802	13,4886	14,7917	14,7216	13,7403	13,6298	13,3394
Mod.Per	38,1690	37,4946	36,3086	34,5569	32,3162	29,5976	26,4669	22,9493	19,1897	15,4920	12,4705	11,2108

Tabela 5.3 - Desempenho das previsões no período de Simulação das redes (RNA1 e RNA2) para o Parque 02.

MAE da RNA1 em [m/s]												
Horizonte	1h	2h	3h	4h	5h	6h	7h	8h	9h	10h	11h	12h
RNA1.	0,8086	1,0484	1,1523	1,2066	1,2260	1,2261	1,2245	1,2566	1,2528	1,2287	1,2309	1,2452
Mod.Per	0,9230	1,5040	1,9820	2,4164	2,7999	3,1590	3,4744	3,7519	3,9667	4,1064	4,1690	4,1831
Horizonte	13h	14h	15h	16h	17h	18h	19h	20h	21h	22h	23h	24h
RNA1.	1,2310	1,2350	1,2569	1,2234	1,1986	1,2117	1,2155	1,2301	1,2204	1,2300	1,2480	1,2710
Mod.Per	4,1793	4,1143	4,0006	3,7883	3,5229	3,2147	2,8601	2,5056	2,1898	1,8867	1,6099	1,4293
MAE da RNA2 em [m/s]												
Horizonte	1h	2h	3h	4h	5h	6h	7h	8h	9h	10h	11h	12h
RNA2.	0,8324	1,0523	1,1334	1,1753	1,2022	1,2313	1,2458	1,2486	1,2341	1,2231	1,2624	1,2899
Mod.Per	0,9230	1,5040	1,9820	2,4164	2,7999	3,1590	3,4744	3,7519	3,9667	4,1064	4,1690	4,1831
Horizonte	13h	14h	15h	16h	17h	18h	19h	20h	21h	22h	23h	24h
RNA2	1,2566	1,2738	1,2834	1,2413	1,2361	1,2295	1,2347	1,2445	1,2766	1,2750	1,2772	1,2732
Mod.Per	4,1793	4,1143	4,0006	3,7883	3,5229	3,2147	2,8601	2,5056	2,1898	1,8867	1,6099	1,4293
MAE da RNA2 em [°]												
Horizonte	1h	2h	3h	4h	5h	6h	7h	8h	9h	10h	11h	12h
RNA2.	4,1197	4,2371	4,1241	4,0822	4,3823	4,0155	4,4101	4,2540	4,1887	3,9888	4,0878	3,8926
Mod.Per	3,1162	3,3207	3,4286	3,5069	3,5396	3,5836	3,5874	3,6858	3,6596	3,8394	3,7673	3,7723
Horizonte	13h	14h	15h	16h	17h	18h	19h	20h	21h	22h	23h	24h
RNA2.	3,8407	3,7776	3,8481	3,9704	3,9758	3,9081	3,9618	3,9606	4,0502	3,9988	3,9886	4,0277
Mod.Per	3,8152	3,8406	3,8247	3,7495	3,7991	3,7730	3,7218	3,7250	3,5689	3,5033	3,5314	3,4540

Com isso as Figuras 5.1 e 5.2 expõem graficamente o comportamento dos erros mostrados nas Tabelas 5.2 e 5.3.

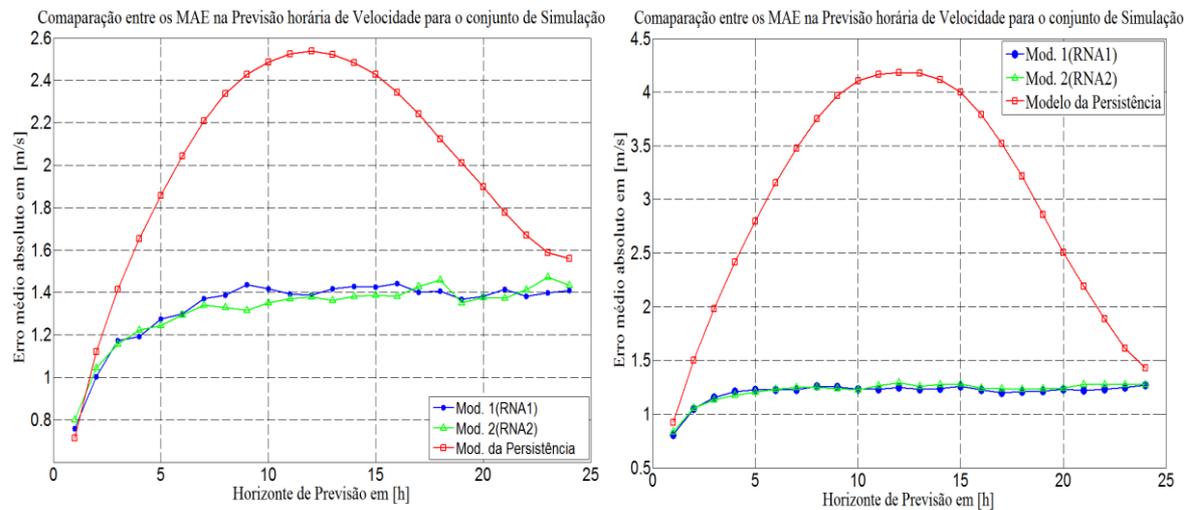


Figura 5.1 - Comparação entre os MAE das previsões de velocidade média cometidos pela RNA1, pela RNA2 e pelo Método da persistência para os Parques 01 (a) e 02 (b).

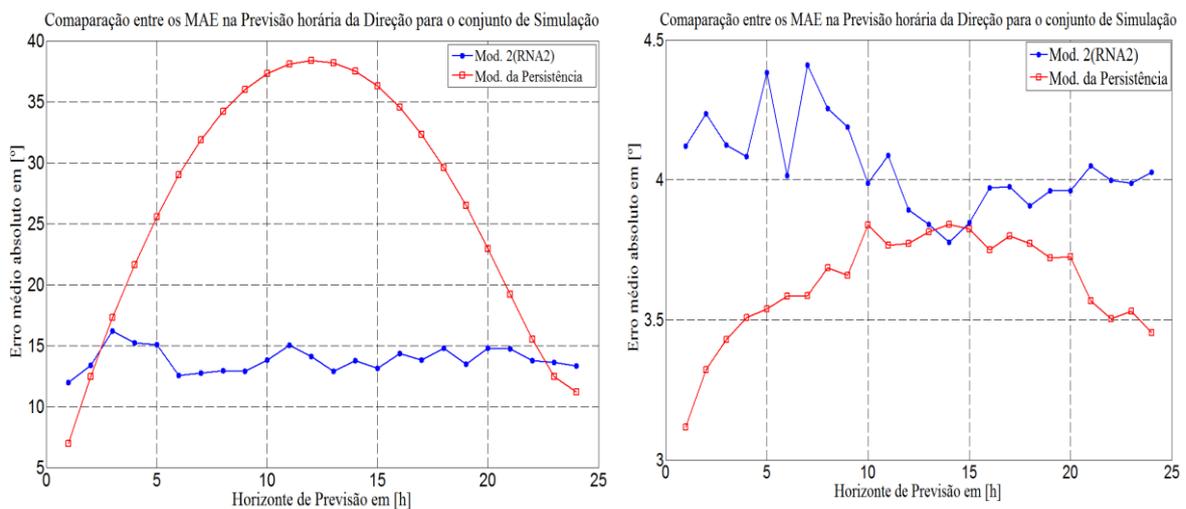


Figura 5.2 - Comparação entre os MAEs das previsões de direção média cometidos pela RNA2 e pelo Método da persistência para os Parques 01 (a) e 02 (b).

Com relação à Figura 5.1 nota-se que na primeira hora da previsão das velocidades o Parque 02 apresenta melhores resultados que o Parque 01 na comparação com o modelo da persistência. Pois na hora 1 para o Parque 01 as RNAs(1 e 2) apresentam um desempenho menor fato que se inverte da hora 2 em diante. Já com relação ao Parque 02 percebe-se um melhor desempenho das RNAs (1 e 2) em relação ao modelo da persistência, fato que corrobora uma melhor correlação entre velocidades e potências no Parque 01 do que no Parque 02

Outra característica aferida com os resultados, é mostrada nas Tabelas 5.2 e 5.3, nelas é possível perceber que devido ao problema na distribuição da direção a RNA1 leva certa vantagem em termos de desempenho quando comparada com a RNA2, nas primeiras 3h de previsão, sendo essa situação invertida da hora quatro em diante.

Sobre a comparação entre a RNA2 e o modelo da persistência, expressa pela Figura 5.2 pode-se notar que a rede tem desempenho menor que o modelo da persistência em relação à primeira hora em ambos os parques. Isto se deve ao fato já explicado anteriormente da forma concentrada da distribuição da direção nos dois parques. Porém é possível perceber pela Figura 5.2 um melhor comportamento no Parque 01 em relação ao Parque 02.

Isso acontece, pois apesar de haver uma concentração alta na distribuição da direção em ambos os parques no Parque 01 essa faixa de frequência de aparição de direções é maior que no Parque 02 o que agrava a situação deste último, conforme mostrado pela Figura 5.2(b). Nela pode-se notar um mau desempenho da RNA2 em relação ao modelo da persistência, na figura a RNA2 só tem resultado satisfatório na hora quatorze.

5.6 (2ª Etapa) Análise na saída dos modelos previsores e Comparação entre os modelos

Objetivando aferir o desempenho final dos modelos de previsão de Potência, foram analisadas as suas respectivas redes neurais artificiais que neste caso simularam curvas de potência, no caso dos Modelos M1a, M2a, bem como o desempenho dos SIFs que simularam também as curvas de Potência no caso dos Modelos M1b e M2b.

Mostrando os resultados obtidos nas saídas dos experimentos em que o objetivo foi uma predição de Potências no que diz respeito aos modelos citados anteriormente. Nesta etapa serão expostos os resultados relativos às previsões, bem como uma comparação entre esses quatro modelos.

De forma a demonstrar a eficiência das Redes e SIFs que simularam as curvas de potência nos modelos previsores (CP-RNAM1a, CP-RNAM2a, CP-FuzzyM1b e CP-FuzzyM2b) as Tabelas 5.3, 5.4 expõem os resultados do MAE relativos ao período de simulação para tais RNAs e SIFs inferindo previsões de potência nos Parques 01 e 02.

Bem como as Tabelas 5.6 e 5.7 expressam o erro médio absoluto normalizado (NMAE) cometido pelos modelos em cada parque em questão.

Com isso, logo após a apresentação das Tabelas 5.4, 5.5, 5.6, e 5.7 são mostradas as Figuras 5.3 e 5.4, que expõem o comportamento gráfico ditado nestas tabelas.

Tabela 5. 4 - Desempenho das previsões no período de Simulação dos modelos previsores (M1a, M1b, M2a e M2b) para o Parque 01.

MAE das Curvas de Potência dos modelos em [MW]												
Horizonte	1h	2h	3h	4h	5h	6h	7h	8h	9h	10h	11h	12h
M1a	5,4983	7,4311	8,7862	8,9065	9,4945	9,6892	10,2733	10,4579	10,8289	10,5869	10,3588	10,3675
M1b	5,4680	7,4352	8,7650	8,9321	9,4997	9,7128	10,2899	10,4478	10,8023	10,5543	10,3485	10,3547
M2a	5,8998	7,7929	8,7854	9,3179	9,2709	9,6941	10,0239	9,8416	9,7320	9,9805	10,2379	10,2072
M2b	5,9964	7,7258	8,6085	9,2407	9,2029	9,6204	9,9123	9,7209	9,6286	9,8773	10,0077	10,1580
Mod.Per	5,0207	8,0623	10,3003	12,0580	13,6638	15,0691	16,2990	17,2662	17,9586	18,4599	18,7995	18,9322
Horizonte	13h	14h	15h	16h	17h	18h	19h	20h	21h	22h	23h	24h
M1a	10,5202	10,6733	10,6318	10,7354	10,5066	10,5629	10,2751	10,3588	10,6016	10,4003	10,5525	10,6258
M1b	10,4642	10,6576	10,6154	10,7069	10,4815	10,5343	10,2541	10,3231	10,5904	10,3828	10,5569	10,6167
M2a	10,1643	10,2823	10,4256	10,4186	10,8822	10,8785	10,1389	10,3241	10,2593	10,6159	11,0612	10,7384
M2b	10,0821	10,1617	10,3764	10,1822	10,5874	10,6672	10,0657	10,1983	10,3138	10,5549	10,9344	10,6655
Mod.Per	18,7812	18,4273	17,9706	17,3486	16,5973	15,7027	14,8337	13,9723	13,0561	12,2111	11,6222	11,4221

Tabela 5. 5 - Desempenho das previsões no período de Simulação dos modelos previsores (M1a, M1b, M2a e M2b) para o Parque 02.

MAE das Curvas de Potência dos modelos em [MW]												
Horizonte	1h	2h	3h	4h	5h	6h	7h	8h	9h	10h	11h	12h
M1a	7,2312	9,2054	10,1577	10,3894	10,5700	10,6059	10,8088	11,0415	11,1539	11,1849	11,1922	11,2453
M1b	7,2230	8,9997	9,9104	10,3682	10,5708	10,6101	10,8074	11,0655	11,2746	11,3077	11,4589	11,3888
M2a	7,0420	9,2892	9,9456	10,3706	10,4264	10,9891	11,0763	11,3881	10,9757	11,3602	11,6890	11,7395
M2b	7,1328	9,1240	9,8684	10,1969	10,3347	10,8668	10,9444	11,2562	11,0120	11,3531	11,7757	11,8660

Mod.Per.	8,9653	15,5186	20,5351	25,1778	29,5092	33,7270	37,9104	41,6583	44,7131	46,4698	46,8647	47,2012
Horizonte	13h	14h	15h	16h	17h	18h	19h	20h	21h	22h	23h	24h
M1a	11,0849	11,0652	11,2897	10,9164	10,6493	10,6897	10,7172	11,0200	11,0231	10,9984	11,1781	11,4294
M1b	11,2465	11,2702	11,5149	11,2473	11,0415	11,0633	10,9593	11,1259	11,2932	11,3149	11,3052	11,6638
M2a	11,4716	11,4534	11,4926	10,9560	10,9559	10,8460	10,8820	11,2067	11,4331	11,4192	11,5206	11,4860
M2b	11,5291	11,5198	11,5411	11,1300	11,0906	10,9519	11,0415	11,2084	11,5175	11,4921	11,6547	11,5727
Mod.Per.	47,6021	47,2250	45,8759	43,3612	39,9521	35,8091	31,4874	27,4332	23,3468	19,1516	15,3361	12,9712

Tabela 5. 6 - Desempenho das previsões no período de Simulação dos modelos previsores (M1a, M1b, M2a e M2b) para o Parque 01.

NMAE das Curvas de Potência dos modelos em [%]												
Horizonte	1h	2h	3h	4h	5h	6h	7h	8h	9h	10h	11h	12h
M1a	7,7923	10,5316	12,4521	12,6225	13,456	13,7319	14,5596	14,8212	15,3471	15,0041	14,6808	14,6931
M1b	8,3614	10,5374	12,4221	12,6589	13,4633	13,7652	14,5832	14,807	15,3093	14,9579	14,6663	14,675
M2a	7,7494	11,0443	12,451	13,2057	13,139	13,7387	14,2062	13,9479	13,7926	14,1447	14,5095	14,466
M2b	8,4984	10,9492	12,2003	13,0963	13,0426	13,6343	14,048	13,7767	13,646	13,9984	14,1832	14,3962
Mod.Per	7,1155	11,4262	14,598	17,089	19,3648	21,3564	23,0995	24,4703	25,4515	26,1619	26,6433	26,8313
Horizonte	13h	14h	15h	16h	17h	18h	19h	20h	21h	22h	23h	24h
M1a	14,9095	15,1266	15,0678	15,2146	14,8904	14,9701	14,5622	14,6809	15,0249	14,7396	14,9554	15,0592
M1b	14,8302	15,1043	15,0445	15,1742	14,8547	14,9295	14,5325	14,6303	15,0091	14,7149	14,9616	15,0464
M2a	14,4052	14,5724	14,7755	14,7655	15,4226	15,4174	14,3691	14,6317	14,5398	15,0453	15,6762	15,2188
M2b	14,2887	14,4015	14,7058	14,4306	15,0048	15,1179	14,2655	14,4533	14,6171	14,9587	15,4967	15,1155
Mod.Per	26,6174	26,1157	25,4685	24,587	23,5223	22,2544	21,0228	19,802	18,5036	17,306	16,4714	16,1877

Tabela 5.7 - Desempenho das previsões no período de Simulação dos modelos previsores (M1a, M1b, M2a e M2b) para o Parque 02.

NMAE das Curvas de Potência dos modelos em [%]												
Horizonte	1h	2h	3h	4h	5h	6h	7h	8h	9h	10h	11h	12h
M1a	5,7391	7,3059	8,0617	8,2456	8,3889	8,4174	8,5784	8,7631	8,8523	8,8769	8,8827	8,9249
M1b	5,7325	7,1426	7,8654	8,2287	8,3896	8,4207	8,5773	8,7821	8,9481	8,9743	9,0944	9,0387
M2a	5,5889	7,3724	7,8934	8,2307	8,2749	8,7215	8,7907	9,0381	8,7108	9,0160	9,2770	9,3171
M2b	5,6610	7,2413	7,8320	8,0928	8,2022	8,6244	8,6860	8,9335	8,7397	9,0104	9,3458	9,4174
Mod.Per	7,1153	12,3163	16,2977	19,9824	23,4200	26,7675	30,0876	33,0621	35,4866	36,8808	37,1942	37,4613
Horizonte	13h	14h	15h	16h	17h	18h	19h	20h	21h	22h	23h	24h
M1a	8,7975	8,7819	8,9601	8,6638	8,4518	8,4839	8,5057	8,7460	8,7485	8,7289	8,8715	9,0709
M1b	8,9258	8,9446	9,1388	8,9264	8,7631	8,7804	8,6979	8,8301	8,9629	8,9800	8,9724	9,2570
M2a	9,1045	9,0900	9,1211	8,6952	8,6952	8,6079	8,6365	8,8942	9,0739	9,0629	9,1433	9,1159
M2b	9,1501	9,1427	9,1596	8,8334	8,8020	8,6919	8,7631	8,8956	9,1408	9,1207	9,2497	9,1847
Mod.Per	37,7794	37,4802	36,4094	34,4137	31,7080	28,4199	24,9900	21,7724	18,5292	15,1997	12,1715	10,2946

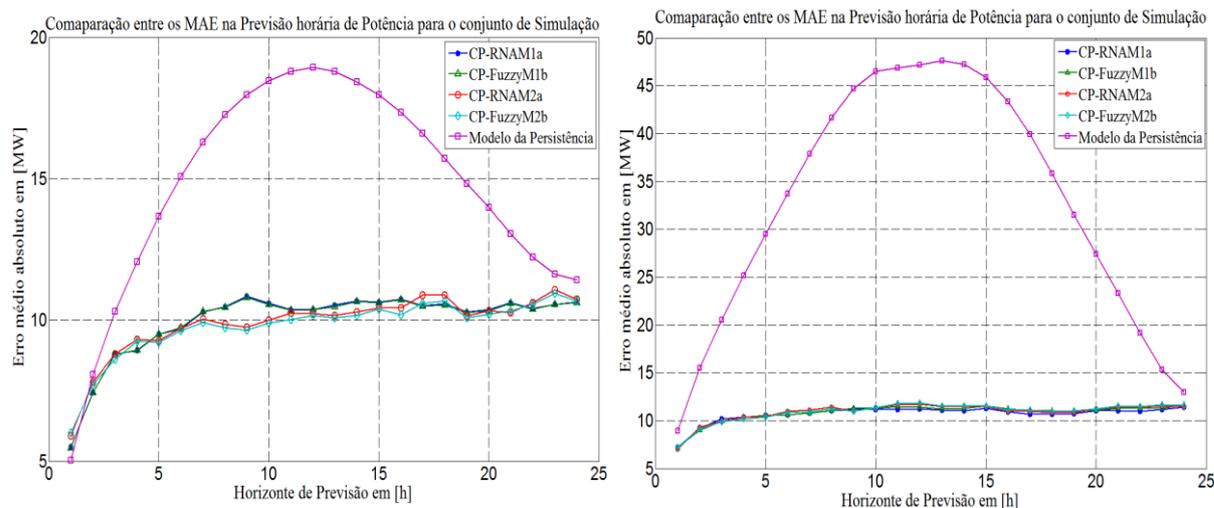


Figura 5.3 - Comparação entre os MAE das previsões de Potência Média cometidos pelos modelos M1a, M1b, M2a, M2b e pelo Modelo da Persistência para os Parques 01 (a) e 02 (b).

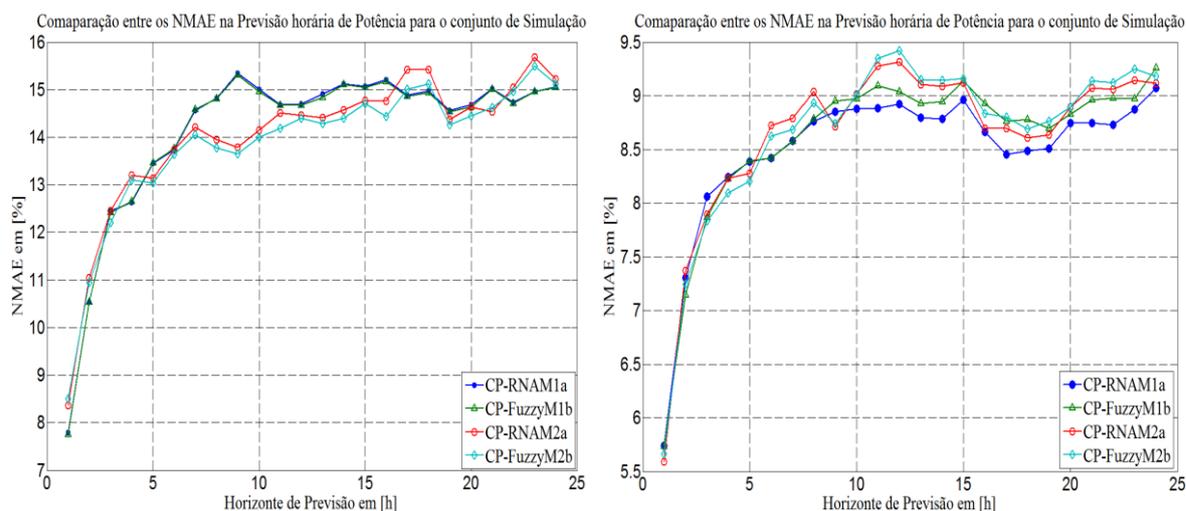


Figura 5.4 - Comparação entre os NMAE das previsões de Potência Média cometidos pelos modelos M1a, M1b, M2a, M2b para os Parques 01 (a) e 02 (b).

Com relação aos resultados relativos ao Parque 01 são feitas as seguintes análises:

Observando a Figura 5.3, percebe-se que na primeira hora do horizonte de previsão os modelos apresentam piores resultados que o modelo da persistência, fato que corrobora a aplicação da persistência como padrão de avaliação da eficiência de um previsor nas primeiras horas, porém esta perspectiva se inverte da hora dois até o fim do horizonte.

Isto acontece devido à boa distribuição das grandezas de entrada e saída nos Modelos, característica intrínseca ao parque em específico, assim a correlação entre os valores é muito boa no início do horizonte e começa a piorar gradativamente até o fim do mesmo.

Com relação ao erro médio absoluto normalizado NMAE de potência cometido pelos modelos nas previsões dos referentes ao Parque 01, pela Figura 5.4 acima nota-se uma ligeira vantagem dos modelos com uma entrada na previsão de potências, esse comportamento é expresso da hora um até a hora dois, sendo os melhores desempenhos referentes aos modelos (M1b e M1a) respectivamente. Logo concluiu-se que nas duas primeiras horas o modelo Fuzzy M1b leva vantagem sobre os seus concorrentes.

No período compreendido da hora dois até a hora seis há uma competição intensa entre os modelos, porém o esperado se mantém com os modelos Fuzzy tendo uma pequena vantagem sobre os modelos a RNAs. Da hora seis até a hora dezesseis, os modelos com duas entradas na previsão de potências se destacam tendo uma expressa vantagem em relação aos modelos com uma entrada situação inversa a expressa no início do horizonte.

Outra característica é que nesse período continua havendo vantagem dos modelos Fuzzy (M1b e M2b) em relação aos modelos que utilizam RNAs (M1a e M2a), sendo o modelo de melhor desempenho neste intervalo o (M2b). Já no intervalo compreendido da hora dezesseis até a hora vinte e um volta a haver uma competição intensa entre os modelos, até uma condição de estabilidade da hora dezoito até o final do horizonte sendo neste período o melhor desempenho do Modelo M2b.

Logo, para o Parque 01 os modelos Fuzzy (M1b e M2b) se destacam em relação aos modelos a RNAs (M1a e M2a), porém devido a características do vento do parque os modelos com CPs de um conjunto de entradas se destacam no início do horizonte de previsão. Já numa perspectiva intermediária até o final do horizonte os modelos com CPs com dois conjuntos de entradas se destacam. Porém nas duas perspectivas os modelos que utilizam lógica Fuzzy são melhores que os que utilizam RNAs

Em termos percentuais de análise a Tabelas 5.5 mostra o comportamento do desempenho dos modelos no Parque 01. No que diz respeito à primeira hora prevista no Parque 01 o melhor modelo foi o modelo M1b, cujo erro na hora um foi de 7,75% da capacidade de potência instalada do Parque 01 (70,56[MW]), sendo este o que mais se aproximou do modelo da persistência com um erro na hora um de 7,11%.

De forma semelhante ao feito no Parque 01, para o Parque 02, são expressas as seguintes análises.

Na Figura 5.3, percebe-se que na primeira hora do horizonte de previsão os modelos apresentam melhores resultados que o modelo da persistência, fato que comprova

a eficiência dos modelos para as primeiras horas, sendo esta perspectiva mantida até o final do horizonte.

Isto acontece devido à forma de concentração da distribuição de uma das grandezas da entrada, a direção, como pode ser visto pela Figura 4.34(b), nela é possível perceber que os valores de direção se concentram numa faixa muito pequena comparada com os 360° abordados, porém esta é uma característica do parque em específico.

Assim a correlação entre os valores que já não é muito boa no início do horizonte, começa a piorar gradativamente até o fim do mesmo. Influenciando no mau desempenho do modelo da persistência no começo e consequente piora no decorrer das previsões

Com relação ao NMAE de potência cometido pelos modelos:

Pela Figura 5.4 acima nota-se que na primeira hora do horizonte há uma ligeira vantagem dos modelos com CPs com dois conjuntos de entradas em relação aos modelos com CPs com um conjunto de entradas. Obtendo melhor desempenho o modelo (M2a), seguido pelos modelos M2b, M1b e M1a respectivamente.

Esta situação mantém-se até a segunda hora quando começa uma competição intensa entre os modelos prolongando-se esta até a hora cinco, sendo o modelo de melhores resultados neste período o (M2b). Após esse período a situação volta a se inverter da hora cinco a hora oito tendo os modelos com CPs com um único conjunto de entradas ligeira vantagem sobre os com CPs de duplo conjunto de entradas, destacando-se nesse intervalo o modelo (M1a).

No intervalo compreendido da hora oito a dez ocorre nova inversão no desempenho sendo os melhores resultados expressos pelos modelos (M2a e M2b). Em que, da hora dez a hora quinze os modelos com CPs com um conjunto de entrada voltam a liderar sendo os melhores resultados expressos pelos modelos (M1a e M1b) seguidos dos modelos (M2a e M2b) respectivamente.

Da hora quinze a dezenove os melhores resultados são dos modelos com CPs a (RNAs) caso dos Modelos (M1a e M2a) levando esses uma pequena vantagem sobre os modelos Fuzzy (M1b e M2b). Desta hora até o fim do horizonte os melhores resultados são expressos pelos modelos com CPs com conjunto único de entrada (M1a e M1b), seguidos respectivamente pelos modelos (M2a e M2b).

Assim, as simulações para o Parque 02 mostram uma acirrada competição entre os modelos previsores tendo os modelos a RNAs uma pequena vantagem em relação aos modelos Fuzzy, diferentemente dos resultados observados no Parque 01.

Logo em termos percentuais de análise, a Tabela 5.6 mostra o comportamento do desempenho dos modelos em cada parque. No que diz respeito à primeira hora prevista no Parque 02 o melhor modelo foi o modelo M2a, cujo erro na hora um foi de 5,59% da capacidade de potência instalada do Parque 02 (126[MW]), contra o melhor modelo Fuzzy na primeira hora o (M2b) com 5,66%.

Em termos comparativos, faz-se agora uma análise em termos de ganho assertivo do valor previsto pelos modelos descritos nesta dissertação, para tal utilizou-se como referência o modelo da persistência. Assim o ganho expressa a margem de acerto do valor previsto tomando como referência as previsões executadas pelo modelo da persistência.

Para o cálculo do ganho foi utilizada a Expressão 5.11, esta expressão utiliza um critério de análise, conforme descrito no início deste capítulo, sendo utilizados os critérios do MAE e do NMAE, descritos respectivamente pelas Expressões 5.9 e 5.10. Esta análise foi feita para as previsões de potências médias expressas na saída de cada modelo analisado.

Mostrando as respostas obtidas no cálculo dos ganhos médios, as Tabelas 5.8 e 5.9, apresentam tais ganhos e critérios aplicados aos Parques sobre estudo:

Tabela 5. 8 – Ganhos Médios horários percentuais das previsões realizadas no Parque 01

Critério utilizado	Ganho médio percentual horário do Modelo M1a	Ganho médio percentual horário do Modelo M1b	Ganho médio percentual horário do Modelo M2a	Ganho médio percentual horário do Modelo M2b
MAE	28,9627	29,0625	29,0074	29,6454
NMAE	28,9627	28,7041	29,3659	29,6454

Tabela 5. 9 - Ganhos Médios horários percentuais das previsões realizadas no Parque 02

Critério utilizado	Ganho médio percentual horário do Modelo M1a	Ganho médio percentual horário do Modelo M1b	Ganho médio percentual horário do Modelo M2a	Ganho médio percentual horário do Modelo M2b
MAE	60,7263	60,3337	60,1933	60,0990
NMAE	60,7263	60,3337	60,1932	60,0990

As Tabelas 5.8 e 5.9 mostram que no Parque 01 os maiores ganhos médios horários são obtidos pelo Modelo M2b sendo estes 29,64% utilizando o MAE e o NMAE, fato que corrobora o que havia sido atestado anteriormente nas análises dos erros relativos aos modelos descritos. Já no Parque 02 os maiores ganhos médios horários são obtidos pelo Modelo M1a sendo estes de 60,72% utilizando o MAE e o NMAE, fato que também corrobora o que havia sido atestado anteriormente nas análises dos erros relativos aos modelos descritos.

Desta forma nota-se que uma competição benéfica mostrando o bom desempenho das ferramentas de IA utilizadas nesta dissertação sendo elas as RNAs representadas pelo Modelo M1a e os SIF representados pelo Modelo M2b.

CAPÍTULO 6

6 Conclusões e Propostas para trabalhos futuros

6.1 Conclusões

Este trabalho teve como meta o desenvolvimento de modelos de previsão de geração eólica. Foram desenvolvidos quatro modelos para este fim. Outro objetivo foi o de obter modelos para curva de potência de parques eólicos. O horizonte de previsão abordado estendeu-se da hora um à hora vinte e quatro, sendo utilizados para isso modelos puramente baseados em RNAs e modelos mistos, compostos por RNAs e SIFs.

Como pôde ser percebido, ao longo deste trabalho, no Capítulo 4 que mostra o desenvolvimento dos modelos, nota-se certa vantagem nas previsões realizadas pelos modelos mistos, nos primeiras horas de previsão. Outra característica bastante importante foi a influência da correlação na escolha das entradas dos modelos, fato que contribuiu de forma bastante evidente no desempenho dos modelos que utilizaram mais de uma entrada.

Uma dificuldade encontrada foi parametrizar modelo com SIF para o Parque 02, haja vista que a distribuição da direção de vento apresentou uma maior concentração na faixa de 0° e 50° , enquanto que para o Parque 01 o vento estava mais espalhado na faixa de 125° a 250° . Em decorrência deste problema foi mais difícil à modelagem do SIF utilizando-se funções de pertinência gaussianas para o Parque 02, o que refletiu na perda de desempenho do modelo de previsão por meio do SIF para este parque.

Desta forma, os modelos que utilizaram dois conjuntos de entradas (velocidade e direção do vento) nas curvas de potência (M2a e M2b) tiveram ligeira vantagem em relação aos modelos que utilizaram um único conjunto de entrada (M1a e M1b) para o Parque 01. Já para Parque 02, a situação foi invertida. Com isso, independente do modelo de previsão utilizado, o estudo de correlação comprovou que quando uma entrada é bem correlacionada com a saída uma melhor precisão é alcançada na previsão. Vale destacar que os modelos desenvolvidos obtiveram melhores resultados em termos de MAE e NMAE do que o modelo da persistência, excetuando apenas o resultado da primeira hora prevista para o Parque 01.

Este trabalho mostrou também que é possível um bom desempenho de modelos previsores de geração eólica utilizando a retro propagação do erro imposta pelo algoritmo *backpropagation* associado às redes do tipo MLP, fato comum nesse tipo de predição conforme mostrado por AQUINO, R. R. B. et. al (2009),(2013) e GOUVEIA, H. T. V., (2011). Porém existe outra abordagem aceitável que utiliza: redes competitivas (método Hebbiano) ou mapas organizáveis (redes de Kohonen), conforme mostrado por SIDERATOS, G. et. al (2007), sendo as duas abordagens bastante eficientes.

Um ponto relevante é que neste trabalho se obteve modelos baseados em inteligência artificial para a curva de potência dos parques. Estes modelos podem conectar modelos de previsão de ventos para se obter previsões de potência média. Logo, neste trabalho a potência foi prevista segundo a curva de potência modelada para o parque, i.e. forneceram-se dados de velocidades e/ou direções previstas como entradas à curva de potência, como resultado obtiveram-se previsões de potências ativas médias.

Logo, pode-se concluir que os modelos previsores utilizando o SIF e a RNA são ferramentas bastante interessantes e competitivas na obtenção de previsões em termos de geração de energia em parques eólicos, o que foi evidenciado em certas horas da previsão e parques eólicos quando os modelos SIF obtiveram melhores resultados comparados aos modelos RNA.

6.2 – Propostas para trabalhos futuros.

Dado que existem n formas de abordar um determinado problema, e que estando dentro desse conjunto de soluções uma solução de caráter ótimo, ou seja, que podem ser feitas novas abordagens com ideias distintas das mostradas aqui que venham a expressar erros menores. Listam-se a seguir algumas propostas que podem agregar uma melhor precisão às previsões de geração eólica, diminuindo assim o erro atrelado às mesmas:

- Utilizar um número maior de entradas, desde que as mesmas estejam correlacionadas e o fator de correlação se apresentar em uma faixa adequada, pois se mostrou neste trabalho que quando o número de entradas correlacionadas aumentou a precisão obteve uma considerável melhora;
- Variar o tipo e a quantidade das funções de pertinência na lógica Fuzzy e, conseqüentemente, o seu número de regras. Com isso os intervalos de análise seriam

menores. Buscando melhorar a precisão das previsões já que seriam menos pontos delimitados para cada trecho, havendo assim uma melhor aproximação;

- Desenvolver um filtro mais eficiente para a mesclagem das imperfeições da base, que em vez de excluir o ponto defeituoso cria-se na base filtrada um ponto correspondente de menor intensidade só que dentro da região condizente, pois com a filtragem o número de amostras se tornou menor e com isso o modelo tornou-se menos verossímil;
- Tentar uma nova abordagem, ou seja, um modelo puramente formado por SIFs que prediriam as potencia médias só com as entradas de velocidade e/ou direção, ou outras variáveis correlacionadas;
- Tentar uma abordagem com vários SIFs, um prevendo velocidades e/ou direções cuja saída alimentaria outro SIF que estivesse parametrizado como uma curva de potência do parque para assim expressar gerações previstas na sua saída;
- Verificar como seria o comportamento das previsões, se em vez de uma RNA fornecendo dados previstos de velocidades e/ou direções para os SIFs e/ou RNAs dependendo do modelo em análise, fosse essa alimentação de previsões fornecida por um SIF para arquiteturas que utilizam RNAs ou SIFs para simular as curvas de potência.

REFERÊNCIAS BIBLIOGRÁFICAS

AFONSO MARQUES, A. C.; 2014. *Comparação Entre Técnicas de Inteligência Artificial e Funções de Pedotransferência para Estimar a Condutividade Hidráulica Saturada de uma Área do Agreste Pernambuco*. Recife. Tese (Doutorado em Engenharia Elétrica) – Centro de Tecnologia e Geociências, Universidade Federal de Pernambuco.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA - ANEEL, *Banco de Informações de Geração-Capacidade de Geração do Brasil*.

Disponível: <<http://www.aneel.gov.br/aplicacoes/capacidadebrasil/capacidadebrasil.cfm>>. Acesso em: 21 set. 2015.

AQUINO, R. R. B., M. LIRA, M. M. S., DE OLIVEIRA, J. B., CARVALHO, M. A., NETO, O. N., DE ALMEIDA, G. J. *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., 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. Porto Alegre : Artmed, 2004.

COSTA, A., CRESPO, A., NAVARRO, J., LIZCANO, G., MADSEN, H., FEITOSA, E. 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.

- DAMOUSIS, I. G., ALEXIADIS, M. C., THEOCHARIS, J. B., DOKOPOULOS, P. S. *A Fuzzy Model For Wind Speed Prediction and Power Generation in Wind Parks Using Spatial Correlation*, IEEE Transactions on energy conversion, vol. 19, N°. 2, June 2004.
- EL-FOULY, T.H.M., EL-SAADANY, E.F., SALAMA, M.M.A.: *One Day Ahead Prediction Of Wind Speed And Direction*, IEEE Transactions on energy conversion, Vol. 23, N°. 1, March 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.
- FOCKENA, U., LANGEA, M., MÖNNICHA, K.; WALDLA, H.P.; BEYERB, H. G.; LUIGB, A.; *Short-term prediction of the aggregated power output of wind farms - a statistical analysis of the reduction of the prediction error by spatial smoothing effects.*; J. Wind Eng. Ind. Aerodyn. 90 (2002) 231–246.
- GIEBEL, G., KARINIOTAKIS, G. N., BROWNSWORD, R. *The State of the art in Short-Term Prediction of Wind Power. Literature Overview*. 36 p. 2003.
Disponível: <http://www.risoe.dk/rispubl/vea/veapdf/ANEMOS_giebel.pdf>. Acesso em: 09 set. 2014.
- GOUVEIA, H. T. V.; 2011. *Previsão de Ventos e Geração Eólica do Sistema NE: Analisando Diversos Sítios e Buscando a Melhor Modelagem Através da Inteligência Artificial*. Recife. Dissertação (Mestrado em Engenharia Elétrica) – Centro de Tecnologia e Geociências, Universidade Federal de Pernambuco.
- HAGAN, M. T., MENHAJ, M. B. *Training Feedforward Networks with the Marquardt Algorithm*. IEEE Transactions on Neural Networks, v. 5, n. 6, Nov.1994.
- HAYKIN, S. *Redes neurais: princípios e prática*. 2ª ed. Porto Alegre: Bookman, 2001.

- 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.; 2005. *Modelagem de fazendas Eólicas para Estudos de Confiabilidade*. Rio de Janeiro. Dissertação (Mestrado em Engenharia Elétrica) – Centro de Tecnologia, Universidade Federal do Rio de Janeiro.
- LIMA, F. G., PERERA, L. C. J., KIMURA, H., SILVA FILHO, A. C. *Aplicação de redes neurais na análise e na concessão de crédito ao consumidor*. RAUSP, v.44, n.1, p. 34-45, mar. 2009.
- LUDERMIR, T. B., BRAGA, A. P., CARVALHO, A. C. P. L. F. *Redes Neurais Artificiais: Teorias e Aplicações*. 1ª ed. Rio de Janeiro: LTC, 2000.
- MADDALA, G. S. *Introdução à Econometria*. 3ª ed. Rio de Janeiro: LTC, 2003.
- MADSEN, H., PINSON, P., KARINIOTAKIS, G., NIELSEN, H. A., NIELSEN, T. S. A *Protocol for Standardizing the Performance Evaluation of Short-term Wind Power Prediction Models*. 17 p. 2004.
- Disponível: < http://hal-enscm.archives-ouvertes.fr/docs/00/52/72/48/PDF/standardizing_-_00527248.pdf >. Acesso em: 21 set. 2015.
- MEYER, P. L. *Probabilidade, Aplicações à Estatística*. 2ª edição. São Paulo: LTC, 2000.

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

MIRANDA, C.; CERQUEIRA e C. MONTEIRO; *Previsão de potência eólica – treino de sistemas com critérios de entropia*. Simpósio Brasileiro de Sistemas Elétricos - SBSE 2006 Campina Grande–PB, Brasil.

OLIVEIRA, J. B.; 2008. *Sistemas Inteligentes e Wavelets para Previsão de Vento e geração Eólica*. Recife. Dissertação (Mestrado em Engenharia Elétrica) – Centro de Tecnologia e Geociências, Universidade Federal de Pernambuco.

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

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: 21 set. 2015.

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

RIEDMILLER, M., BRAUN, H. *A Direct Adaptive Method for Faster Backpropagation Learning: the RPROP Algorithm*. In: IEEE International Conference on Neural Networks, 1993, San Francisco.

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

SOUSA, J.N.M.S.; 2007. *Previsão da Produção Eléctrica em Parques Eólicos*.
Dissertação (Mestrado em Engenharia Electrotécnica e de Computadores) –
Faculdade de Engenharia, Universidade do Porto.

STIEBLER, M. *Wind Energy Systems for Electric Power Generation Green Energy and Technology*. 1ª ed. Berlin Heidelberg : © Springer-Verlag, 2008.

ÜSTÜNTAS, T., SAHIN, A.D. *Wind turbine power curve estimation based on cluster center Fuzzy logic modeling*. J. Wind Eng. Ind. Aerodyn. 96 (2008) 611–620.

WU, B., LANG, Y., ZARGARI, N., KOURO, S. *Power Conversion and Control of Wind Energy Systems*. 1ª ed. Berlin : © The Institute of Electrical and Electronics Engineers, Inc., 2011.