

FELIPE SHOHO HIRUMA

PREVISÃO DA GERAÇÃO DE ENERGIA EÓLICA COM REDES NEURAIAS
ARTIFICIAIS

Dissertação apresentada como requisito parcial à obtenção do grau de Mestre em Engenharia de Recursos Hídricos, pelo Programa de Pós-Graduação em Engenharia de Recursos Hídricos e Ambiental, Setor de Tecnologia, Universidade Federal do Paraná.

Orientador: Prof. Dr. Alexandre Kolodynskie Guetter
Coorientador: Prof. Dr. Fábio Teodoro de Souza

CURITIBA
2016

H671p

Hiruma, Felipe Shogo

Previsão da geração de energia eólica com redes neurais artificiais. /
Felipe Shogo Hiruma. – Curitiba, 2016.

168f. : il. [algumas color.] ; 30 cm.

Dissertação (mestrado) - Universidade Federal do Paraná, Setor de
Tecnologia, Programa de Pós-graduação em Engenharia de Recursos
Hídricos e Ambiental, 2016.

Orientador: Alexandre Kolodynskie Guetter-- Coorientador: Fábio
Teodoro de Souza.

1. Energia eólica. 2. Redes neurais artificiais. I. Guetter, Alexandre
Kolodynskie . II. Souza, Fábio Teodoro de. III. Título.

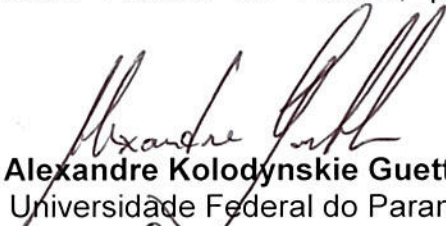
CDD: 621.3

TERMO DE APROVAÇÃO
FELIPE SHOGO HIRUMA

**“Previsão da Geração de Energia Eólica com
Redes Neurais”**

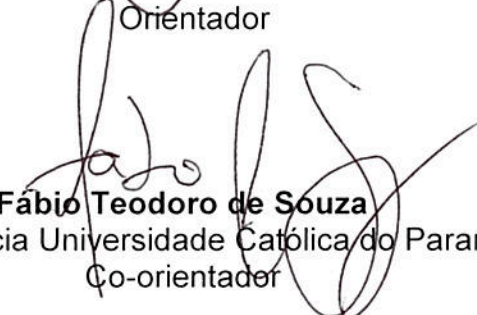
Dissertação aprovada como requisito parcial à obtenção do grau de Mestre, pelo Programa de Pós-Graduação em Engenharia de Recursos Hídricos e Ambiental do Setor de Tecnologia da Universidade Federal do Paraná, pela comissão formada pelos professores:

PRESIDENTE:



Alexandre Kolodynskie Guetter
Universidade Federal do Paraná
Orientador

MEMBROS:



Fábio Teodoro de Souza
Pontifícia Universidade Católica do Paraná
Co-orientador



Julio Cesar Niévola
Pontifícia Universidade Católica do Paraná



Eloy Kaviski
Universidade Federal do Paraná



Heinz Dieter Oskar August Fill
Universidade Federal do Paraná



Marcelo Rodrigues Bessa
Universidade Federal do Paraná

Curitiba, 29 de fevereiro de 2016

AGRADECIMENTOS

Todos aqui citados trouxeram importante contribuição para esse trabalho:

Alexandre Kolodynskie Guetter: pela direção e orientação dessa dissertação e o conhecimento transmitido em nossas reuniões, sempre muito proveitosas.

Fábio Teodoro de Souza: por ter ministrado a matéria de Energia e Meio Ambiente, decisiva para eu seguir essa linha de estudo, e incentivo à pesquisa.

Marcelo Rodrigues Bessa: pelas relevantes trocas de ideia ainda na graduação, sempre me encorajando a seguir pelo mestrado.

André Luiz Tonso Fabiani: tornou possível o meu ingresso na pós-graduação e me ajudou com o tratamento de dados com o *Excel*.

João Marcos Lima: pela disposição em me auxiliar, sempre que necessário.

Companhia Paranaense de Energia (COPEL): por ter disponibilizado os dados utilizados nessa dissertação.

A família sempre respeitando e valorizando este trabalho, executado com o máximo esforço e dedicação.

Deus, que está acima de tudo e de todos. Louvado seja!

RESUMO

A geração de energia elétrica por fonte eólica tem se mostrado competitiva pela contínua diminuição de seus custos, tanto para instalação quanto nos equipamentos. As maiores capacidades instaladas, ao final de 2015, estavam na China (145.104 MW) e nos Estados Unidos da América (EUA) (74.471 MW), conforme relatório anual elaborado pelo *Global Wind Energy Council* (GWEC). No Brasil, ressalta-se a existência de diversas áreas favoráveis à implantação e à expansão dessa tecnologia, que poderia ajudar na diversificação de sua matriz energética. Considerando que o vento é um fenômeno natural e inconstante, qualquer estimativa de geração de energia baseada nele, para tomar decisões e buscar eficiência energética, torna-se um grande desafio. Estudos da previsão de geração dividem-se em três categorias: estatísticas, físicas e híbridas. As primeiras, de fácil implementação, podem envolver inteligência computacional e são baseadas, essencialmente, nas estruturas de persistência temporal extraídas dos dados históricos das variáveis de interesse, não contemplando as características meteorológicas específicas do local onde se encontra o empreendimento. As físicas fundamentam-se em modelos determinísticos de previsão meteorológica, que posteriormente são convertidos através de modelos de transformação de vento em potência. Finalmente, as híbridas utilizam uma combinação das abordagens estatísticas (maior precisão no curto prazo) e físicas (maior precisão no médio prazo), considerando uma ou outra dependendo do período estudado. Neste trabalho, foram implementados modelos estatísticos com Redes Neurais Artificiais (RNA) para as previsões de velocidade de vento e de geração eólica de curtíssimo prazo para a Usina Eólio-Elétrica de Palmas (PR). As RNA produziram resultados de geração satisfatórios para horizontes de previsão de até seis horas.

Palavras-chave: energia eólica, Redes Neurais Artificiais, previsão de curtíssimo prazo, Usina Eólio-Elétrica de Palmas.

ABSTRACT

Wind energy, as a clean power generation source, is already consolidated and has become competitive by its constant decrease in costs, including equipment's installation and purchase. The largest installed capacities, by the end of 2015, were in China (145,104 MW) and the United States of America (USA) (74,471 MW), according to the annual Global Wind Energy Council's report. In Brazil, there are several areas favorable to the implementation and expansion of this technology, which could help in the diversification of its energy matrix. Whereas wind is a natural and highly variable phenomenon, its generation forecast becomes a challenge. Forecasting methods are divided into three categories: statistical, physical and hybrid. The first one, which is easy to implement, may involve computational intelligence and is based on the persistence structure estimated from historical data of the variables of interest. It doesn't consider specific meteorological characteristics of the site. Physical models are based on information generated by weather prediction models, which are then converted by wind models into power. In this case, it is noteworthy the need of many data and lot of computational effort. Finally, hybrid models use a combination of statistical (short-term forecast) and physical approaches (medium-term forecast), using one or another depending on the period considered. This study develops statistical models based on Artificial Neural Networks (ANN) for wind and generation predictions for the Palmas Wind Farm (PR). The ANN were sufficiently trained and reach satisfactory results for forecasts up to six hours.

Key-words: wind energy, Artificial Neural Networks, very short-term prediction, Palmas Wind Farm.

LISTA DE ILUSTRAÇÕES

Figura 1 – Velocidade de vento V sobre uma área transversal A delimitada pelas pás do aerogerador.....	27
Figura 2 – Redução da velocidade do vento após a passagem pelo aerogerador....	28
Figura 3 – Distribuição do coeficiente C_p em função de V_3/V_1	30
Figura 4 – Exemplo de aerogerador de eixo vertical (<i>Darrieus</i>)	32
Figura 5 – Exemplo de aerogerador de eixo horizontal.....	32
Figura 6 – Componentes de um aerogerador de eixo horizontal.....	33
Figura 7 – Curva de potência do aerogerador ENERCON E-40	34
Figura 8 – Modelo de rugosidade.....	36
Figura 9 – Etapas dos modelos estatísticos.....	39
Figura 10 – Etapas dos modelos físicos.....	41
Figura 11 – Árvore de Agrupamento no estudo sobre incêndios florestais	44
Figura 12 – Etapas para classificação conforme o Método <i>k-Means</i>	45
Figura 13 – Análise Fatorial no estudo sobre incêndios florestais.....	47
Figura 14 – Curvas da distribuição de Weibull	56
Figura 15 – Usina Eólico-Elétrica de Palmas – PR	61
Figura 16 – Vista aérea da UEE de Palmas.....	62
Figura 17 – Curvas de potência e de coeficiente de potência do aerogerador E-40.....	63
Figura 18 – Ciclo diário da massa específica do ar em Palmas (PR).....	64
Figura 19 – Tela representando o uso do programa <i>Statistica</i>	65
Figura 20 – Tela representando o uso do programa <i>Statistica Neural Networks</i>	67
Figura 21 – Neurônio biológico.....	68
Figura 22 – Neurônio artificial.....	69
Figura 23 – Arquitetura de uma rede MLP com duas camadas escondidas	71
Figura 24 – Propagação para frente dos sinais funcionais e retro propagação dos sinais de erro	72
Figura 25 – Validação cruzada.....	78
Figura 26 – Rosa dos ventos em Palmas (PR)	80
Figura 27 – Histograma de velocidade do vento em Palmas	82
Figura 28 – Histograma de potência em Palmas (período quente)	83
Figura 29 – Histograma de potência em Palmas (período frio)	84
Figura 30 – Ciclo diário da velocidade média do vento	85
Figura 31 – Variabilidade mensal da velocidade média do vento em Palmas.....	86
Figura 32 – Ciclo diário da potência nos períodos quente e frio.....	87
Figura 33 – Árvore de Agrupamento	89
Figura 34 – Análise Fatorial pelo Método dos Componentes Principais	91
Figura 35 – Raiz do erro médio quadrático do vento previsto (resolução de 10 minutos).....	93
Figura 36 – Velocidades do vento previstas e observadas durante o período quente – resolução de 10 minutos – 10 minutos à frente	94
Figura 37 – Resultados da previsão de velocidade do vento durante o período quente – resolução de 10 minutos – 10 minutos à frente	94
Figura 38 – Velocidades do vento previstas e observadas durante o período quente – resolução de 10 minutos – 20 minutos à frente	95
Figura 39 – Resultados da previsão de velocidade do vento durante o período quente – resolução de 10 minutos – 20 minutos à frente	95

Figura 40 – Velocidades do vento previstas e observadas durante o período frio – resolução de 10 minutos – 10 minutos à frente	96
Figura 41 – Resultados da previsão de velocidade do vento durante o período frio – resolução de 10 minutos – 10 minutos à frente	96
Figura 42 – Velocidades do vento previstas e observadas durante o período frio – resolução de 10 minutos – 20 minutos à frente	97
Figura 43 – Resultados da previsão de velocidade do vento durante o período frio – resolução de 10 minutos – 20 minutos à frente	97
Figura 44 – Raiz do erro médio quadrático do vento previsto (resolução de 1 hora)	99
Figura 45 – Velocidades do vento previstas e observadas durante o período quente – resolução de 1 hora – 1 hora à frente	100
Figura 46 – Resultados da previsão de velocidade do vento durante o período quente – resolução de 1 hora – 1 hora à frente	100
Figura 47 – Velocidades do vento previstas e observadas durante o período quente – resolução de 1 hora – 2 horas à frente	101
Figura 48 – Resultados da previsão de velocidade do vento durante o período quente – resolução de 1 hora – 2 horas à frente	101
Figura 49 – Velocidades do vento previstas e observadas durante o período frio – resolução de 1 hora – 1 hora à frente	102
Figura 50 – Resultados da previsão de velocidade do vento durante o período frio – resolução de 1 hora – 1 hora à frente	102
Figura 51 – Velocidades do vento previstas e observadas durante o período frio – resolução de 1 hora – 2 horas à frente	103
Figura 52 – Resultados da previsão de velocidade do vento durante o período frio – resolução de 1 hora – 2 horas à frente	103
Figura 53 – Raiz do erro médio quadrático do vento previsto (resolução de 3 horas)	104
Figura 54 – Velocidades do vento previstas e observadas durante o período quente – resolução de 3 horas – 3 horas à frente	105
Figura 55 – Resultados da previsão de velocidade do vento durante o período quente – resolução de 3 horas – 3 horas à frente	105
Figura 56 – Velocidades do vento previstas e observadas durante o período quente – resolução de 3 horas – 6 horas à frente	106
Figura 57 – Resultados da previsão de velocidade do vento durante o período quente – resolução de 3 horas – 6 horas à frente	106
Figura 58 – Velocidades do vento previstas e observadas durante o período frio – resolução de 3 horas – 3 horas à frente	107
Figura 59 – Resultados da previsão de velocidade do vento durante o período frio – resolução de 3 horas – 3 horas à frente	107
Figura 60 – Velocidades do vento previstas e observadas durante o período frio – resolução de 3 horas – 6 horas à frente	108
Figura 61 – Resultados da previsão de velocidade do vento durante o período frio – resolução de 3 horas – 6 horas à frente	108
Figura 62 – Raiz do erro médio quadrático do vento previsto – modelos aprimorados (resolução de 3 horas)	110
Figura 63 – Velocidades do vento previstas e observadas durante o período quente – modelos aprimorados – resolução de 3 horas – 3 horas à frente	111
Figura 64 – Resultados da previsão de velocidade do vento durante o período quente – modelos aprimorados – resolução de 3 horas – 3 horas à frente ..	111

Figura 65 – Velocidades do vento previstas e observadas durante o período quente – modelos aprimorados – resolução de 3 horas – 6 horas à frente	112
Figura 66 – Resultados da previsão de velocidade do vento durante o período quente – modelos aprimorados – resolução de 3 horas – 6 horas à frente ..	112
Figura 67 – Velocidades do vento previstas e observadas durante o período frio – modelos aprimorados – resolução de 3 horas – 3 horas à frente	113
Figura 68 – Resultados da previsão de velocidade do vento durante o período frio – modelos aprimorados – resolução de 3 horas – 3 horas à frente	113
Figura 69 – Velocidades do vento previstas e observadas durante o período frio – modelos aprimorados – resolução de 3 horas – 6 horas à frente	114
Figura 70 – Resultados da previsão de velocidade do vento durante o período frio – modelos aprimorados – resolução de 3 horas – 6 horas à frente	114
Figura 71 – Raiz do erro médio quadrático da potência prevista (resolução de 10 minutos)	122
Figura 72 – Potências previstas e observadas durante o período quente – resolução de 10 minutos – 10 minutos à frente.....	123
Figura 73 – Resultados da previsão de potência durante o período quente – resolução de 10 minutos – 10 minutos à frente	123
Figura 74 – Potências previstas e observadas durante o período quente – resolução de 10 minutos – 20 minutos à frente.....	124
Figura 75 – Resultados da previsão de potência durante o período quente – resolução de 10 minutos – 20 minutos à frente	124
Figura 76 – Potências previstas e observadas durante o período frio – resolução de 10 minutos – 10 minutos à frente.....	125
Figura 77 – Resultados da previsão de potência durante o período frio – resolução de 10 minutos – 10 minutos à frente.....	125
Figura 78 – Potências previstas e observadas durante o período frio – resolução de 10 minutos – 20 minutos à frente.....	126
Figura 79 – Resultados da previsão de potência durante o período frio – resolução de 10 minutos – 20 minutos à frente.....	126
Figura 80 – Raiz do erro médio quadrático da potência prevista (resolução de 1 hora)	128
Figura 81 – Potências previstas e observadas durante o período quente – resolução de 1 hora – 1 hora à frente	129
Figura 82 – Resultados da previsão de potência durante o período quente – resolução de 1 hora – 1 hora à frente	129
Figura 83 – Potências previstas e observadas durante o período quente – resolução de 1 hora – 2 horas à frente.....	130
Figura 84 – Resultados da previsão de potência durante o período quente – resolução de 1 hora – 2 horas à frente	130
Figura 85 – Potências previstas e observadas durante o período frio – resolução de 1 hora – 1 hora à frente	131
Figura 86 – Resultados da previsão de potência durante o período frio – resolução de 1 hora – 1 hora à frente	131
Figura 87 – Potências previstas e observadas durante o período frio – resolução de 1 hora – 2 horas à frente.....	132
Figura 88 – Resultados da previsão de potência durante o período frio – resolução de 1 hora – 2 horas à frente.....	132
Figura 89 – Raiz do erro médio quadrático da potência prevista (resolução de 3 horas).....	134

Figura 90 – Potências previstas e observadas durante o período quente – resolução de 3 horas – 3 horas à frente	135
Figura 91 – Resultados da previsão de potência durante o período quente – resolução de 3 horas – 3 horas à frente	135
Figura 92 – Potências previstas e observadas durante o período quente – resolução de 3 horas – 6 horas à frente	136
Figura 93 – Resultados da previsão de potência durante o período quente – resolução de 3 horas – 6 horas à frente	136
Figura 94 – Potências previstas e observadas durante o período frio – resolução de 3 horas – 3 horas à frente	137
Figura 95 – Resultados da previsão de potência durante o período frio – resolução de 3 horas – 3 horas à frente	137
Figura 96 – Potências previstas e observadas durante o período frio – resolução de 3 horas – 6 horas à frente	138
Figura 97 – Resultados da previsão de potência durante o período frio – resolução de 3 horas – 6 horas à frente	138
Figura 98 – Vista da nacele de um aerogerador	163
Figura 99 – Fluxo de ar aderente à pá	165
Figura 100 – Curva de potência típica de um aerogerador com controle de passo	165
Figura 101 – Fluxo separado em torno da pá	166
Figura 102 – Curva de potência típica de um aerogerador com controle tipo <i>stall</i>	166
Figura 103 – Esquema de um gerador com velocidade constante	167
Figura 104 – Esquema de um gerador com velocidade variável	168

LISTA DE TABELAS

Tabela 1 – Altura de rugosidade em função do tipo de solo.....	36
Tabela 2 – Resultados das previsões de velocidade do vento para resolução de 3 horas (período quente)	54
Tabela 3 – Resultados das previsões de velocidade do vento para resolução de 3 horas (período frio)	54
Tabela 4 – Resultados das previsões de potência para resolução de 3 horas (período quente)	54
Tabela 5 – Resultados das previsões de potência para resolução de 3 horas (período frio)	54
Tabela 6 – $RMSE$, R^2 , excesso de curtose e assimetria para os modelos NWP e os resultados do Filtro de Kalman	55
Tabela 7 – Resultados da previsão	57
Tabela 8 – Comparação dos erros de previsão.....	57
Tabela 9 – $NMAPE$ para diferentes métodos de previsão para horizonte de 24 horas	59
Tabela 10 – Localização da UEE de Palmas	62
Tabela 11 – Características técnicas da UEE de Palmas	62
Tabela 12 – Ventos vindos de cada direção.....	79
Tabela 13 – Estudo estatístico da velocidade do vento em Palmas – resolução de 10 minutos	81
Tabela 14 – Estudo estatístico da potência em Palmas (período quente)	82
Tabela 15 – Estudo estatístico da potência em Palmas (período frio)	83
Tabela 16 – Médias mensais da velocidade do vento em Palmas	86
Tabela 17 – Intervalos utilizados para treinamento, teste e validação dos modelos de previsão de velocidade do vento	88
Tabela 18 – Método k -Means.....	90
Tabela 19 – Correlação Linear entre as variáveis	91
Tabela 20 – Resultados das previsões de velocidade do vento para resolução de 10 minutos (período quente).....	92
Tabela 21 – Resultados das previsões de velocidade do vento para resolução de 10 minutos (período frio).....	92
Tabela 22 – Resultados das previsões de velocidade do vento para resolução de 1 hora (período quente)	98
Tabela 23 – Resultados das previsões de velocidade do vento para resolução de 1 hora (período frio)	98
Tabela 24 – Resultados das previsões de velocidade do vento para resolução de 3 horas (período quente)	104
Tabela 25 – Resultados das previsões de velocidade do vento para resolução de 3 horas (período frio)	104
Tabela 26 – Dados de entrada aos modelos aprimorados com resolução de 3 horas	109
Tabela 27 – Resultados das previsões de velocidade do vento dos modelos aprimorados – resolução de 3 horas (período quente)	109
Tabela 28 – Resultados das previsões de velocidade do vento dos modelos aprimorados – resolução de 3 horas (período frio)	109
Tabela 29 – Classificadores de geração (resolução de 10 minutos)	116

Tabela 30 – Classificadores de geração (resolução de 1 hora)	117
Tabela 31 – Classificadores de geração (resolução de 3 horas).....	119
Tabela 32 – Intervalos utilizados para treinamento, teste e validação dos modelos de previsão de potência (período quente)	121
Tabela 33 – Intervalos utilizados para treinamento, teste e validação dos modelos de previsão de potência (período frio)	121
Tabela 34 – Resultados das previsões de potência para resolução de 10 minutos (período quente)	121
Tabela 35 – Resultados das previsões de potência para resolução de 10 minutos (período frio)	122
Tabela 36 – Resultados das previsões de potência para resolução de 1 hora (período quente)	127
Tabela 37 – Resultados das previsões de potência para resolução de 1 hora (período frio)	127
Tabela 38 – Resultados das previsões de potência para resolução de 3 horas (período quente)	133
Tabela 39 – Resultados das previsões de potência para resolução de 3 horas (período frio)	133
Tabela 40 – Comparativo entre energias geradas e previstas pelos modelos – resolução de 10 minutos (período quente)	139
Tabela 41 – Comparativo entre energias geradas e previstas pelos modelos – resolução de 10 minutos (período frio)	139
Tabela 42 – Comparativo entre energias geradas e previstas pelos modelos – resolução de 1 hora (período quente).....	140
Tabela 43 – Comparativo entre energias geradas e previstas pelos modelos – resolução de 1 hora (período frio).....	140
Tabela 44 – Comparativo entre energias geradas e previstas pelos modelos – resolução de 3 horas (período quente)	141
Tabela 45 – Comparativo entre energias geradas e previstas pelos modelos – resolução de 3 horas (período frio)	141
Tabela 46 – Redes desenvolvidas e <i>delays</i> considerados em cada horizonte de previsão de velocidade do vento – resolução de 10 minutos.....	153
Tabela 47 – Redes desenvolvidas e <i>delays</i> considerados em cada horizonte de previsão de velocidade do vento – resolução de 1 hora.....	153
Tabela 48 – Redes desenvolvidas e <i>delays</i> considerados em cada horizonte de previsão de velocidade do vento – resolução de 3 horas	153
Tabela 49 – Redes desenvolvidas e <i>delays</i> considerados em cada horizonte de previsão de velocidade do vento – resolução de 3 horas (modelos aprimorados).....	154
Tabela 50 – Redes desenvolvidas e <i>delays</i> considerados em cada horizonte de previsão – resolução de 10 minutos (classificador de geração)	154
Tabela 51 – Redes desenvolvidas e <i>delays</i> considerados em cada horizonte de previsão – resolução de 1 hora (classificador de geração).....	154
Tabela 52 – Redes desenvolvidas e <i>delays</i> considerados em cada horizonte de previsão – resolução de 3 horas (classificador de geração)	155
Tabela 53 – Redes desenvolvidas e <i>delays</i> considerados em cada horizonte de previsão de potência – resolução de 10 minutos (período quente)	155
Tabela 54 – Redes desenvolvidas e <i>delays</i> considerados em cada horizonte de previsão de potência – resolução de 10 minutos (período frio)	155

Tabela 55 – Redes desenvolvidas e <i>delays</i> considerados em cada horizonte de previsão de potência – resolução de 1 hora (período quente).....	155
Tabela 56 – Redes desenvolvidas e <i>delays</i> considerados em cada horizonte de previsão de potência – resolução de 1 hora (período frio).....	156
Tabela 57 – Redes desenvolvidas e <i>delays</i> considerados em cada horizonte de previsão de potência – resolução de 3 horas (período quente).....	156
Tabela 58 – Redes desenvolvidas e <i>delays</i> considerados em cada horizonte de previsão de potência – resolução de 3 horas (período frio).....	156
Tabela 59 – <i>Delays</i> e variáveis considerados nos modelos de previsão	157
Tabela 60 – 1° modelo complementar desenvolvido para resolução de 3 horas (período quente)	158
Tabela 61 – 1° modelo complementar desenvolvido para resolução de 3 horas (período frio)	158
Tabela 62 – 2° modelo complementar desenvolvido para resolução de 3 horas (período quente)	158
Tabela 63 – 2° modelo complementar desenvolvido para resolução de 3 horas (período frio)	158
Tabela 64 – 3° modelo complementar desenvolvido para resolução de 3 horas (período quente)	158
Tabela 65 – 3° modelo complementar desenvolvido para resolução de 3 horas (período frio)	159
Tabela 66 – 4° modelo complementar desenvolvido para resolução de 3 horas (período quente)	159
Tabela 67 – 4° modelo complementar desenvolvido para resolução de 3 horas (período frio)	159
Tabela 68 – 5° modelo complementar desenvolvido para resolução de 3 horas (período quente)	159
Tabela 69 – 5° modelo complementar desenvolvido para resolução de 3 horas (período frio)	159
Tabela 70 – 6° modelo complementar desenvolvido para resolução de 3 horas (período quente)	160
Tabela 71 – 6° modelo complementar desenvolvido para resolução de 3 horas (período frio)	160
Tabela 72 – 7° modelo complementar desenvolvido para resolução de 3 horas (período quente)	160
Tabela 73 – 7° modelo complementar desenvolvido para resolução de 3 horas (período frio)	160
Tabela 74 – 8° modelo complementar desenvolvido para resolução de 3 horas (período quente)	160
Tabela 75 – 8° modelo complementar desenvolvido para resolução de 3 horas (período frio)	161
Tabela 76 – 9° modelo complementar desenvolvido para resolução de 3 horas (período quente)	161
Tabela 77 – 9° modelo complementar desenvolvido para resolução de 3 horas (período frio)	161
Tabela 78 – Vantagens dos aerogeradores de velocidades fixa e variável.....	168

LISTA DE ABREVIATURAS E SIGLAS

ABEEólica – Associação Brasileira de Energia Eólica

AF – Análise Fatorial

ANFIS – *Artificial Neuro-Fuzzy Inference System*

ANN – *Artificial Neural Networks*

AR – Autorregressivo

ARIMA – Autorregressivo Integrado de Média Móvel

ARMA – Autorregressivo de Média Móvel

BP – *Backpropagation*

CBA – *Classification Based on Associations*

CBEE – Centro Brasileiro de Energia Eólica da UFPE

COPEL – Companhia Paranaense de Energia

DEWI – *Deutsches Windenergie Institut*

DWIA – *Danish Wind Industry Association*

ELM – *Extreme Learning Machine*

EUA – Estados Unidos da América

FCM – *Fuzzy C-Means*

GWEC – *Global Wind Energy Council*

IEC – *International Electrotechnical Commission*

IVDN – Índice de Vegetação por Diferença Normalizada

JRC – *Joint Research Centre*

LM – *Levenberg Marquardt*

LR – *Logic Rules*

MA – Maranhão

MLP – *Multi-Layer Perceptron*

MOS – *Model Output Statistics*

NLN – *Neural Logic Network*

NN – *Neural Network*

NWP – Previsão Numérica de Tempo

PNN – *Probabilistic Neural Network*

PR – Paraná

PROINFA – Programa de Incentivo às Fontes Alternativas de Energia Elétrica

RAMS – *Regional Atmospheric Modeling System*

RBF – *Radial Basis Function*

RNA – Redes Neurais Artificiais

SCADA – *Supervisory Control and Data Acquisition*

SNN – *Statistica Neural Networks*

UEE – Usina Eólio-Elétrica

UFPE – Universidade Federal de Pernambuco

UGP – *Upper Great Plains*

USA – *United States of America*

USDOE – *United States Department of Energy*

LISTA DE SÍMBOLOS

E_c – energia cinética

m – massa do ar

V – velocidade do vento

P – potência

ρ – massa específica do ar

A – área varrida pelas pás do rotor

V_1 – velocidade do vento na entrada do rotor

V_3 – velocidade do vento na saída do rotor

A_1 – área da seção transversal na entrada do rotor

A_3 – área da seção transversal na saída do rotor

P_t – potência extraída do vento pela turbina eólica

P_1 – potência disponível na entrada do rotor eólico

P_3 – potência disponível na saída do rotor eólico

C_p – coeficiente de eficiência do rotor

P_{\max} – potência máxima produzida pelo aerogerador

$V_{cut\ in}$ – velocidade do vento mínima para que a turbina comece a gerar energia

V_c – velocidade de corte de geração

$V(h)$ – velocidade do vento na altura h

h – altura para a qual se quer determinar a velocidade $V(h)$

$V(z)$ – velocidade de referência (conhecida)

z – altura de referência

z_0 – “altura de rugosidade”

r – coeficiente de Correlação Linear

d – distância Euclidiana

NS – coeficiente de *Nash-Sutcliffe*

N – tamanho da série de dados

$pred(t)$ – valor previsto no instante t

$pred$ – média dos valores previstos

$meas(t)$ – valor medido no instante t

$meas$ – média dos valores medidos

R^2 – coeficiente de determinação

e_i – erro de previsão no instante i

v_{pred}^i – velocidade prevista do vento

v_{meas}^i – velocidade medida do vento

$RMSE$ – raiz do erro médio quadrático

$e_{t+k|t}$ – erro equivalente ao tempo $t+k$, para a previsão realizada no instante t

P_{t+k} – potência medida no instante $t+k$

$P_{t+k|t}$ – potência prevista para o momento $t+k$ no instante t

P_{inst} – potência instalada da usina eólica

MAE – erro médio absoluto

$NMAE$ – erro médio absoluto normalizado

$NRMSE$ – raiz do erro médio quadrático normalizado

$MAPE$ – erro percentual absoluto médio

$NMAPE$ – erro percentual absoluto médio normalizado

t_pos – quantidade de amostras GERA que foram corretamente classificadas como tais

pos – quantidade de amostras positivas

t_neg – quantidade de amostras NÃO GERA que foram corretamente classificadas como tais

neg – quantidade de amostras negativas

f_pos – quantidade de amostras NÃO GERA que foram incorretamente classificadas como GERA

f_neg – quantidade de amostras GERA que foram incorretamente classificadas como NÃO GERA

n – número da iteração

$u_j(n)$ – média ponderada

$w_{ij}(n)$ – peso

$y_i(n)$ – sinais de entrada no i -ésimo nó do neurônio j

$y_j(n)$ – sinais de saída do neurônio j

φ – função de ativação

$\theta_j(n)$ – polarizador

$v_j(n)$ – potencial de ativação do neurônio j na iteração n

$d_j(n)$ – resposta desejada para o neurônio j

$e_j(n)$ – sinal de erro

$\varepsilon(n)$ – valor instantâneo da soma dos erros quadráticos

MSE – erro médio quadrático

N' – tamanho do conjunto de treinamento

$\Delta w_{ij}(n)$ – correção aplicada à i -ésima sinapse do neurônio j

η – taxa de aprendizado

$\delta_j(n)$ – gradiente local do neurônio j

$\varphi_j(v_j(n))$ – função de ativação

α – fator de momento

V_{44} – velocidade do vento a 44 metros de altura

V_{46} – velocidade do vento a 46 metros de altura

V_{100} – velocidade do vento a 100 metros de altura

λ – razão de velocidade

SUMÁRIO

1 INTRODUÇÃO	22
1.1 OBJETIVO GERAL	23
1.2 ATIVIDADES	24
1.3 JUSTIFICATIVA	24
1.4 ORGANIZAÇÃO	25
2 FUNDAMENTAÇÃO TEÓRICA	26
2.1 PRINCÍPIOS FÍSICOS E TECNOLOGIA DOS AEROGERADORES	26
2.1.1 <i>Princípios físicos</i>	26
2.1.2 <i>Tecnologia</i>	31
2.2 CONTROLE DE VELOCIDADE	34
2.3 PERFIL DA VELOCIDADE DO VENTO	35
2.4 IMPORTÂNCIA E BENEFÍCIOS DA PREVISÃO DA GERAÇÃO EÓLICA	37
2.5 TIPOS DOS MODELOS DE PREVISÃO DA GERAÇÃO EÓLICA	38
2.5.1 <i>Modelos estatísticos</i>	38
2.5.2 <i>Modelos físicos</i>	40
2.5.3 <i>Modelos híbridos</i>	42
2.6 TÉCNICAS EM MINERAÇÃO DE DADOS (<i>DATA MINING</i>)	42
2.6.1 <i>Correlação Linear</i>	43
2.6.2 <i>Árvore de Agrupamento (Árvore Hierárquica)</i>	43
2.6.3 <i>Método k-Means</i>	45
2.6.4 <i>Análise Fatorial (AF)</i>	45
2.7 REDES NEURAS ARTIFICIAIS E APLICAÇÕES	47
2.8 AVALIAÇÃO DO DESEMPENHO DE PREVISÃO DA GERAÇÃO EÓLICA	49
2.8.1 <i>Nash-Sutcliffe (NS)</i>	50
2.8.2 <i>Coefficiente de determinação (R^2)</i>	50
2.8.3 <i>Indicadores de erro</i>	51
2.8.4 <i>Análise de desempenho dos métodos de previsão</i>	53
2.9 AVALIAÇÃO DO DESEMPENHO DOS MODELOS CLASSIFICADORES	59
3 ÁREA DE ESTUDO E DADOS	61
3.1 O PARQUE EÓLICO DE PALMAS – PR	61
3.2 DADOS DA UEE DE PALMAS	63
3.2.1 <i>Curvas de potência e de coeficiente de potência</i>	63
3.2.2 <i>Massa específica do ar</i>	63
3.2.3 <i>Dados</i>	64
4 MÉTODOS	65
4.1 FERRAMENTA <i>STATISTICA</i>	65
4.2 REDES NEURAS ARTIFICIAIS	67

4.2.1 Neurônio biológico.....	68
4.2.2 Neurônio artificial.....	69
4.3 MULTI-LAYER PERCEPTRON.....	71
4.3.1 Conceito.....	71
4.3.2 Algoritmo backpropagation.....	72
4.3.3 Derivada da função de ativação.....	74
4.3.3.1 Função logística.....	75
4.3.3.2 Função tangente hiperbólica.....	75
4.3.4 Taxa de aprendizado e fator de momento.....	76
4.3.5 Critério de parada para o treinamento da rede.....	77
5 ANÁLISE DOS RESULTADOS.....	79
5.1 DIREÇÃO DO VENTO.....	79
5.2 CORREÇÃO DOS DADOS ANEMOMÉTRICOS.....	80
5.3 ANÁLISE ESTATÍSTICA DA VELOCIDADE DO VENTO E DA POTÊNCIA.....	81
5.3.1 Velocidade do vento.....	81
5.3.2 Potência (período quente).....	82
5.3.3 Potência (período frio).....	83
5.4 ANÁLISE DE VARIABILIDADE DA VELOCIDADE DO VENTO E DA POTÊNCIA.....	84
5.4.1 Velocidade do vento.....	85
5.4.2 Potência.....	87
5.5 PREVISÃO DE VELOCIDADE DO VENTO.....	87
5.5.1 Resolução de 10 minutos.....	88
5.5.1.1 Análise de agrupamento de dados (Árvore de Agrupamento e Método k-Means).....	89
5.5.1.2 Análise estatística (Correlação Linear e Análise Fatorial).....	90
5.5.1.3 Resultados da previsão de velocidade do vento (resolução de 10 minutos).....	92
5.5.2 Resolução de 1 hora.....	98
5.5.3 Resolução de 3 horas.....	103
5.6 CLASSIFICADOR DE GERAÇÃO.....	115
5.6.1 Resolução de 10 minutos.....	115
5.6.2 Resolução de 1 hora.....	117
5.6.3 Resolução de 3 horas.....	119
5.7 PREVISÃO DE POTÊNCIA.....	120
5.7.1 Resolução de 10 minutos.....	121
5.7.2 Resolução de 1 hora.....	127
5.7.3 Resolução de 3 horas.....	133
5.8 ENERGIA GERADA.....	139
5.8.1 Resolução de 10 minutos.....	139
5.8.2 Resolução de 1 hora.....	140
5.8.3 Resolução de 3 horas.....	140
6 CONCLUSÕES E RECOMENDAÇÕES.....	142
REFERÊNCIAS.....	145
APÊNDICE A.....	153

PREVISÃO DE VELOCIDADE DO VENTO	153
CLASSIFICADOR DE GERAÇÃO.....	154
PREVISÃO DE POTÊNCIA.....	155
APÊNDICE B	157
ANEXO.....	162
TORRE.....	162
NACELE	162
PÁS	163
CAIXA DE ENGRENAGENS.....	164
ANEMÔMETRO E ANEMOSCÓPIO.....	164
FREIO	164
MECANISMOS DE CONTROLE	164
GERADOR	167
AEROGERADORES DE VELOCIDADE CONSTANTE E VARIÁVEL	167

1 INTRODUÇÃO

O setor de energia elétrica vem expandindo com a geração por fontes não poluentes e que tenham baixos riscos de desastres ambientais. Dentre as alternativas, a eólica possui a tecnologia consolidada e tem apresentado a maior taxa de crescimento (LARA *et al.*, 2009).

Mundialmente, sua capacidade instalada era de 7.600 MW ao final de 1997 e em 2015 era de 432.419 MW. Houve, portanto, um aumento superior a 55 vezes em menos de duas décadas. Os maiores números de aerogeradores instalados, ao término deste ano, estavam na China com 145.104 MW, EUA com 74.471 MW e Alemanha com 44.947 MW (GWEC, 2016).

No Brasil, a introdução desta tecnologia se deu pelo Programa de Incentivo às Fontes Alternativas de Energia Elétrica (PROINFA), lançado em 2004 e baseado em uma estrutura de financiamento e políticas regionais. Até o início de janeiro de 2016, o país detinha uma capacidade eólica instalada de 8.720 MW, representando 6,2% de sua matriz energética. No período, os empreendimentos em fase de construção totalizavam 3.144,8 MW e contratados, 6.933,3 MW (ABEEólica, 2016).

Dos quatorze leilões nos quais as fontes eólicas fizeram parte entre 2009 e 2015, contrataram-se mais de 14.000 MW em novos projetos e ao final de 2019, espera-se que o país atinja uma capacidade instalada de 17.776,9 MW (ABEEólica, 2015).

A maior parte dos novos empreendimentos eólicos no Brasil especifica aerogeradores com tecnologia de alto desempenho, com potência nominal de 3 MW e torres de 120 metros de altura. Dentre as principais causas para o recente desenvolvimento da indústria no país, tem-se: as características do vento nas extensas áreas favoráveis do território brasileiro e as condições dos leilões de mercado regulado e de financiamento (MELO, 2014).

Nos estudos de implantação desses empreendimentos, fica estabelecido que a geração eólica depende fundamentalmente da velocidade do vento incidente no aerogerador, que não pode ser controlada e apresenta grande variabilidade em função de fatores como relevo e altitude do terreno. Dessa forma, a previsão da geração eólica é de difícil determinação, embora seja imprescindível para o setor elétrico. O operador da rede elétrica, por exemplo, deve manter uma capacidade de

reserva no programa de despacho para que garanta equilíbrio entre carga e energia. A previsão, nesse contexto, serve para reduzir o custo de tal reserva. O operador do parque eólico, por outro lado, tem interesse nestas informações para gerir, de forma otimizada, as ações de operação e de manutenção do empreendimento.

Devido à diversidade de entidades integrantes do sistema elétrico, as previsões empregadas abrangem diferentes horizontes de tempo. Curtíssimo prazo (até nove horas à frente) está associado à participação no mercado intradiário (visa o equilíbrio entre a produção e a carga do sistema), controle dos aerogeradores e definição da garantia de abastecimento por parte do operador da rede elétrica. Curto prazo (até 72 horas à frente) é utilizado no mercado diário e no despacho dos serviços de sistema, por exemplo. Médio prazo (até sete dias à frente), empregado na manutenção dos sistemas elétricos e gestão de portfólio. Longo prazo, utilizado na estimativa do recurso eólico e na avaliação de viabilidade econômica das usinas (MONTEIRO *et al.*, 2009).

Para a previsão de velocidade do vento e de geração eólica de curtíssimo prazo, o modelo aplicado neste estudo é o de Redes Neurais Artificiais (RNA). São adotadas para a solução de problemas onde não existam regras lineares e o aprendizado se dá por meio de exemplos. O modelo de previsão de geração eólica com RNA foi desenvolvido para a Usina de Palmas, localizada ao sul do estado do Paraná. O empreendimento eólico, primeiro da região sul do Brasil, conta com cinco aerogeradores ENERCON modelo E-40 de 500 kW cada, sendo, atualmente, de controle total da Companhia Paranaense de Energia (COPEL). Os dados de energia, velocidade e direção do vento utilizados neste estudo foram fornecidos pela empresa estatal.

1.1 OBJETIVO GERAL

Desenvolver modelos de previsão de geração de curtíssimo prazo para a Usina Eólio-Elétrica de Palmas (PR), utilizando a técnica de Redes Neurais Artificiais (RNA).

1.2 ATIVIDADES

As atividades principais deste estudo são:

- 1) Obtenção dos dados de geração e de velocidade e direção do vento, disponibilizados pela COPEL;
- 2) Correção da velocidade do vento para a altura do eixo dos aerogeradores;
- 3) Análise estatística dos dados anemométricos e da geração elétrica;
- 4) Treinamento na implementação e na aplicação das Redes Neurais Artificiais;
- 5) Desenvolvimento de modelos classificadores de geração eólica;
- 6) Desenvolvimento de modelos previsores de vento e de geração eólica;
- 7) Validação dos modelos e avaliação de desempenho dos sistemas previsores.

1.3 JUSTIFICATIVA

O ano de 2015 foi de grande destaque para a energia eólica. A capacidade instalada mundial passou de 369.695 MW para 432.419 MW (GWEC, 2016). Com o interesse nessa tecnologia, torna-se imprescindível prever a energia gerada por um determinado empreendimento eólico para que o opere de forma otimizada. Dentre os métodos existentes, as Redes Neurais Artificiais são adequadas para as previsões de curtíssimo prazo (até 9 horas à frente) e apresentam como principais vantagens: o pouco conhecimento necessário da dinâmica atmosférica e a capacidade de aprendizado através de exemplos.

1.4 ORGANIZAÇÃO

Esse trabalho está organizado em seis capítulos, incluindo esta introdução. No Capítulo 2, apresenta-se a fundamentação teórica sobre temas importantes referentes a esta área de pesquisa. O Capítulo 3 descreve a área de estudo e os dados utilizados para a realização do trabalho. O Capítulo 4 apresenta os programas utilizados nesta dissertação e os conceitos teóricos envolvendo as Redes Neurais Artificiais. O Capítulo 5 exhibe os resultados obtidos, fazendo as devidas discussões. No Capítulo 6, são expostas as conclusões deste estudo e as recomendações para futuros trabalhos. Ao final estão incluídos o anexo e os apêndices e listadas as referências citadas.

2 FUNDAMENTAÇÃO TEÓRICA

A fundamentação teórica está dividida em nove partes: (1) princípios físicos e tecnologia dos aerogeradores, (2) controle de velocidade, (3) perfil da velocidade do vento na atmosfera, (4) importância e benefícios provenientes da previsão eólica, (5) tipos de modelos de previsão: estatísticos, físicos e híbridos, (6) técnicas em Mineração de Dados ou *Data Mining*, que visa à identificação de padrões de associação entre sequências de velocidades de vento passadas e futuras, (7) Redes Neurais Artificiais (RNA), método utilizado neste trabalho, e (8) avaliação de desempenho dos modelos de previsão numérica e (9) dos modelos classificadores.

2.1 PRINCÍPIOS FÍSICOS E TECNOLOGIA DOS AEROGERADORES

2.1.1 Princípios físicos

Os aerogeradores são equipamentos que transformam a energia cinética do fluxo de ar que atravessa as pás da turbina em torque no eixo do rotor. Com o gerador elétrico, tal torque é transformado em energia elétrica, passando a ser disponibilizada à rede em seus terminais de saída.

A energia cinética resultante da incidência do vento sobre as pás do aerogerador, que delimitam uma seção transversal circular com área A (ilustrada na Figura 1), é dada por:

$$E_c = \frac{1}{2}mV^2 \quad (1)$$

onde: E_c - energia cinética, em Joules; m - massa do ar, em kg; V - velocidade do vento, em m/s.




Figura 1 – Velocidade de vento V sobre uma área transversal A delimitada pelas pás do aerogerador

Fonte: adaptado de Gasch e Twele (2002)

E a potência correspondente é expressa por (REIS, 2003):

$$P = \frac{1}{2} \rho A V^3 \quad (2)$$

onde: P - potência, em Watt; ρ - massa específica do ar, em kg/m^3 ; A - área varrida pelas pás do rotor, em m^2 ; V - velocidade do vento, em m/s .

Portanto, a potência varia linearmente com a massa específica ρ do ar (que é dependente da pressão atmosférica, da temperatura e da umidade relativa) e com o cubo da velocidade do vento. Na prática, porém, a potência proporcionada pelo vento não é inteiramente aproveitada pela turbina. Uma parte destinar-se-á ao vento residual no volume de controle posterior ao equipamento (CUSTÓDIO, 2009). A Figura 2 ilustra o fluxo de ar através da turbina eólica de eixo horizontal, sendo a velocidade de vento V_1 anterior às pás e a velocidade V_3 posterior às pás.




Figura 2 – Redução da velocidade do vento após a passagem pelo aerogerador
 Fonte: adaptado de Gasch e Twele (2002)

Conforme a lei da conservação de massa, tem-se:

$$\rho V_1 A_1 = \rho V_3 A_3 \quad (3)$$

onde: ρ - massa específica do ar, em kg/m^3 ; V_1 - velocidade do vento na entrada do rotor, em m/s; V_3 - velocidade do vento na saída do rotor, em m/s; A_1 - área da seção transversal na entrada do rotor, em m^2 ; A_3 - área da seção transversal na saída do rotor, em m^2 .

A potência do aerogerador é equivalente à diferença entre a potência do vento anterior e posterior à passagem pelas pás (CUSTÓDIO, 2009):

$$P_t = P_1 - P_3 \quad (4)$$

onde: P_t - potência extraída do vento pela turbina eólica, em Watt; P_1 - potência disponível na entrada do rotor eólico, em Watt; P_3 - potência disponível na saída do rotor eólico, em Watt.

A velocidade do vento não é constante no plano das lâminas e no sentido macroscópico. O fluxo de massa de ar através das lâminas é expresso em função da velocidade média entre V_1 e V_3 (PATEL, 1999), portanto:

$$\text{fluxo de massa} = \rho A \frac{V_1 + V_3}{2} \quad (5)$$

Desta forma, a potência extraída pelo aerogerador é equivalente a:

$$P_t = \frac{1}{2} \left[\rho A \frac{(V_1 + V_3)}{2} \right] \cdot (V_1^2 - V_3^2) \quad (6)$$

Rearranjado (6), obtém-se:

$$P_t = \frac{1}{2} \rho A V_1^3 \frac{\left(1 + \frac{V_3}{V_1}\right) \left[1 - \left(\frac{V_3}{V_1}\right)^2\right]}{2} \quad (7)$$

Visto que a turbina eólica não converte integralmente a potência disponibilizada pelo vento, é definido o coeficiente de eficiência do rotor, C_p . Indica-se, desta forma, a fração da potência do vento incidente que realmente é aproveitada pelo aerogerador (LARA *et al.*, 2009):

$$P_t = \frac{1}{2} \rho A V_1^3 C_p \quad (8)$$

onde:

$$C_p = \frac{\left(1 + \frac{V_3}{V_1}\right) \left[1 - \left(\frac{V_3}{V_1}\right)^2\right]}{2} \quad (9)$$

De acordo com (8), caso a pá dobre de comprimento e as demais variáveis permaneçam constantes, a potência aumenta em quatro vezes, uma vez que a área A é diretamente proporcional ao quadrado do raio (o comprimento da pá, nesta situação). Enquanto, se a velocidade do vento duplicar, a potência aumenta em oito vezes (TONG, 2010).

É imprescindível, portanto, que haja um estudo sobre as séries de vento no local de interesse, pois suas variações são fator preponderante para avaliar a energia que poderá ser gerada pela usina e que definirá o sucesso econômico do empreendimento eólico.

Patel (1999) destaca que para uma dada velocidade incidente, C_p é função da razão das velocidades posterior e anterior ao equipamento (V_3/V_1). Na construção do gráfico de C_p versus (V_3/V_1), verifica-se que o valor máximo do coeficiente de eficiência do rotor é de 0,59 (definido como limite de Betz), quando (V_3/V_1) equivale a 1/3, conforme ilustrado na Figura 3.

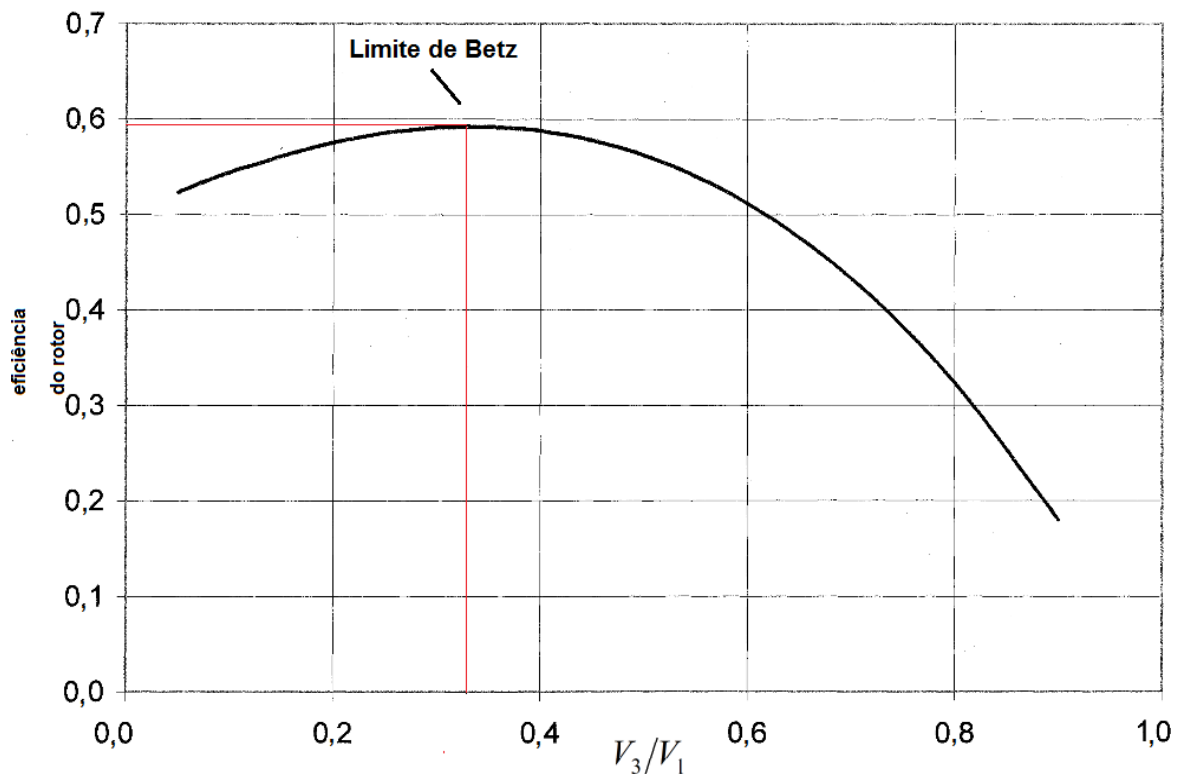


Figura 3 – Distribuição do coeficiente C_p em função de V_3/V_1

Fonte: adaptado de Patel (1999)

A potência máxima produzida pelo aerogerador é, portanto:

$$P_{\max} = (0,59) \frac{1}{2} \rho A V_1^3 \quad (10)$$

Esta expressão descreve a potência do aerogerador em condições ideais, resultante de duas reduções distintas. A primeira, de 1/3, do fluxo que passa através da turbina, relacionada ao alargamento do tubo de corrente de ar e a segunda, de 1/9, referente a uma incompleta absorção de energia, ocorrendo, desta forma, uma

velocidade no interior da turbina diferente de 0 m/s (USDOE, 1996).

Na prática, porém, o valor máximo de C_p encontra-se usualmente entre 0,25 e 0,45 (LARA *et al.*, 2009), dependendo de fatores como a aerodinâmica das pás, a forma de controle da turbina e as velocidades instantâneas de rotação (STIEBLER, 2008). Para cada turbina e velocidade, há um C_p distinto.

2.1.2 Tecnologia

Há dois tipos de aerogeradores: os de eixo vertical e os de eixo horizontal. Os aerogeradores com rotor de eixo vertical, que desempenham um papel secundário e podem ser movidos por forças de arrasto e de sustentação, não necessitam de mecanismos direcionais, uma vez que estão sempre voltados ao vento. Isto torna a concepção de projeto mais simples. Os rotores de *Darrieus*, compostos por lâminas de perfil aerodinâmico ligadas à haste nas suas extremidades, são os aerogeradores de eixo vertical mais comuns (DUTRA, 2001).

Os aerogeradores de eixo horizontal são predominantes e possuem estruturas e mecanismos que possibilitam que a área varrida pelas pás esteja sempre perpendicular ao vento incidente, maximizando a *performance* dos equipamentos. A posição do rotor em relação à torre pode estar à montante, necessitando de mecanismos de orientação conforme o fluxo de vento, e estar à jusante, situação que a orientação ocorre automaticamente (DUTRA, 2001).

A Figura 4 e a Figura 5 apresentam exemplos de aerogeradores de eixo vertical (*Darrieus*, no caso) e horizontal, respectivamente.



Figura 4 – Exemplo de aerogerador de eixo vertical (*Darrieus*)
Fonte: UGP Wind Energy (2015)



Figura 5 – Exemplo de aerogerador de eixo horizontal
Fonte: Luci Coccia (2015)

Os aerogeradores são compostos por:

- Torre;
- Turbina acoplada às pás;
- Mecanismo de guinada;
- Caixa de engrenagens;
- Gerador elétrico;
- Sensores de velocidade e de controle.

E a Figura 6 ilustra esquematicamente um aerogerador com seus componentes principais.




Figura 6 – Componentes de um aerogerador de eixo horizontal
Fonte: CBEE/UFPE (2000)

2.2 CONTROLE DE VELOCIDADE

A velocidade do rotor deve ser controlada pelos seguintes motivos (PATEL, 1999):

- Geração de mais energia;
- Proteção ao aerogerador (considerando seus equipamentos e dispositivos), evitando que sobrecarreguem sob ventos fortes;
- Em casos que o gerador se desconecta acidentalmente ou em situações programadas, como de manutenção.

O funcionamento do rotor apresenta cinco regiões distintas de funcionamento, como ilustrado na Figura 7, referente à curva de potência:

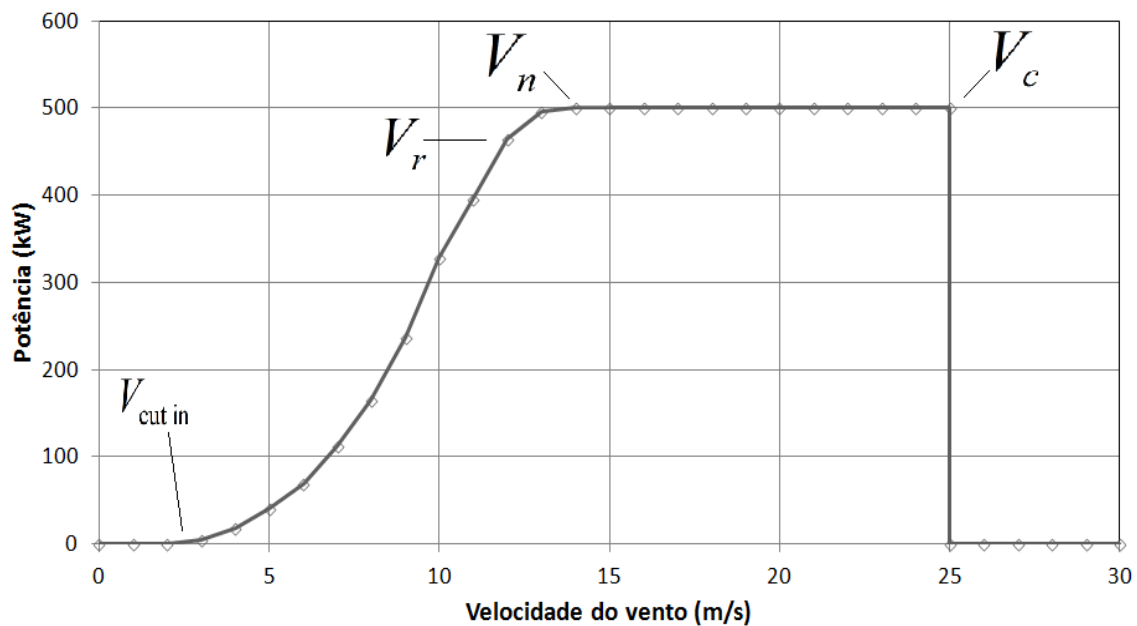


Figura 7 – Curva de potência do aerogerador ENERCON E-40

- 1) $0 \leq V < V_{\text{cut in}}$, onde $V_{\text{cut in}}$ é a velocidade do vento mínima para que a turbina comece a gerar energia;
- 2) $V_{\text{cut in}} \leq V < V_r$: região que a velocidade do rotor altera com a variação da velocidade do vento incidente;

- 3) $V_r \leq V < V_n$: sob fortes ventos, a velocidade do rotor é limitada a um valor máximo constante, baseado nas características do sistema. Neste caso, C_p é inferior ao C_p máximo e a potência aumenta em uma taxa menor que a observada na região anterior;
- 4) $V_n \leq V < V_c$: em casos de ventos extremos, o equipamento opera com uma potência constante, reduzindo a velocidade do rotor para proteger o gerador e os componentes eletrônicos de uma sobrecarga;
- 5) $V_c \leq V$: para velocidade de vento incidente além da determinada, o rotor interrompe a produção de energia, protegendo os componentes do sistema.

2.3 PERFIL DA VELOCIDADE DO VENTO

A variação da velocidade do vento com a distância em relação ao solo pode ser expressa pela seguinte equação para locais atendendo aos requisitos de rugosidade uniforme (ROHATGI; NELSON, 1994; LYSEN, 1982; GIPE, 1993):

$$\frac{V(z)}{V(h)} = \frac{\ln\left(\frac{z}{z_0}\right)}{\ln\left(\frac{h}{z_0}\right)} \quad (11)$$

onde: $V(z)$ - velocidade de referência (conhecida), em m/s; $V(h)$ - velocidade do vento na altura h , em m/s; z - altura de referência, em m; h - altura para a qual se quer determinar a velocidade $V(h)$, em m; z_0 - “altura de rugosidade”, em função do tipo de ocupação do solo, em m.

Para a obtenção de valores típicos da altura de rugosidade z_0 para diferentes tipos de terreno, pode-se citar o trabalho desenvolvido por Silva (2004), conforme Tabela 1.

Tabela 1 – Altura de rugosidade em função do tipo de solo

Tipo de terreno	z_0 (m)
Gelo ou lama plana	10^{-5} a $3 \cdot 10^{-5}$
Mar calmo	$2 \cdot 10^{-4}$ a $3 \cdot 10^{-4}$
Areia	$2 \cdot 10^{-4}$ a 10^{-3}
Neve	10^{-3} a $6 \cdot 10^{-3}$
Gramma baixa	10^{-3} a 10^{-2}
Estepe	10^{-2} a $4 \cdot 10^{-2}$
Gramma alta	$4 \cdot 10^{-2}$ a $4 \cdot 10^{-1}$
Floresta	10^{-1} a 1
Subúrbio	1 a 2
Cidade	1 a 4

Fonte: Silva (2004)

Destaca-se adicionalmente, o modelo de rugosidade adotado no Atlas Eólico Brasileiro, Figura 8, resultado da conversão dos dados de Índice de Vegetação por Diferença Normalizada (IVDN) e do uso do solo pelo *software MesoMap*. Estes dados foram produzidos pela *US Geological Survey*, Universidade de Nebraska, e pela *Joint Research Centre (JRC)*, Comissão Europeia.



Figura 8 – Modelo de rugosidade
Fonte: Amarante *et al.* (2001)

2.4 IMPORTÂNCIA E BENEFÍCIOS DA PREVISÃO DA GERAÇÃO EÓLICA

Devido à crescente integração das usinas eólicas à rede elétrica e à variabilidade que o vento apresenta, torna-se imprescindível a realização da previsão eólica para os diferentes participantes do setor energético, tendo cada qual seu horizonte de interesse.

A acurácia dos modelos tem melhorado à medida que a capacidade eólica e os conhecimentos adquiridos na área aumentam (PARKES *et al.*, 2006). Destaca-se que a raiz do erro médio quadrático da previsão realizada para um dia à frente caiu à metade entre os anos de 2001 e 2006 (MACKENSEN; LANGE; SCHLOGL, 2006). Os principais avanços estão no aprimoramento dos modelos utilizados (estatísticos e físicos, por exemplo), no aumento da capacidade dos computadores e na melhor qualidade dos dados disponíveis (velocidade do vento, principalmente).

Ressalta-se, porém, que o benefício econômico de sua implantação depende fortemente dessa acurácia e do seu custo. Conforme modelo que avaliou as vantagens obtidas com a previsão da geração eólica no mercado de eletricidade, o máximo ganho obtido era de £ 4,50 por MWh no Reino Unido, valor que representava aproximadamente 12,6% do valor da eletricidade praticado no ano do estudo, 2003. Para empreendimentos de até 30 MW, caso a diferença entre as médias dos ventos previstos e medidos seja superior a $\pm 10\%$ da média dos dados reais, o ônus de antever incorretamente a geração passa a ser mais expressivo que os eventuais benefícios obtidos. Para empreendimentos de 30 a 100 MW, os custos anuais do modelo devem ser de até £ 100.000 para que seja vantajoso. Por fim, para usinas cujas potências instaladas são superiores a 100 MW, a previsão é reconhecidamente favorável (BARTHELMIE; MURRAY; PRYOR, 2008).

Entre os integrantes do sistema elétrico interessados na previsão eólica, estão (BARTHELMIE; MURRAY; PRYOR, 2008):

- Operador da usina eólica: utiliza a previsão de curtíssimo e curto prazo na gestão operacional do parque, agendando, por exemplo, a manutenção das turbinas em períodos de baixa velocidade do vento. Ressalta-se a necessidade da previsão enquanto participante do

mercado de eletricidade. Como exemplo, há o mercado intradiário, que permite o equilíbrio entre a produção e a carga;

- Operador do sistema de transmissão: responsável pela capacidade de fornecimento de energia em longo prazo e pelo gerenciamento, por meio de compra e venda, do fluxo de energia em tempo real. Cobra de todos os usuários, os custos do funcionamento balanceado do sistema;
- Operador do sistema de distribuição: as previsões de energia de curto prazo assistem na gestão da rede. É de grande importância para os operadores que utilizam redes de baixa tensão, por não serem capazes de acomodar mudanças bruscas, conhecidas por rampa e características das usinas eólicas, (TANDE, 2003).

2.5 TIPOS DOS MODELOS DE PREVISÃO DA GERAÇÃO EÓLICA

2.5.1 Modelos estatísticos

Os modelos estatísticos, utilizados especialmente para a previsão de curtíssimo prazo (WANG; GUO; HUANG, 2011), baseiam-se nos dados históricos das variáveis a serem previstas (registrados geralmente pelo sistema de controle e monitoramento da usina eólica conhecido por *Supervisory Control and Data Acquisition*, SCADA), não considerando as informações específicas dos locais onde se encontram os empreendimentos, como na Figura 9. Vale destacar, porém, que em modelos multivariados, dados como direção do vento incidente e temperatura podem ser utilizados para melhorar os resultados obtidos.

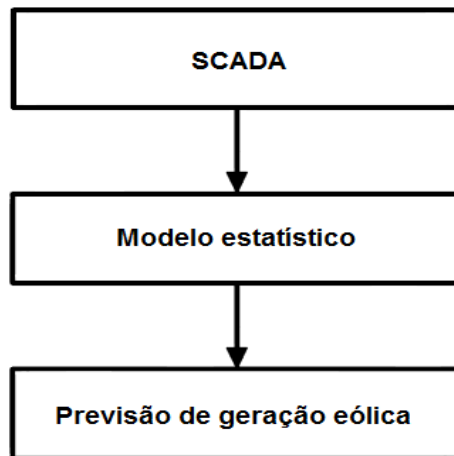


Figura 9 – Etapas dos modelos estatísticos
Fonte: adaptado de Monteiro *et al.* (2009)

Há uma grande variedade de métodos estatísticos, tais como: Modelo Autorregressivo Integrado de Média Móvel (ARIMA), Modelo Autorregressivo de Média Móvel (ARMA), Filtro de Kalman e Regressão Harmônica, assim como métodos envolvendo inteligência computacional, como as Redes Neurais Artificiais.

As grandes vantagens dos métodos estatísticos são sua implementação simples, necessitando de modestos recursos computacionais, e sua agilidade na realização e na atualização das previsões.

Por basearem-se somente em dados passados, geram resultados mais aderentes à realidade que a Persistência (considerada como referência) para horizontes de até seis horas à frente (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1997). Esta técnica consiste em assumir que as condições que influenciam a previsão não mudarão em um instante t , fazendo com que, por exemplo, a velocidade nesse instante t seja igual à atual (SIEBERT, 2008).

Desta forma, os modelos estatísticos têm sido recomendados para as previsões de curtíssimo e curto prazo. E para estes períodos, a melhora nos resultados obtidos, quando comparados à Persistência, encontra-se entre 15% e 20% (GIEBEL; KARINIOTAKIS; BROWNSWORD, 2003).

Dentre os métodos, Filtro de Kalman foi o primeiro voltado à previsão de geração eólica (BOSSANYI, 1985), sendo importante no controle dos aerogeradores que operam com velocidade variável (VIHRIALA *et al.*, 1999). O Modelo ARIMA, entretanto, é o primeiro a ser empregado para a previsão de velocidade do vento incidente (BOX; JENKINS, 1976).

Torres *et al.* (2005) utilizaram em suas pesquisas, cinco Modelos ARMA na previsão da velocidade horária do vento para um horizonte de dez horas para localidades que apresentassem diferentes características topográficas. Conseguiram reduzir o erro em 20%, se comparado ao da Persistência. Schwartz e Milligan (2002), entretanto, concluem que o desempenho de tais modelos é altamente dependente do período de treinamento aplicado.

Voltados à inteligência artificial, Alexiadis, Dokopoulos e Sahsamanoglou (1999) propuseram um método baseado em Redes Neurais Artificiais para a previsão de velocidade de vento na Ilha Syros (Grécia), utilizando dados históricos de sua localidade e de ilhas ao redor. Obtiveram uma melhora de 32%, em relação à Persistência, para um horizonte de uma hora. Por fim, o trabalho de Sfetsos (2000), ao comparar os valores gerados pelo Modelo ARIMA, Sistema Neuro-*Fuzzy* e RNA, concluiu que estas produziam os resultados mais significativos ao obter uma melhora entre 20% e 40%, se comparados aos do modelo de referência.

2.5.2 Modelos físicos

Atualmente, uma variedade de métodos voltados à previsão de geração eólica necessita de dados da previsão do tempo ao envolver maiores horizontes de tempo (entre 6 e 72 horas à frente).

Conforme apresentada na Figura 10, a abordagem física foca na descrição do vento ao redor e sob as usinas eólicas e considera, no refinamento da Previsão Numérica de Tempo (NWP), as características dos empreendimentos e dos seus locais de implantação, como orografia do terreno, altura das turbinas, rugosidade e obstáculos.

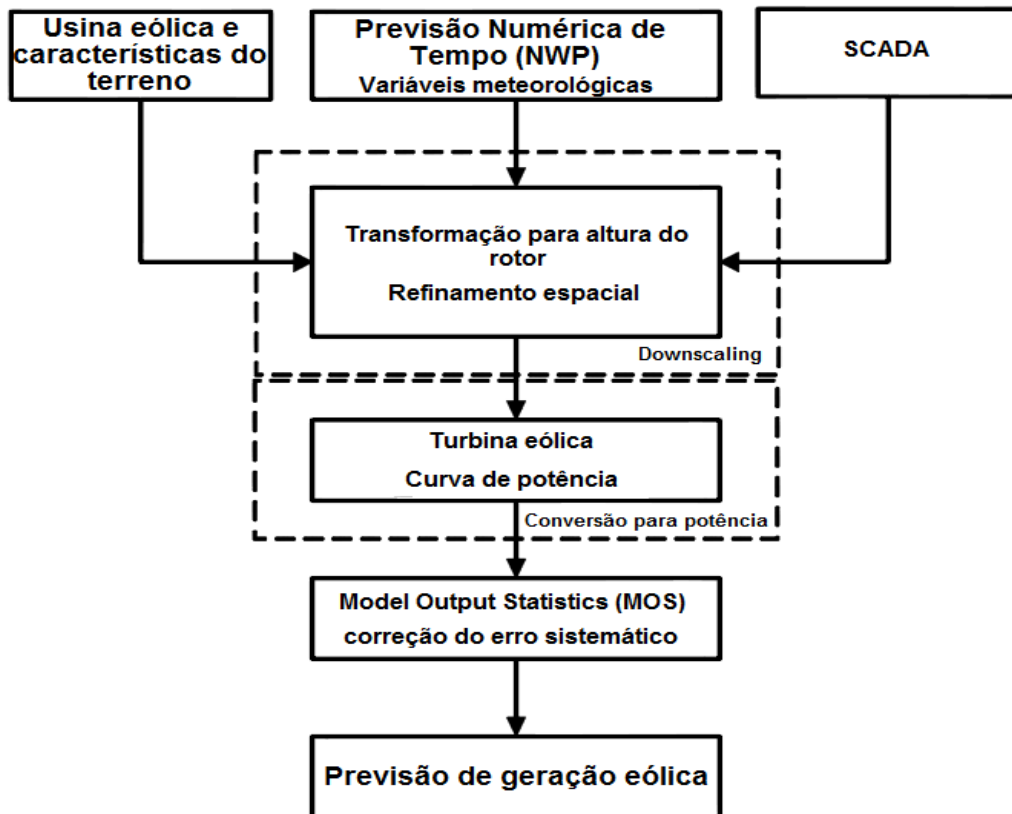


Figura 10 – Etapas dos modelos físicos
Fonte: adaptado de Monteiro *et al.* (2009)

Para a determinação da energia gerada, utiliza a curva de potência disponibilizada pelo fabricante dos aerogeradores, mesmo que estudos recentes apontem desvantagens em empregá-la (CABEZON *et al.*, 2004). Vale destacar, neste caso, que os equipamentos são testados/homologados normalmente na Europa, com massa específica do ar superior à observada no Brasil. No ano de 2008, por exemplo, a densidade média em Palmas (PR) foi de $1,07 \text{ kg/m}^3$ (SOARES; HIRUMA; GUETTER, 2014), enquanto que a *International Electrotechnical Commission* – IEC (2005), órgão responsável por preparar e publicar as Normas Internacionais para todas as tecnologias elétricas e eletrônicas, cita, em seu relatório, um valor de $1,225 \text{ kg/m}^3$ para as curvas desenvolvidas.

Os resultados da NWP são fornecidos por um modelo global para vários nós da rede cobrindo uma área. Para a obtenção de variáveis meteorológicas mais detalhadas na região da usina eólica, torna-se necessária uma extrapolação. A metodologia desenvolvida por Lange e Focken (2005) consiste em aninhar vários submodelos para transformar a previsão do vento médio na grade de dezenas de quilômetros em uma previsão de vento na escala de um quilômetro, para posterior

conversão da velocidade na altura do rotor em previsão da geração. Salienta-se que os modelos da Previsão Numérica de Tempo preveem ventos com horizontes variando entre 3 e 72 horas (BESSA, 2008).

Enfim, com o objetivo de corrigir os erros sistemáticos e melhorar os resultados de geração eólica, incorpora-se o *Model Output Statistics* (MOS) na etapa de pós-processamento. Este adapta as saídas dos modelos físicos com as medições realizadas em tempo real no local de estudo.

2.5.3 Modelos híbridos

Trabalhos recentes em previsão de geração eólica utilizam um método combinado das abordagens matemáticas e físicas (COSTA *et al.*, 2008). Obtêm, dessa forma, as vantagens de ambas: a elevada precisão das séries temporais nas previsões de curtíssimos e curtos horizontes de tempo e a elevada precisão dos modelos físicos para horizontes temporais que variam entre 6 e 72 horas. Nestes casos, avalia-se individualmente aquele que melhor se adapta a cada período estudado.

Vale destacar que qualquer modelo de previsão eólica somente gerará resultados satisfatórios caso os erros sejam inferiores àqueles obtidos por métodos de referência, como Persistência. Quanto maior o horizonte do tempo, o erro que relaciona os resultados previstos com a sua incerteza aumenta.

2.6 TÉCNICAS EM MINERAÇÃO DE DADOS (*DATA MINING*)

Através do aprimoramento dos computadores e dos dispositivos digitais, tornou-se possível o armazenamento de uma grande quantidade de dados e o estudo de fenômenos físicos mais complexos. É importante, entretanto, utilizar um conjunto de ferramentas e técnicas capazes de revelar padrões consistentes e assessorar na descoberta de conhecimento, devido à inviabilidade de análise por métodos tradicionais, como as planilhas de cálculo.

A Mineração de Dados (*Data Mining*) é empregada neste sentido e envolve atividades de diversas áreas, por exemplo: aprendizado de máquina, técnicas de visualização de dados, matemática e estatística.

A seguir, são apresentadas as técnicas estatísticas (Correlação Linear e Análise Fatorial) e de agrupamento de dados (Árvore de Agrupamento e Método *k-Means*). Destaca-se a importância de uma visão integrada dos métodos para que se resolva um determinado problema.

2.6.1 Correlação Linear

Os coeficientes de Correlação Linear, extraídos da matriz de correlação, indicam a relação linear existente entre variáveis (analisadas sempre em pares), sendo expressos pela seguinte equação para X e Y , por exemplo:

$$r = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}} \quad (12)$$

Os valores não dependem das unidades de medida, sendo adimensionais e estão sempre contidos entre -1 e +1. Estes indicam uma associação linear perfeita negativa e positiva, respectivamente. Não se pode afirmar, entretanto, que se estes dados forem elevados, existe uma relação de causa-efeito. Como, caso o coeficiente de correlação seja equivalente a zero, não implica, necessariamente, em ausência de relação entre as variáveis. Pode-se ter, por exemplo, dependência funcional não linear (NAGHETTINI; PINTO, 2007).

2.6.2 Árvore de Agrupamento (Árvore Hierárquica)

Neste caso e no Método *k-Means*, as variáveis são organizadas em classes para que as dispostas em um mesmo grupo (*cluster*) possuam maior similaridade

em comparação às demais (HAN; KAMBER, 2001).

A Árvore de Agrupamento forma as classes com base no cálculo das distâncias. Tendo-se, por exemplo, duas variáveis com seus respectivos valores históricos: $X = (X_1, X_2, \dots, X_n)$ e $Y = (Y_1, Y_2, \dots, Y_n)$. A distância Euclidiana é calculada, por exemplo, através de:

$$d(X, Y) = \sqrt{(X_1 - Y_1)^2 + (X_2 - Y_2)^2 + \dots + (X_n - Y_n)^2} \quad (13)$$

Dentre trabalhos, Souza, Koerner e Chlad (2015) utilizaram técnicas em Mineração de Dados para determinar quais variáveis são mais determinantes para elucidar os padrões de incêndios florestais no Parque Nacional Chapada das Mesas (MA). Obtiveram o dendograma apresentado na Figura 11, baseado no cálculo das distâncias Euclidianas, que destaca sua grande relação com as velocidades dos ventos ocorridos no local (m/s), seguido por incidência solar (horas/dia) e chuva (milímetros acumulados nas últimas 72 horas).

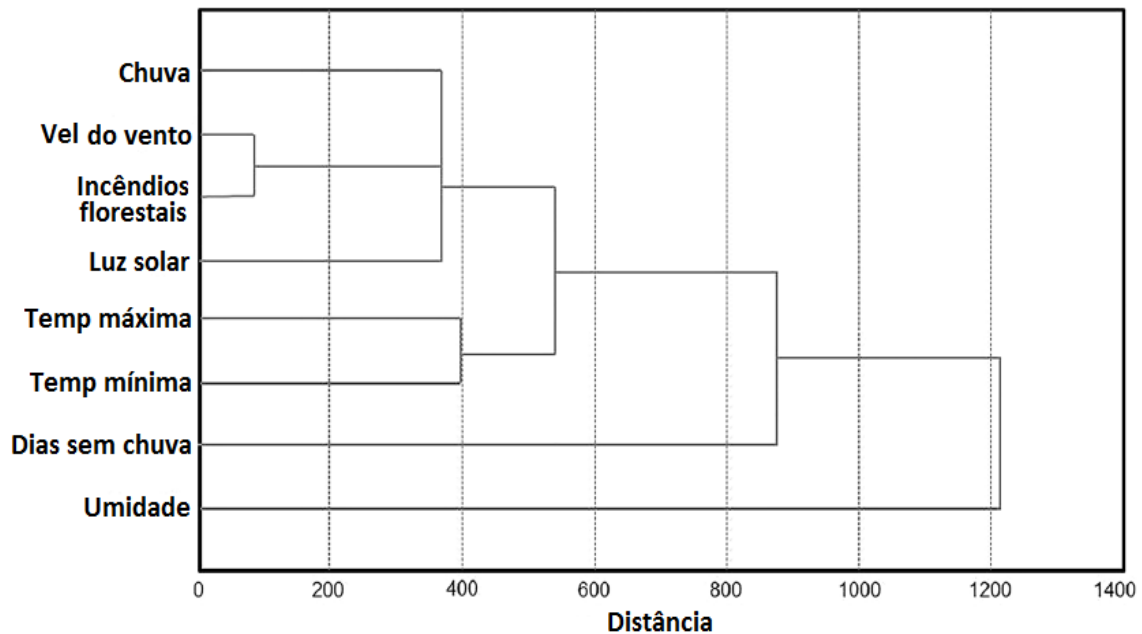


Figura 11 – Árvore de Agrupamento no estudo sobre incêndios florestais
Fonte: adaptado de Souza, Koerner e Chlad (2015)

2.6.3 Método *k*-Means

k-Means é uma técnica iterativa de agrupamento de dados (*clustering*) em que as variáveis estudadas são divididas em *k* conjuntos definidos pelo usuário, contrário ao ocorrido na Árvore Hierárquica (HAN; KAMBER, 2001).

Os centros dessas classes são escolhidos aleatoriamente, como em *b* da Figura 12, e os objetos passam a integrá-las de forma que sua distância seja mínima. Posteriormente são rearranjados pela média dos objetos que os constituíram na etapa anterior, sendo, em seguida, os dados reclassificados. Este processo se estende até que não haja mais mudanças (momento *h* da ilustração a seguir).

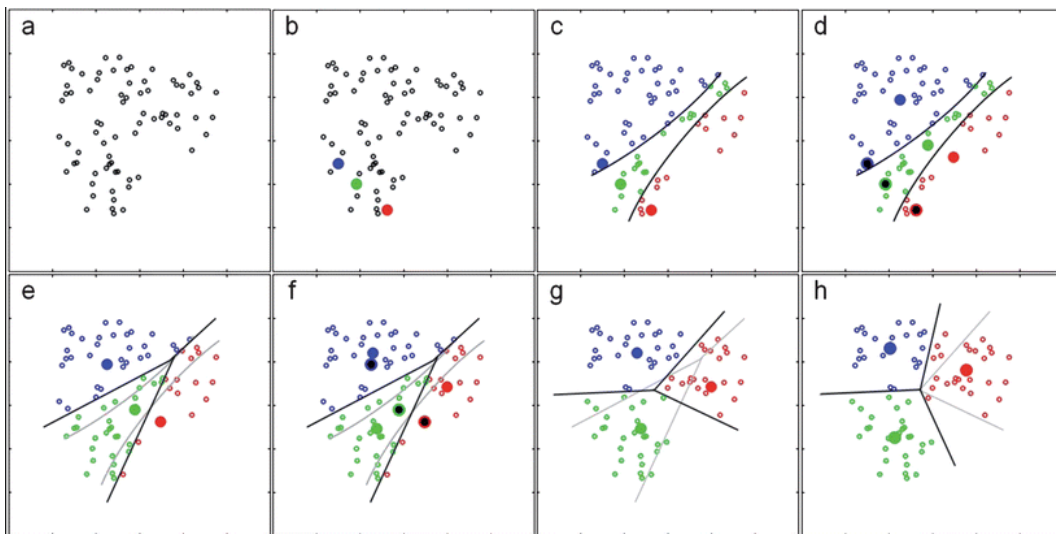


Figura 12 – Etapas para classificação conforme o Método *k*-Means
Fonte: Konicek, Lefman e Szakai (2012)

2.6.4 Análise Fatorial (AF)

A Análise Fatorial possibilita resumir as informações contidas em um grande número de variáveis observadas em um valor reduzido de variáveis latentes ou fatores, com perda mínima de informação.

Conforme Hair *et al.* (1998), os seguintes passos devem ser seguidos para a

sua realização: concepção do problema, obtenção da matriz de correlação, definição do método de Análise Fatorial, indicação do número de fatores, rotação e interpretação dos fatores e cálculo das cargas fatoriais.

Tendo-se a matriz de correlação das variáveis originais (deve possuir um número considerável de valores superiores a 0,30, em módulo), algumas técnicas são sugeridas para a obtenção dos fatores. O Método dos Componentes Principais é um dos mais recomendados e considerado apropriado quando o foco é a previsão. Neste caso, os autovalores da matriz de correlação são considerados na criação das variáveis latentes.

Dentre os critérios para determinar o número de fatores considerados, podem-se citar:

- Critério da raiz latente: somente os fatores com autovalores superiores a 1 são significativos, sendo os demais descartados;
- Critério *a priori*: sabem-se antes da realização da análise, quantos fatores devem ser extraídos;
- Critério de porcentagem da variância: mantém os fatores que representem uma porcentagem da variância total já predeterminado.

A capacidade de rotação é uma grande vantagem da Análise Fatorial em relação a demais técnicas e nesse caso, cada um dos novos fatores passa a apresentar uma correlação mais forte com uma ou mais variáveis e mais fraca com as demais. Faz, portanto, os coeficientes aproximarem-se, na medida do possível, de 0 ou 1. Isto possibilita a obtenção de soluções mais simples e significativas e facilita a interpretação. As técnicas existentes, para tanto, são:

- Quartimax: realiza a rotação para que uma variável possua carga elevada com um fator e baixa com as demais;
- Varimax: minimiza o número de variáveis com alta carga sobre o fator, reforçando sua interpretação. É o mais utilizado;
- Equamax: considerada uma combinação de Quartimax e Varimax.

Como resultados, as cargas fatoriais equivalem à correlação de cada

variável com o fator, sendo significativas quando seus valores são maiores que 0,60 (HAIR *et al.*, 1998). Desta forma, cargas numericamente superiores tornam as variáveis representativas e responsáveis pela nomeação do fator em questão.

Complementarmente à Árvore Hierárquica, Souza, Koerner e Chlad (2015) utilizaram a Análise Fatorial em seus estudos. A Figura 13 apresenta o resultado obtido por esta técnica e, conforme os autores, reitera a variável de velocidade do vento como importante ao acontecimento de incêndios florestais. A AF destaca adicionalmente a relevância da temperatura máxima (°C) e da quantidade de dias sem chuva.

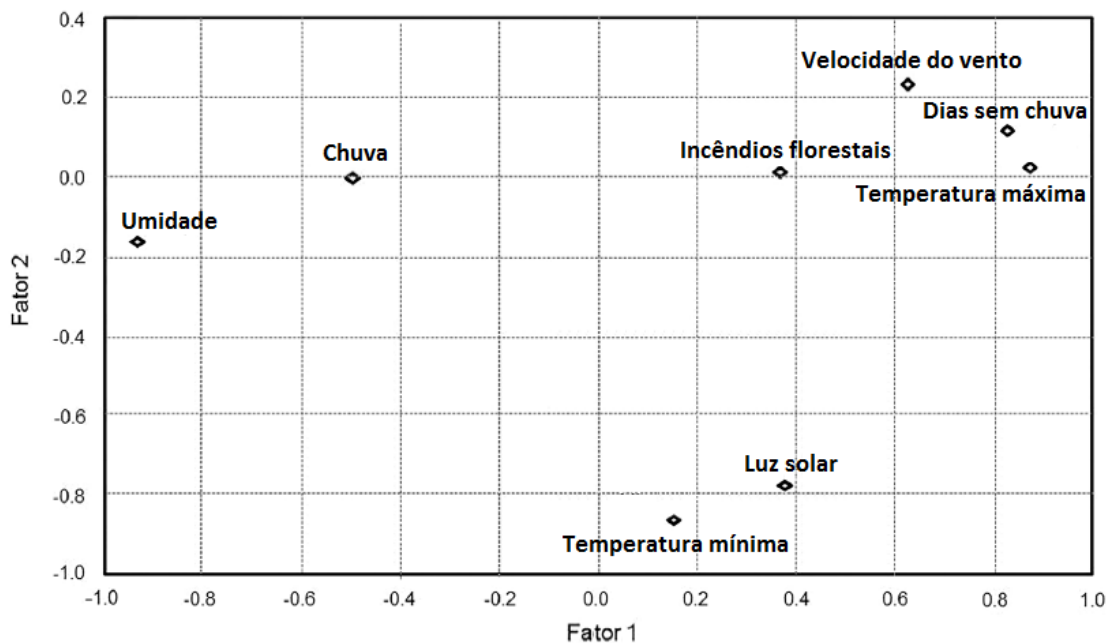


Figura 13 – Análise Fatorial no estudo sobre incêndios florestais
Fonte: adaptado de Souza, Koerner e Chlad (2015)

2.7 REDES NEURAIAS ARTIFICIAIS E APLICAÇÕES

As Redes Neurais Artificiais (RNA) simulam por técnicas de computação inteligente o funcionamento do cérebro humano, órgão que soluciona problemas em que não existam regras e que aprende através de exemplos. Tais redes são, dessa forma, capazes de manusear dados com ruídos e incompletos e proceder com problemas não lineares e complexos da vida real (MENDES; MARENGO, 2009).

Os sinais de entrada são captados e cada um encontra-se associado a seu respectivo peso. O neurônio é responsável por combiná-los e produzir uma saída linear, soma ponderada das entradas pelos respectivos pesos. Uma função de ativação é aplicada sobre esta saída, geralmente envolvendo comparações e transformações matemáticas, originando o valor de saída do neurônio.

Na prática, a rede aprende ajustando os pesos das conexões entre neurônios. Este peso é um fator que pondera o valor da entrada, em outras palavras, indica o grau de influência do valor de entrada para a obtenção da saída desejada. As regras de aprendizado podem ser classificadas em *supervisionada*, quando é fornecida uma referência do objetivo a ser alcançado, ou seja, são apresentados à rede pares entrada-saída, e *não supervisionada*, quando não é fornecida referência externa (CAM *et al.*, 2005).

O método para que a rede possa aprender através de exemplos é denominado algoritmo de aprendizado e envolve, basicamente, três fases: aquisição e processamento dos sinais de entrada para a determinação do sinal de saída, comparação da saída da rede com a resposta desejada através de uma função de desempenho e ajuste dos pesos das conexões (MOHANDÉS *et al.*, 2004). Este processo se repete até que algum critério de parada seja atingido.

Existem diversos algoritmos de treinamento para diferentes tipos de Redes Neurais Artificiais. O que os diferencia é o método para a minimização do erro e a forma como os pesos são ajustados.

Para a correta estruturação da RNA a ser utilizada em um determinado trabalho, torna-se necessário selecionar: o tipo de neurônio, o número de parâmetros de entrada, o número de camadas ocultas (intermediárias) e o tipo de treinamento. Um conjunto de parâmetros de entrada e de saída é necessário, sendo dividido para uso em etapas distintas, porém igualmente importantes: treinamento (atualização dos pesos sinápticos), teste (verificação da resposta da rede a dados não usados no treino) e validação das estimativas produzidas. A correta seleção dos dados de entrada é essencial para uma boa *performance* do modelo desenvolvido (MORI; UMEZAWA, 2009).

Um dos primeiros modelos propostos envolvendo RNA foi a *Perceptron*, formada por vários neurônios de entrada conectados através de pesos sinápticos a um neurônio de saída. O treinamento é realizado por conjuntos de exemplos com

entradas e saídas, desta forma diz-se que o aprendizado é supervisionado. Esta rede possui a habilidade de reconhecer padrões linearmente separáveis, porém destaca-se que muitos dos problemas práticos não são lineares. Posteriormente, foi desenvolvida a RNA *Adaline*, que possui a mesma estrutura da Rede *Perceptron*, porém com a possibilidade de utilizar uma função contínua para representar a saída do neurônio (WIDROW; LEHR, 1990).

Pode-se citar, também, *Self-Organising Map* proposto por Kohonen em 1982, Rede de Hopfield proposto por Hopfield em 1982 e *Counterpropagation* proposto por Hecht-Nielsen em 1986.

Entre trabalhos de previsão de geração eólica realizados por meio de RNA, Lobo (2010) utilizou Redes Neurais Artificiais recorrentes com múltiplas camadas dedicadas a horizontes diferentes de até 24 horas e Gama *et al.* (2012) utilizaram RNA de multicamadas para a previsão de até uma hora, para utilização no controle de uma usina eólica.

A precisão para curtíssimo horizonte de tempo (até nove horas à frente), o pouco conhecimento requerido da dinâmica das variáveis de tempo, a capacidade de aprendizado por meio de exemplos e a possibilidade de generalizar a resposta adquirida durante o treinamento da rede são as principais vantagens inerentes ao uso desta técnica. Em contrapartida, é imprescindível a existência de um banco de dados observados suficientemente grande e apresenta uma maior imprecisão para horizontes de tempo mais longos, se comparada aos modelos físicos.

2.8 AVALIAÇÃO DO DESEMPENHO DE PREVISÃO DA GERAÇÃO EÓLICA

Os resultados obtidos da previsão de geração eólica não são exatos e são caracterizados por uma incerteza associada. Torna-se imprescindível avaliá-los para determinar o desempenho do método utilizado e descobrir, com maior profundidade, os fatores que causam sua imprecisão. Como exemplos, podem-se citar a complexidade do terreno, a resolução espacial da NWP e a qualidade dos dados utilizados. Porém, mesmo que muitos parques eólicos atuais estejam equipados com um sistema capaz de operar e monitorar remotamente e em tempo real os equipamentos utilizados no empreendimento, *Supervisory Control and Data*

Acquisition (SCADA), pode haver períodos com valores indisponíveis ou com baixa qualidade (MONTEIRO *et al.*, 2009). O analista deve, portanto, possuir experiência suficiente para decidir como lidar com os dados dispostos, fazendo as devidas conclusões.

2.8.1 Nash-Sutcliffe (NS)

O coeficiente de Nash-Sutcliffe NS (NASH; SUTCLIFFE, 1970) é um teste que avalia o poder preditivo do modelo utilizado, neste caso as Redes Neurais Artificiais. Os resultados variam de $-\infty$ a 1. Um coeficiente de 1 representa uma combinação perfeita das previsões aos valores observados. Se NS for equivalente a 0, os resultados obtidos com as RNA são tão precisos quanto utilizar a média dos dados observados, e se o coeficiente for inferior a 0, esta média é considerada um melhor previsor que o modelo estudado.

$$NS = 1 - \frac{\sum_{t=1}^N (pred(t) - meas(t))^2}{\sum_{t=1}^N (meas(t) - meas)^2} \quad (14)$$

onde: N - tamanho da série de dados; $pred(t)$ - valor previsto no instante t ; $meas(t)$ - valor medido no instante t ; $meas$ - média dos valores medidos.

2.8.2 Coeficiente de determinação (R^2)

O coeficiente de determinação ($0 \leq R^2 \leq 1$) é uma medida descritiva da proporção da variabilidade de velocidade do vento ou de potência que é explicada pelo modelo de regressão (NAGHETTINI; PINTO, 2007). Calcula-se por:

$$R^2 = \left[\frac{\sum_{t=1}^N (meas(t) - meas)(pred(t) - pred)}{\sqrt{\sum_{t=1}^N (meas(t) - meas)^2 \sum_{t=1}^N (pred(t) - pred)^2}} \right]^2 \quad (15)$$

onde: N - tamanho da série de dados; $meas(t)$ - valor medido no instante t ; $meas$ - média dos valores medidos; $pred(t)$ - valor previsto no instante t ; $pred$ - média dos valores previstos.

2.8.3 Indicadores de erro

Determina-se o erro de previsão no instante i , e_i , como a diferença entre a velocidade prevista do vento v_{pred}^i , em m/s, e a velocidade medida do vento v_{meas}^i , em m/s:

$$e_i = v_{pred}^i - v_{meas}^i \quad (16)$$

Enquanto a raiz do erro médio quadrático, $RMSE$, é expressa por:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N e_i^2}{N}} \quad (17)$$

Para a determinação do erro de previsão realizada em um instante t para o momento $t+k$, utilizando os dados de potência, tem-se:

$$e_{t+k|t} = P_{t+k} - P_{t+k|t} \quad (18)$$

onde: $e_{t+k|t}$ - erro equivalente ao tempo $t+k$, para a previsão realizada no instante t ,

em kW; P_{t+k} - potência medida no instante $t+k$, em kW; $P_{t+k|t}$ - potência prevista para o momento $t+k$ no instante t , em kW.

É possível dividi-lo pela potência instalada da usina eólica em questão para compará-lo com qualquer empreendimento, independentemente de seu porte, portanto:

$$e_{t+k|t} = \frac{P_{t+k} - P_{t+k|t}}{P_{inst}} \quad (19)$$

onde: $e_{t+k|t}$ - erro equivalente ao tempo $t+k$, para a previsão realizada no instante t ; P_{inst} - potência instalada da usina eólica, em kW; P_{t+k} - potência medida no instante $t+k$, em kW; $P_{t+k|t}$ - potência prevista para o momento $t+k$ no instante t , em kW.

O erro de previsão pode ser decomposto em erro sistemático e aleatório. Em um modelo perfeito, o primeiro erro deveria ser equivalente a zero, enquanto que o segundo deveria ser uma sequência de erros aleatórios independentes que poderiam ser modelados por uma distribuição gaussiana de média zero. Porém, na prática, os erros de previsão são comumente correlacionados (MONTEIRO *et al.*, 2009).

Utilizando medidores específicos de erro, pode-se determinar a qualidade dos modelos de previsão. Dois destes medidores são erro médio absoluto (*MAE*):

$$MAE_k = \frac{1}{N} \sum_{t=1}^N |e_{t+k|t}| \quad (20)$$

onde: N - tamanho da série de dados; $e_{t+k|t}$ - erro correspondente ao tempo $t+k$, para a previsão realizada no instante t , em kW.

E raiz do erro médio quadrático (*RMSE*):

$$RMSE_k = \sqrt{\frac{\sum_{t=1}^N e_{t+k|t}^2}{N}} \quad (21)$$

onde: $e_{t+k|t}$ - erro equivalente ao tempo $t+k$, para a previsão realizada no instante t , em kW; N - tamanho da série de dados.

Pode-se dividir ambos pela capacidade instalada da usina eólica, resultando no erro médio absoluto normalizado ($NMAE$) e na raiz do erro médio quadrático normalizado ($NRMSE$).

Conforme Pinson (2006) e Siebert (2008), resultados característicos dos modelos válidos para dados até aquela data de previsão são: $NMAE$ entre 6% e 9% e $NRMSE$ entre 10% e 13% da capacidade instalada da usina eólica para um horizonte de até seis horas à frente, passando para 13% e 16% e 18% e 22%, respectivamente, para até 48 horas à frente.

Por fim, define-se o erro percentual absoluto médio ($MAPE$), expresso pelo quociente entre o erro absoluto e o valor observado de potência:

$$MAPE_k = \frac{100}{N} \sum_{t=1}^N \left| \frac{P_{t+k} - P_{t+k|t}}{P_{t+k}} \right| \quad (22)$$

onde: N - tamanho da série de dados; P_{t+k} - potência medida no instante $t+k$, em kW; $P_{t+k|t}$ - potência prevista para o momento $t+k$ no instante t , em kW.

2.8.4 Análise de desempenho dos métodos de previsão

Soares (2015) realizou previsões para a Usina Eólio-Elétrica de Palmas (PR) através do método *Box & Jenkins*. Desenvolveu, no estudo, três modelos preditivos baseados nas séries temporais fornecidas pela COPEL: de velocidade do vento e de potência, sendo este fundamentado, primeiramente, em seus valores passados e, posteriormente, nos dados previstos de vento, convertidos em potência com o auxílio da curva de potência dos aerogeradores instalados no empreendimento.

Foram utilizados neste trabalho, a linguagem *Python* e o *software* estatístico *R*, para a elaboração dos Modelos ARIMA

Entre as resoluções temporais estudadas, estão: 10 minutos, 1 hora e 3 horas.

A Tabela 2 e a Tabela 3 indicam os desempenhos dos modelos previsores de velocidade do vento para a resolução de 3 horas para os períodos quente (02/02/2011) e frio (12/07/2011).

Tabela 2 – Resultados das previsões de velocidade do vento para resolução de 3 horas (período quente)

Estatísticas	3 horas	6 horas	9 horas
Nash-Sutcliffe	0,55	0,34	0,26
Raiz do erro médio quadrático (m/s)	1,32	1,61	1,71
Erro médio absoluto (m/s)	1,02	1,30	1,37

Fonte: adaptado de Soares (2015)

Tabela 3 – Resultados das previsões de velocidade do vento para resolução de 3 horas (período frio)

Estatísticas	3 horas	6 horas	9 horas
Nash-Sutcliffe	0,54	0,34	0,25
Raiz do erro médio quadrático (m/s)	1,67	2,00	2,15
Erro médio absoluto (m/s)	1,28	1,60	1,68

Fonte: adaptado de Soares (2015)

E a Tabela 4 e a Tabela 5 indicam as *performances* dos modelos de previsão de potência baseados simplesmente em suas séries históricas.

Tabela 4 – Resultados das previsões de potência para resolução de 3 horas (período quente)

Estatísticas	3 horas	6 horas	9 horas
Nash-Sutcliffe	0,60	0,38	0,30
Raiz do erro médio quadrático (kW)	242,14	301,69	322,81
Erro médio absoluto (kW)	180,28	224,29	245,07

Fonte: adaptado de Soares (2015)

Tabela 5 – Resultados das previsões de potência para resolução de 3 horas (período frio)

Estatísticas	3 horas	6 horas	9 horas
Nash-Sutcliffe	0,55	0,33	0,29
Raiz do erro médio quadrático (kW)	385,56	473,23	492,41
Erro médio absoluto (kW)	289,11	366,35	371,26

Fonte: adaptado de Soares (2015)

Os resultados do trabalho indicaram uma piora de desempenho dos modelos à medida que se estende o horizonte de tempo e a resolução temporal das séries. Como exceção, tem-se a previsão de potência baseada nos dados históricos de

vento. Neste caso, houve melhores *performances* dos modelos de resolução de 1 hora e de 3 horas, se comparadas aos de 10 minutos. O autor, enfim, destaca que esta metodologia é adequada para previsões de até 6 horas à frente.

Em outro estudo, Stathopoulos *et al.* (2013) empregaram para três usinas eólicas localizadas nas ilhas de Creta e Kefalonia (Grécia), dois sistemas atmosféricos de alta resolução de previsão de vento: *Skiron* e *Regional Atmospheric Modeling System* (RAMS). Utilizaram Filtro de Kalman para estudar seus efeitos sobre os resultados finais. A Tabela 6 ilustra os índices estatísticos para as previsões de velocidade do vento obtidos no trabalho.

Tabela 6 – *RMSE*, R^2 , excesso de curtose e assimetria para os modelos NWP e os resultados do Filtro de Kalman

Velocidade do vento ("Tatrapolis", Kefalonia)					
	Skiron (116 m)	Kalman (1ª ordem)		Kalman (2ª ordem)	Observações
<i>RMSE</i> (m/s)	3,87	3,89		4,29	-
R^2	0,55	0,43		0,35	-
Excesso de curtose	0,12	0,21		0,21	1,29
Assimetria	0,71	0,65		0,65	1,08
Velocidade do vento ("Xirolimni", E. Creta)					
	RAMS (47 m)	Kalman (1ª ordem)	RAMS (154 m)	Kalman (2ª ordem)	Observações
<i>RMSE</i> (m/s)	4,20	3,87	3,89	3,63	-
R^2	0,28	0,19	0,52	0,48	-
Excesso de curtose	-0,86	-0,74	-0,80	-0,58	-0,36
Assimetria	0,09	0,12	0,07	-0,08	0,61
Velocidade do vento ("Vardia", W. Creta)					
	RAMS (47 m)	Kalman (1ª ordem)	RAMS (154 m)	Kalman (2ª ordem)	Observações
<i>RMSE</i> (m/s)	5,67	4,00	3,53	3,85	-
R^2	0,29	0,49	0,61	0,56	-
Excesso de curtose	-0,67	-0,12	0,78	0,66	0,28
Assimetria	0,62	0,74	0,79	0,90	0,98

Fonte: adaptado de Stathopoulos *et al.* (2013)

Stathopoulos *et al.* (2013) concluíram que ambos os modelos envolvendo NWP subestimaram a velocidade do vento e a aplicação do Filtro de Kalman aumentou significativamente o desempenho do modelo por meio da redução do ruído a aproximadamente zero. Em relação à curtose e à assimetria, a distribuição dos dados após a utilização do filtro se ajustou melhor aos dados de velocidade do vento observados. Por outro lado, não se verificou mudança significativa em relação

à *RMSE*. Os valores de R^2 indicaram que as previsões de velocidade do vento, antes e depois da aplicação de Kalman não apresentaram relação linear com os dados observados.

A Figura 14 apresenta um exemplo da aplicação do Filtro de Kalman para a usina de Tetrapolis, localizada a sudoeste da Grécia. Em *a*, a curva em azul representa a função densidade da distribuição de Weibull oriunda do sistema *Skiron* e em *b*, a curva em verde representa o resultado derivado da aplicação do filtro. Em ambos os casos, a representação em vermelho indica as observações. Percebe-se neste caso, a melhor correspondência das curvas em *b*.

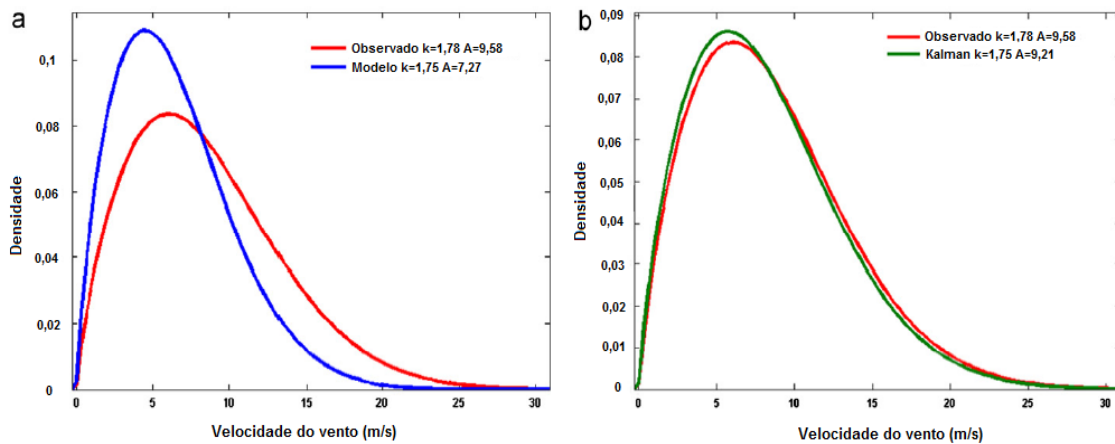


Figura 14 – Curvas da distribuição de Weibull
Fonte: adaptado de Stathopoulos *et al.* (2013)

Sfetsos (2000) comparou diversos métodos para a previsão da velocidade horária do vento. Utilizou os dados obtidos para a ilha grega de Creta e referentes ao mês de março de 1996, totalizando 744 horas. Além dos modelos lineares tradicionais e das Redes Neurais Recorrentes, foram examinadas: *Artificial Neuro-Fuzzy Inference System* (ANFIS) e Redes Neurais Lógicas. No estudo, foram avaliadas as suas capacidades de produzir previsões precisas e rápidas.

O trabalho concluiu que os modelos baseados em inteligência artificial superaram os lineares, enquanto que os modelos não lineares apresentaram um *RMSE* considerado semelhante. Destaca a Rede Neural Lógica incorporada das Regras Lógicas como o melhor método, com um *RMSE* 4,89% inferior ao método da Persistência e tempo de convergência de 141 segundos. A Tabela 7 resume os resultados dos modelos de previsão utilizados no estudo.

Tabela 7 – Resultados da previsão

Modelo	RMSE (m/s)	% melhora	Tempo de convergência (s)
Persistência	1,2587	-	-
AR(2)	1,2383	1,62	-
ARIMA 1	1,2303	2,25	-
ARIMA 2	1,2607	-0,15	-
linear NN	1,2162	3,37	79
BP NN	1,2111	3,78	532
LM NN	1,1999	4,67	5
RBF	1,2121	3,70	39
ELM	1,2250	2,67	331
ANFIS	1,2062	4,17	7
NLN	1,2048	4,28	22
NLN + LR	1,1971	4,89	141

Fonte: adaptado de Sfetsos (2000)

Em outro trabalho, Zhu *et al.* (2012) empregaram Lógica *Fuzzy* (Difusa) para a previsão de curto prazo de energia eólica. Dados de velocidade de vento, oriundos de uma usina eólica localizada na Mongólia, foram utilizados como entrada.

Primeiramente, um algoritmo de agrupamento *Fuzzy C-Means* (FCM) foi empregado para determinar o número ideal de regras *Fuzzy*. Em seguida, os parâmetros das funções de entrada e de saída foram automaticamente ajustados por um algoritmo *backpropagation*. A Tabela 8 ilustra os erros de previsão para os modelos de Lógica *Fuzzy*, de maior precisão, e Redes Neurais Artificiais.

Tabela 8 – Comparação dos erros de previsão

Período de previsão	Modelo <i>Fuzzy</i>		Modelo com RNA	
	RMSE (treinamento)	RMSE (teste)	RMSE (treinamento)	RMSE (teste)
0,5 hora	55,2834	78,2315	93,6025	99,4276
1 hora	55,7073	118,6786	135,0132	193,4415
2 horas	64,8351	136,9822	182,6726	234,4822

Fonte: adaptado de Zhu *et al.* (2012)

O modelo apresentou uma boa concordância com os dados reais e Zhu *et al.* (2012) concluíram que a Lógica *Fuzzy* pode ser utilizada para a previsão de energia eólica. Esta metodologia apresenta uma estrutura capaz de revelar uma descrição qualitativa útil do sistema de previsão. Ressalta-se que quanto mais parâmetros forem considerados, melhor será a previsão.

Por fim, no trabalho desenvolvido por Giorgi, Ficarella e Tarantino (2011), vários sistemas de previsão baseados em RNA foram desenvolvidos para prever a

energia gerada por um parque eólico localizado ao sul da Itália para diferentes horizontes de tempo: 1, 3, 6, 12 e 24 horas à frente.

No sistema I, uma rede de Elman foi utilizada apenas como um modelo estatístico baseado em séries temporais *on-line* de energia eólica medida para cada instante t . O valor de entrada é determinado pelo somatório das potências médias horárias ao longo do horizonte de previsão h .

Para avaliar a melhora de desempenho devido à NWP e indicar os parâmetros meteorológicos mais significativos, o segundo conjunto de previsão (II a VI) foi realizado. Revelou que além da importância da velocidade do vento, a pressão e a temperatura também influenciam na *performance* do modelo.

Os dois melhores sistemas (II e V) são baseados nos dados de potência e de velocidade do vento prevista (II) e nos dados de potência, velocidade do vento prevista, pressão e temperatura (V).

Na tentativa de obter um melhor desempenho, tais modelos, II e V, têm sido utilizados para desenvolver um modelo híbrido mais complexo, *Multi-Layer Perceptron* (MLP). As novas técnicas desenvolvidas correspondem a VII e VIII, alcançando melhores resultados principalmente em horizontes de tempo mais longos.

A *performance* do modelo foi medida através do erro percentual absoluto médio normalizado (*NMAPE*) e o sistema VIII (combinação de I e VI) obteve o melhor resultado.

Esse modelo foi comparado com quatro métodos utilizados na literatura com base na implantação de uma única técnica de previsão treinada de acordo com as séries temporais de potência e/ou NWP. Para horizontes de tempo de 24 horas, a melhoria em relação à *NMAE* é notória.

Conclui o trabalho que a melhor técnica de previsão é o modelo híbrido baseado em três RNA, obtendo resultados superiores ao método de uma única rede em todos os horizontes de tempo.

A Tabela 9 ilustra o desempenho do sistema VIII em comparação aos quatro métodos utilizados na literatura. A: Rede Neural *multi-layer feedforward*; B: Rede de Elman; C: Rede *multi-layer feedforward*; D: Rede de Elman, incluídas as direções horárias de vento oriundas da NWP.

Tabela 9 – *NMAPE* para diferentes métodos de previsão para horizonte de 24 horas

Método de previsão	<i>NMAPE</i>
VIII	10,98%
A	15,93%
B	18,80%
C	18,88%
D	14,04%

Fonte: Giorgi, Ficarella e Tarantino (2011)

2.9 AVALIAÇÃO DO DESEMPENHO DOS MODELOS CLASSIFICADORES

Para estudar o desempenho dos modelos classificadores em reconhecer as classes GERA (descritas como amostras positivas e que representam situações de velocidades do vento superiores ou equivalentes a 2,5 m/s, suficiente para acionar o funcionamento do aerogerador) e NÃO GERA (descritas como amostras negativas e que representam situações de velocidades do vento inferiores a 2,5 m/s), utilizam-se as medidas de *sensibilidade* e *singularidade*.

$$\text{sensibilidade} = \frac{t_pos}{pos} \quad (23)$$

$$\text{singularidade} = \frac{t_neg}{neg} \quad (24)$$

onde: t_pos - quantidade de amostras GERA que foram corretamente classificadas como tais; pos - quantidade de amostras positivas; t_neg - quantidade de amostras NÃO GERA que foram corretamente classificadas como tais; neg - quantidade de amostras negativas.

Pode-se utilizar a *precisão* para calcular a porcentagem de amostras classificadas como GERA e que são realmente desta classe.

$$\text{precisão} = \frac{t_pos}{(t_pos + f_pos)} \quad (25)$$

onde: t_pos - quantidade de amostras GERA que foram corretamente classificadas como tais; f_pos - quantidade de amostras NÃO GERA que foram incorretamente classificadas como GERA.

Ou mesmo para calcular a porcentagem das amostras classificadas corretamente como NÃO GERA.

$$precisão = \frac{t_neg}{(t_neg + f_neg)} \quad (26)$$

onde: t_neg - quantidade de amostras NÃO GERA que foram corretamente classificadas como tais; f_neg - quantidade de amostras GERA que foram incorretamente classificadas como NÃO GERA.

A *acurácia* do modelo pode, por fim, ser expressa por:

$$acurácia = \left\{ \left(\frac{t_pos}{pos} \right) \cdot \left[\frac{pos}{(pos + neg)} \right] \right\} + \left\{ \left(\frac{t_neg}{neg} \right) \cdot \left[\frac{neg}{(pos + neg)} \right] \right\} \quad (27)$$

onde: t_pos - quantidade de amostras GERA que foram corretamente classificadas como tais; pos - quantidade de amostras positivas; t_neg - quantidade de amostras NÃO GERA que foram corretamente classificadas como tais; neg - quantidade de amostras negativas.

3 ÁREA DE ESTUDO E DADOS

3.1 O PARQUE EÓLICO DE PALMAS – PR

O local de estudo corresponde à Usina Eólio-Elétrica de Palmas (Figura 15), localizada na região de Horizonte, município de Palmas (sul do estado do Paraná e a cerca de 320 quilômetros de Curitiba). Entrou em operação em fevereiro de 1999 e conta com cinco aerogeradores ENERCON modelo E-40 de 500 kW cada, conforme a Figura 16.



Figura 15 – Usina Eólio-Elétrica de Palmas – PR
Fonte: COPEL (2012)

A UEE de Palmas foi a primeira usina eólica construída na região sul do Brasil, implantada pelas Centrais Eólicas do Paraná a um custo total de US\$ 3.000.000,00. A identificação do potencial eólico do local ocorreu através de medições de vento realizadas a partir de 1995 com o Projeto Ventar (COPEL, 2013). A implementação do empreendimento teve efeito praticamente desprezível, uma vez

que a utilização dos campos é para a pastagem (CAMARGO, 2005).




Figura 16 – Vista aérea da UEE de Palmas
Fonte: Google Maps (2015)

A Tabela 10 resume as informações de localização da usina e a Tabela 11 apresenta as informações técnicas do empreendimento.

Tabela 10 – Localização da UEE de Palmas

Localização	
Município	Palmas – PR
Latitude/longitude	26° 34' S/51° 41' O
Altitude média	1314 m

Fonte: COPEL (2005)

Tabela 11 – Características técnicas da UEE de Palmas

Potência elétrica nominal	2,5 MW - 5 aerogeradores de 500 kW
Produção média de energia	4.200.000 a 5.800.000 kWh/ano (estimado)
Aerogeradores	Modelo ENERCON-40 Fabricante: WOBLEN Potência nominal: 500 kW Eixo horizontal com 3 pás Área varrida pelas pás: 1257 m ²
Rotor	Diâmetro do rotor: 40,3 m Altura do cubo: 44 m Rotação: 18 a 38 rpm Regulação: tipo <i>pitch</i>
Velocidade do vento	Para partida (<i>cut-in</i>): 2,5 m/s Para parada de emergência: 25 m/s
Coefficiente de potência máxima	0,42
Conexão ao Sistema Elétrico	5 transformadores de 400 V p/ 34,5 kV Conexão à LT 34,5 kV (37 km)

Fonte: COPEL (2005)

3.2 DADOS DA UEE DE PALMAS

3.2.1 Curvas de potência e de coeficiente de potência

A Figura 17 ilustra as curvas de potência e de coeficiente de potência C_p certificadas pela empresa alemã Windtest Grevenbroich GmbH em WINDTEST WT 890/98, para os aerogeradores modelo E-40 utilizados na Usina Eólio-Elétrica de Palmas.

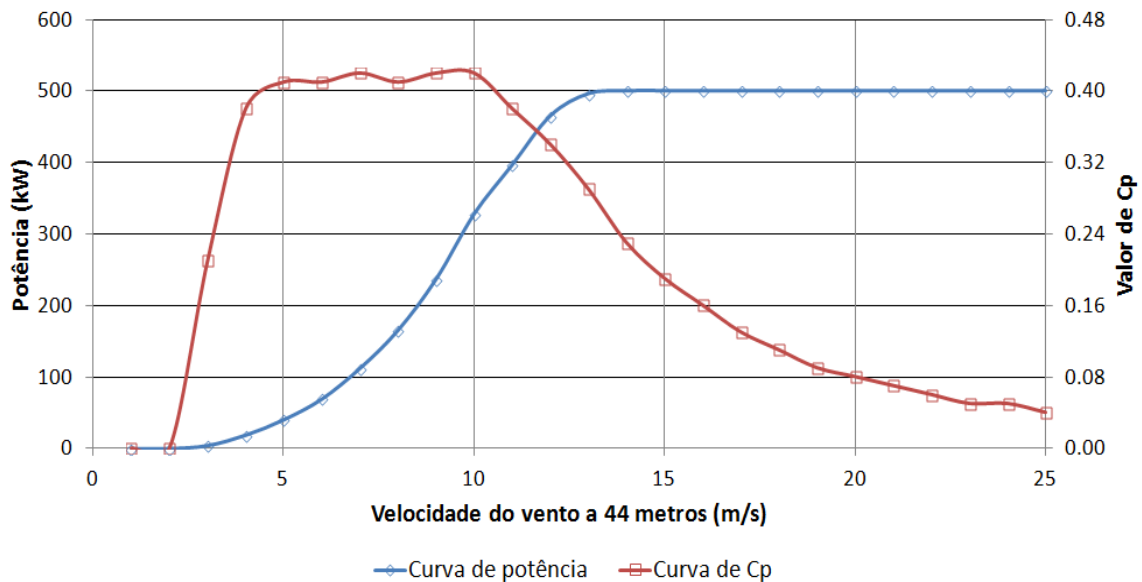


Figura 17 – Curvas de potência e de coeficiente de potência do aerogerador E-40

3.2.2 Massa específica do ar

Segundo Soares, Hiruma e Guetter (2014), a massa específica média do ar em Palmas foi de $1,07 \text{ kg/m}^3$ no ano de 2008. O estudo destaca que esta variável foi 2,3% inferior nos meses quentes (Outubro a Março), comparada à dos meses frios (Abril a Setembro). Cita também o ciclo diário existente, tendo-se valores menores no período da tarde/noite, conforme a Figura 18.

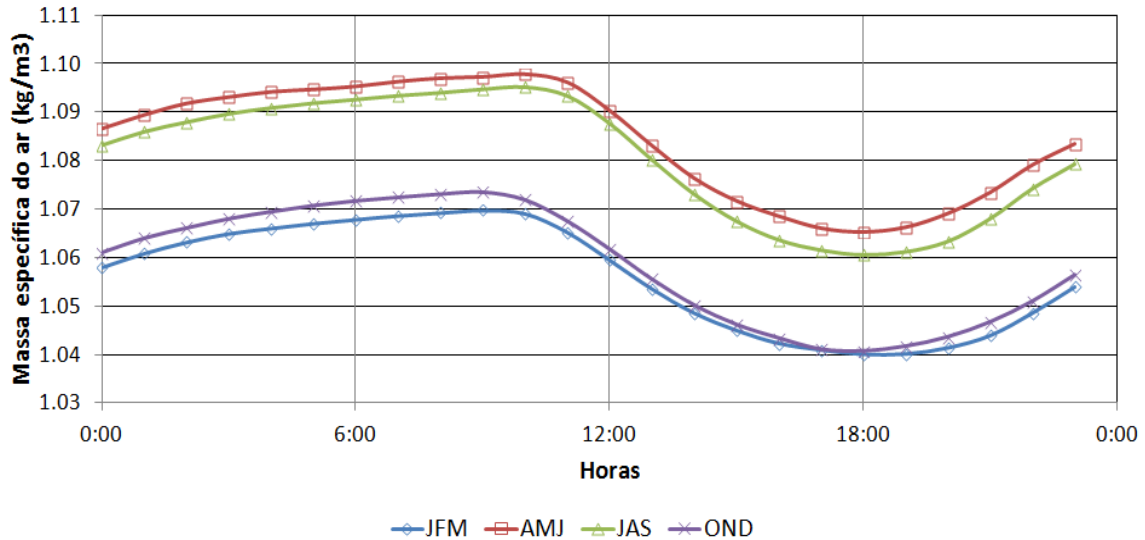


Figura 18 – Ciclo diário da massa específica do ar em Palmas (PR)
 Fonte: Soares, Hiruma e Guetter (2014)

3.2.3 Dados

Os dados de energia gerada pela Usina Eólio-Elétrica de Palmas, compreendendo o período de 01/01/2008 a 19/04/2012, foram disponibilizados pela COPEL. A empresa estatal forneceu conjuntamente, as séries históricas de direção e velocidade dos ventos incidentes no local do empreendimento (de 01/01/2008 a 31/12/2011) para as alturas de 46, 75 e 100 metros. Estas informações são registradas a cada dez minutos e utilizadas como dados de entrada aos modelos previsores de suas respectivas variáveis.

Ressalta-se que os dados de vento foram obtidos através de torre anemométrica instalada próxima aos aerogeradores do parque, cujas coordenadas são 26°34'46,8"S/51°41'51,0"O.

4 MÉTODOS

A seguir são apresentadas as ferramentas computacionais e matemáticas utilizadas no desenvolvimento dessa dissertação.

4.1 FERRAMENTA STATISTICA

O programa *Statistica*, desenvolvido pela *StatSoft* e exemplificado pela Figura 19, foi utilizado para pré-selecionar as variáveis de entrada mais importantes às RNA desenvolvidas neste trabalho, através de técnicas em Mineração de Dados. Dentre os diversos recursos existentes no programa, estão:

- Análise de Agrupamentos;
- Análise Fatorial;
- Árvore de Regressão e Classificação;
- Análise Discriminante.

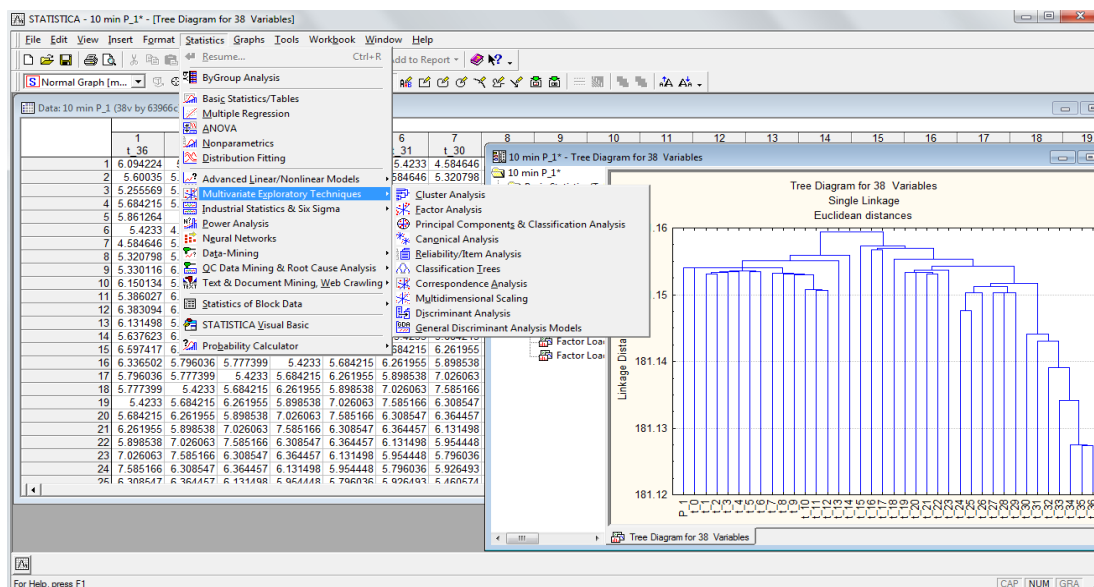


Figura 19 – Tela representando o uso do programa *Statistica*

Statistica Neural Networks (SNN) é um programa capaz de desenvolver modelos com Redes Neurais Artificiais para a previsão de dados numéricos e de classificação, com base em suas séries históricas. Dentre as vantagens, destacam-se: facilidade de uso, elevado poder analítico e capacidade de desenvolver grandes modelos, tanto em número de camadas, como de neurônios associados.

O programa, para tanto, suporta diversas classes de RNA, como:

- *Multi-Layer Perceptron* (MLP), com 3 ou 4 camadas;
- *Radial Basis Function* (RBF);
- *Probabilistic Neural Network* (PNN).

Bem como diferentes funções de ativação, associadas a cada neurônio das camadas escondida(s) e de saída:

- Linear;
- Exponencial;
- Tangente hiperbólica;
- Logística;
- Seno.

O programa é recomendado tanto para novos usuários, como para os que já possuem conhecimento na área. Estes podem decidir, com base em suas experiências e da maneira que desejarem, diferentes parâmetros, como: função de ativação de cada neurônio, tamanho e tipo da rede e algoritmo de treinamento.

Os iniciantes, por outro lado, podem utilizar o recurso “*Intelligent Problem Solver*”, que os guia nos processos para a criação de redes e auxilia na escolha daquelas que produzam os melhores resultados em termos estatísticos.

Realizada a etapa de treinamento, como apresentada na Figura 20, o SNN retém estes modelos e possibilita que sejam analisados e avaliados separadamente, conforme as três amostras do dado histórico, selecionadas manualmente pelo próprio usuário do programa: treinamento, teste e validação.

As RNA podem ser aplicadas para a realização de novas previsões, de duas formas distintas:

- Os modelos são salvos no próprio programa e aplicados, posteriormente, para um novo banco de dados;
- O SNN disponibiliza o código fonte da rede desenvolvida em C ou Java, podendo ser integrado e compilado por outros programas.

O usuário, portanto, possui flexibilidade na utilização dos resultados obtidos com o programa.

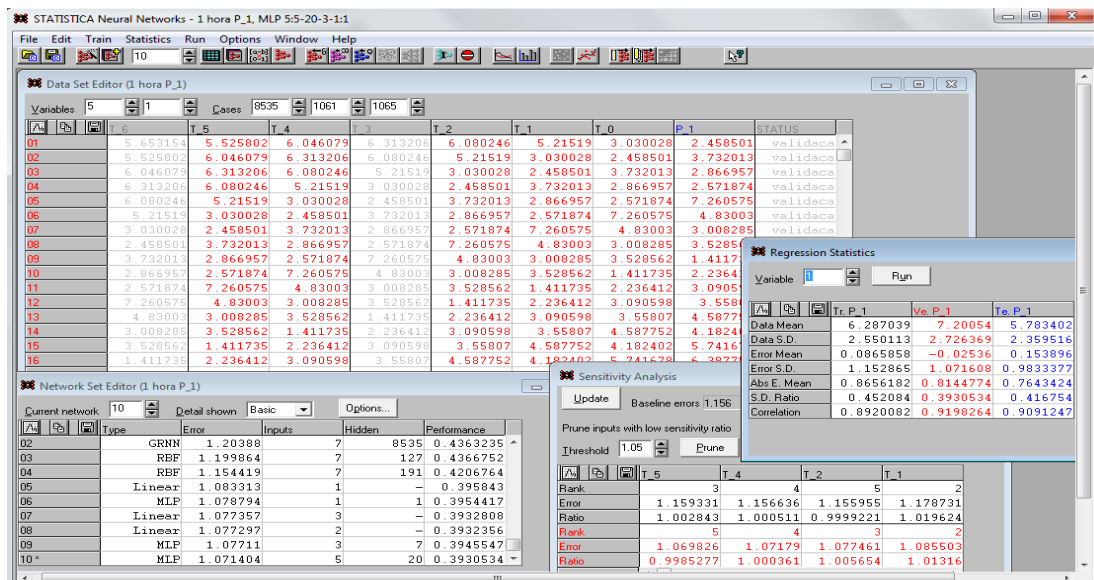


Figura 20 – Tela representando o uso do programa *Statistica Neural Networks*

4.2 REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNA) são modelos simplificados dos neurônios e do cérebro humano, capazes de ser implementadas em *software* e *hardware*. Vêm sendo utilizadas em diversas tarefas e áreas, como na medicina, no reconhecimento de padrões e nas previsões de séries temporais.

4.2.1 Neurônio biológico

O cérebro humano é o órgão responsável por funções como consciência, pensamento, imaginação, memória e emoção, sendo composto por diversas células especializadas. Dentre elas, os neurônios são interconectados e trabalham em união para a solução de problemas, seguindo a Lei do Tudo ou Nada, em que o estímulo nervoso é transmitido quando o limiar excitatório é ultrapassado. Caso contrário, o impulso nervoso não ocorre e a informação não é passada adiante (LEVINE; SHEFNER, 1991).

A Figura 21 mostra a estrutura de um neurônio, destacando suas principais partes: núcleo, dendritos e axônio, com seus terminais.

Os dendritos recebem os estímulos transmitidos através de neurotransmissores, que provocam oscilações nas concentrações dos íons sódio (Na^+), potássio (K^+) e cloro (Cl^-) e, portanto, na diferença de potencial elétrico. O núcleo celular coleta, combina e processa internamente as informações recebidas e o axônio transmite os estímulos para outras células nervosas. Do órgão e de todos os seus processos envolvidos, destaca-se a capacidade de resolver problemas complexos e de aprender através de exemplos, generalização de casos.




Figura 21 – Neurônio biológico
Fonte: Lopes e Rosso (2010)

4.2.2 Neurônio artificial

Utilizando como referência a célula biológica, o neurônio artificial, ilustrado na Figura 22, é composto por entradas (dendritos), unidade de processamento (corpo celular) e saída (terminais do axônio).

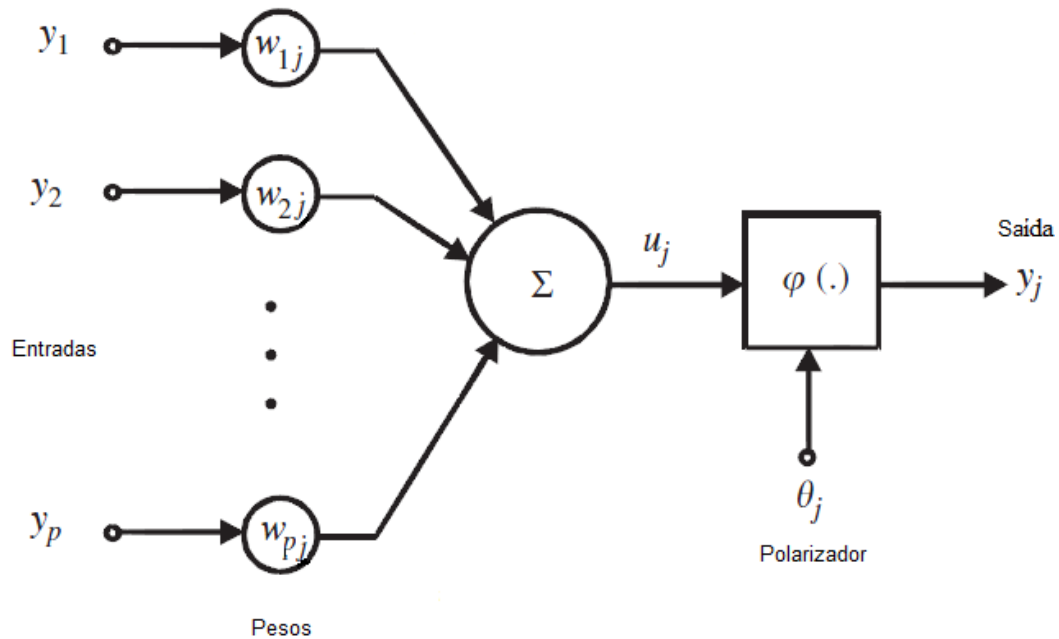


Figura 22 – Neurônio artificial
Fonte: adaptado de Haykin (1994)

O neurônio j , apresentado na Figura 22, pode ser descrito matematicamente, para a iteração n , por:

$$u_j(n) = \sum_{i=1}^p w_{ij}(n) y_i(n) \quad (28)$$

$$y_j(n) = \varphi(u_j(n) - \theta_j(n)) \quad (29)$$

Neste caso, o neurônio recebe um conjunto de sinais $y_i(n)$ associados a seus pesos $w_{ij}(n)$. Calcula-se a média ponderada $u_j(n)$ usando uma função

somatória e, em seguida, é passado o polarizador $\theta_j(n)$. Finalmente, é utilizada a função de ativação $\varphi(\cdot)$ para a produção da saída $y_j(n)$, que pode ser processada por outro neurônio. Destaca-se que $\theta_j(n)$ tem o efeito de transladar $\varphi(\cdot)$ em torno da origem (transformação afim), fazendo que o potencial de ativação $v_j(n)$ não seja nulo quando as entradas $\{y_1, y_2, \dots, y_p\}$ forem.

Entre as funções de ativação existentes, destacam-se:

- Linear ($y_j = v_j(n)$);
- Logística $\left(y_j = \frac{1}{1 + \exp[-v_j(n)]} \right)$;
- Tangente hiperbólica ($y_j = \tanh[v_j(n)]$).

onde: $v_j(n)$ - potencial de ativação do neurônio j na iteração n (soma ponderada de todas as entradas sinápticas mais o polarizador).

A capacidade das RNA de resolver problemas complexos e não lineares é originada do aprendizado através de exemplos e da capacidade de generalização, adquirida durante o treinamento do modelo.

Este processo é responsável por ajustar os pesos das conexões entre os neurônios, podendo ser classificado em:

- Supervisionado: assume-se a presença de professor e as respostas são conhecidas e comparadas diretamente com as previsões realizadas;
- Não supervisionado: Não há professor e as respostas são desconhecidas. O processo de treinamento busca descobrir padrões existentes nos dados disponibilizados.

As redes podem ser divididas, conforme o modo como os neurônios são interligados, em: recorrentes, quando existem laços de realimentação envolvendo uma ou mais camadas do modelo, ou unidirecionais, quando não existem tais ciclos.

4.3 MULTI-LAYER PERCEPTRON

4.3.1 Conceito

As redes *Multi-Layer Perceptron* (MLP) representam uma importante classe de Redes Neurais Artificiais, sendo utilizadas para resolver diversos problemas complexos através de seu treinamento supervisionado com o algoritmo *backpropagation* (RUMELHART; HINTON; WILLIAMS, 1986). São constituídas por uma camada de entrada (*input layer*), que não apresenta pesos ajustáveis, uma ou mais camadas escondidas (*hidden layer*) e uma camada de saída (*output layer*), como na Figura 23.

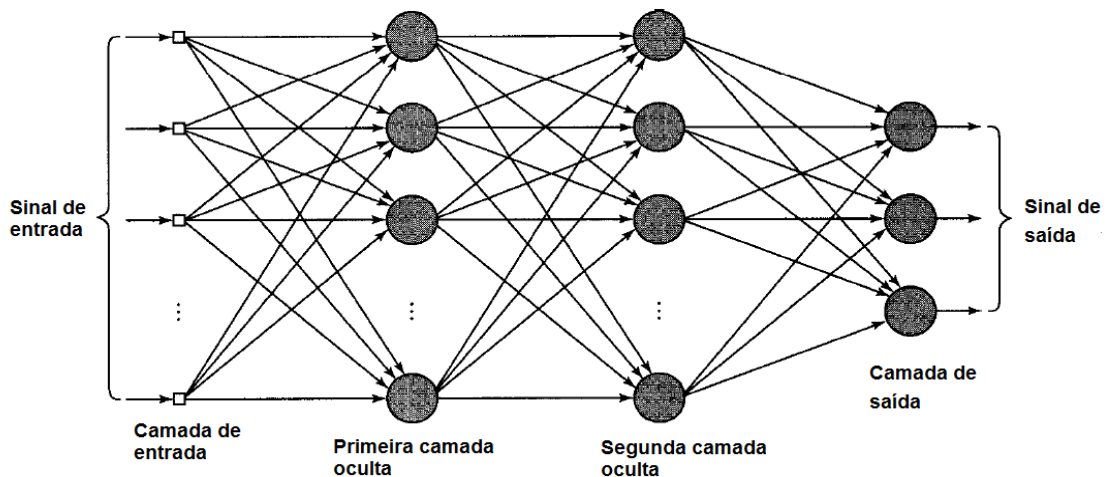


Figura 23 – Arquitetura de uma rede MLP com duas camadas escondidas
Fonte: adaptado de Haykin (1994)

Entre demais características apresentadas pelas *Multi-Layer Perceptrons*, citam-se:

- São consideradas progressivas (*feedforward*), ou seja, as saídas dos neurônios de uma determinada camada se conectam apenas às entradas dos neurônios da camada seguinte;
- Apresentam para cada neurônio da rede, uma função de ativação $\varphi(\cdot)$ não linear e diferenciável em qualquer ponto. Entre as mais utilizadas

estão as funções logística e tangente hiperbólica;

- Possuem alto grau de conectividade, indicado pelas sinapses da rede.

A utilização de camadas escondidas e a alta conectividade característica das MLP permitem que a rede possa resolver problemas não linearmente separáveis ao extrair características mais significativas dos padrões de entrada, porém tornam sua análise e treinamento (ajuste dos pesos) mais complexos (BRAGA; CARVALHO; LUDEMIR, 2000). O algoritmo *backpropagation*, entretanto, é um método eficiente para este fim, sendo explicado na subseção seguinte.

4.3.2 Algoritmo *backpropagation*

Backpropagation é o mais popular e utilizado algoritmo de treinamento supervisionado, que busca minimizar o erro obtido e reajustar os pesos sinápticos associados (GALLANT, 1993).

Este processo é realizado em duas fases distintas: o passo direto (*forward pass*) e o passo reverso (*backward pass*), conforme apresentados na Figura 24 (RUMELHART; HINTON; WILLIAMS, 1986).

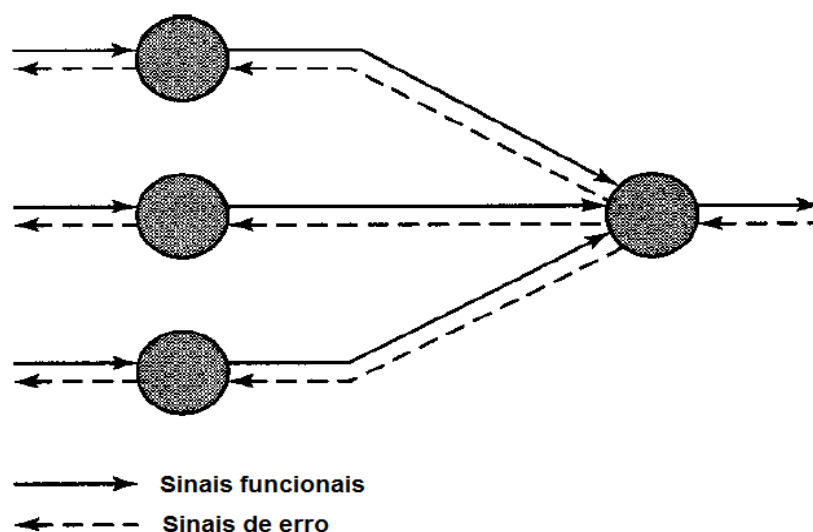


Figura 24 – Propagação para frente dos sinais funcionais e retro propagação dos sinais de erro
 Fonte: adaptado de Haykin (1994)

Durante a primeira etapa, caracterizada pela fixação dos pesos sinápticos, ocorre a propagação dos dados de entrada, camada por camada, até a saída, através de (28) e (29). Ao final, por exemplo, é obtido o sinal de saída $y_j(n)$.

Este resultado é comparado com a resposta desejada para o neurônio j , $d_j(n)$, obtendo o sinal de erro $e_j(n)$.

$$e_j(n) = d_j(n) - y_j(n) \quad (30)$$

A partir deste dado, o valor instantâneo da soma dos erros quadráticos $\varepsilon(n)$ é calculado por:

$$\varepsilon(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (31)$$

onde: C representa todos os neurônios da camada de saída.

O erro médio quadrático MSE pode, portanto, ser obtido pela média de todos os $\varepsilon(n)$ considerados no conjunto de treinamento N' :

$$MSE = \frac{1}{N'} \sum_{n=1}^{N'} \varepsilon(n) \quad (32)$$

Para minimizar MSE , o sinal de erro é retropropagado da camada de saída até a entrada e os pesos de conexão são reajustados a cada apresentação de um novo padrão à rede.

Determina-se a correção $\Delta w_{ij}(n)$, aplicada à i -ésima sinapse do neurônio j , por:

$$\Delta w_{ij}(n) = \eta \delta_j(n) y_i(n) \quad (33)$$

onde: η - taxa de aprendizado.

O gradiente local $\delta_j(n)$ pode, neste caso, ser calculado pela seguinte equação (caso o neurônio pertença à camada de saída):

$$\delta_j(n) = \varphi_j'(v_j(n)) e_j(n) \quad (34)$$

Ou por (35) (caso pertença à camada escondida):

$$\delta_j(n) = \varphi_j'(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (35)$$

Para um determinado neurônio situado na camada de saída, o gradiente local é definido pela multiplicação do erro desta unidade computacional pela derivada de sua não linearidade (34). Obtidos os valores de gradiente para todos os neurônios situados na camada de saída, são quantificadas as alterações em todas as conexões que os alimentam (33).

Posteriormente, são calculados os gradientes locais dos neurônios situados na camada anterior (35) e reajustadas as sinapses que os alimentam (33).

Este processo é realizado recursivamente até que se atinja a camada de entrada.

4.3.3 Derivada da função de ativação

Para o cálculo dos valores de gradiente local δ , utilizados na correção dos pesos w , torna-se necessário conhecer a derivada $\varphi'(\cdot)$ associada a cada neurônio da rede MLP. Para que exista, a única exigência é que a função seja continuamente diferenciável. Duas formas da função não linear sigmoide, comumente utilizada em RNA, são a logística e a tangente hiperbólica, descritas a seguir (HAYKIN, 1994).

4.3.3.1 Função logística

Esta função, cuja saída encontra-se no intervalo entre 0 e 1, é expressa por:

$$\varphi_j(v_j(n)) = \frac{1}{1 + \exp[-v_j(n)]} \quad (36)$$

onde: $\varphi_j(v_j(n))$ - função de ativação; $v_j(n)$ - potencial de ativação do neurônio j .

Derivando a função em relação a $v_j(n)$:

$$\varphi_j'(v_j(n)) = \frac{d\varphi_j(v_j(n))}{d(v_j(n))} = \frac{\exp[-v_j(n)]}{\{1 + \exp[-v_j(n)]\}^2} \quad (37)$$

Sendo $y_j(n) = \varphi_j(v_j(n))$, obtém-se finalmente:

$$\varphi_j'(v_j(n)) = y_j(n)[1 - y_j(n)] \quad (38)$$

Para esta expressão, a derivada atinge seu valor mínimo, $\varphi_j'(v_j(n)) = 0$, quando $y_j(n) = 0$ ou $y_j(n) = 1$ e seu valor máximo para $y_j(n) = 0,5$.

4.3.3.2 Função tangente hiperbólica

A função tangente hiperbólica é definida por:

$$\varphi_j(v_j(n)) = \tanh[v_j(n)] \quad (39)$$

onde: $\varphi_j(v_j(n))$ - função de ativação; $v_j(n)$ - potencial de ativação do neurônio j .

Derivando a função em relação a $v_j(n)$, obtém-se:

$$\varphi_j'(v_j(n)) = \frac{d\varphi_j(v_j(n))}{dv_j(n)} = 1 - y_j^2(n) \quad (40)$$

4.3.4 Taxa de aprendizado e fator de momento

As correções aplicadas aos pesos w da rede MLP ao longo da fase *backward* são influenciadas por η , conforme (41). Esta taxa de aprendizado varia entre 0 a 1 e corresponde ao tamanho do passo para a correção do erro. Caso a convergência seja muito rápida (η próximo de 1), pode-se atingir apenas um mínimo local ou o algoritmo pode se tornar instável (oscilatório). Por outro lado, se o valor da razão for pequeno, as correções aplicadas aos pesos sinápticos entre iterações consecutivas serão menores e a trajetória no espaço dos pesos associados será mais suave. Esta busca pode levar a um mínimo global, porém o tempo necessário ao treinamento da rede pode aumentar demasiadamente (HAYKIN, 1994).

$$\Delta w_{ij}(n) = \eta \delta_j(n) y_i(n) \quad (41)$$

onde: $\Delta w_{ij}(n)$ - correção aplicada à i -ésima sinapse do neurônio j ; η - taxa de aprendizado; $\delta_j(n)$ - gradiente local do neurônio j ; $y_i(n)$ - sinal de entrada no i -ésimo nó do neurônio j .

Uma forma de diminuir o tempo necessário à conversão e manter a trajetória estável é introduzir o fator de momento α (VALENÇA, 2005).

$$\Delta w_{ij}(n) = \alpha \Delta w_{ij}(n-1) + \eta \delta_j(n) y_i(n) \quad (42)$$

Neste caso, se o sinal algébrico das correções é mantido durante várias

iterações seguidas, estas alterações são aumentadas por α , uma vez que a trajetória na superfície do erro ocorre em uma descida íngreme e o mínimo global apresenta-se distante. Por outro lado, caso ocorram mudanças de sinal ao longo das iterações, as correções são diminuídas através de α , visto que o mínimo, provavelmente global, encontra-se próximo.

4.3.5 Critério de parada para o treinamento da rede

Antes do processo de treinamento das Redes Neurais Artificiais, certas questões devem ser definidas para o sucesso do modelo desenvolvido. O banco de dados apresentado às RNA deve ser suficientemente grande para que todas as possíveis variações de resposta possam ser encontradas e deve-se determinar como será realizada a sua divisão, dependente da quantidade de exemplos apresentados, em treinamento (atualização dos pesos sinápticos), teste (verificação das respostas do modelo a dados não utilizados no treinamento) e validação (avaliação da melhor rede obtida) (BASHEER; HAJMEER, 2000). Neste trabalho, foi optada pela partição usualmente utilizada em demais estudos de: 80% para treinamento, 10% para teste e 10% para validação.

No momento de parada do treinamento da RNA, deve-se obter o equilíbrio entre a precisão e a generalização. É possível imaginar, a princípio, que quanto mais iterações forem realizadas, melhor será o aprendizado. Nesta situação, pode-se ter, entretanto, o superajustamento ou *overfitting*, em que a rede se adapta bem aos casos apresentados e perde a capacidade de generalização. Caso o número de iterações seja exageradamente pequeno, a rede pode não adquirir conhecimento suficiente do banco de dados utilizado e apresentar problemas de convergência (VALENÇA, 2005). Há nesta situação, *underfitting*.

Entre critérios ou condições de parada para obter este difícil equilíbrio, tem-se: número de iterações predeterminado, erro médio quadrático inferior a certo valor previamente informado e validação cruzada.

Este último método corresponde ao ajuste dos pesos com os dados definidos para o treinamento e o cálculo do erro com os dados de validação. O

modelo é considerado devidamente treinado quando este erro começa a aumentar com o número de iterações, como apresentado na Figura 25.

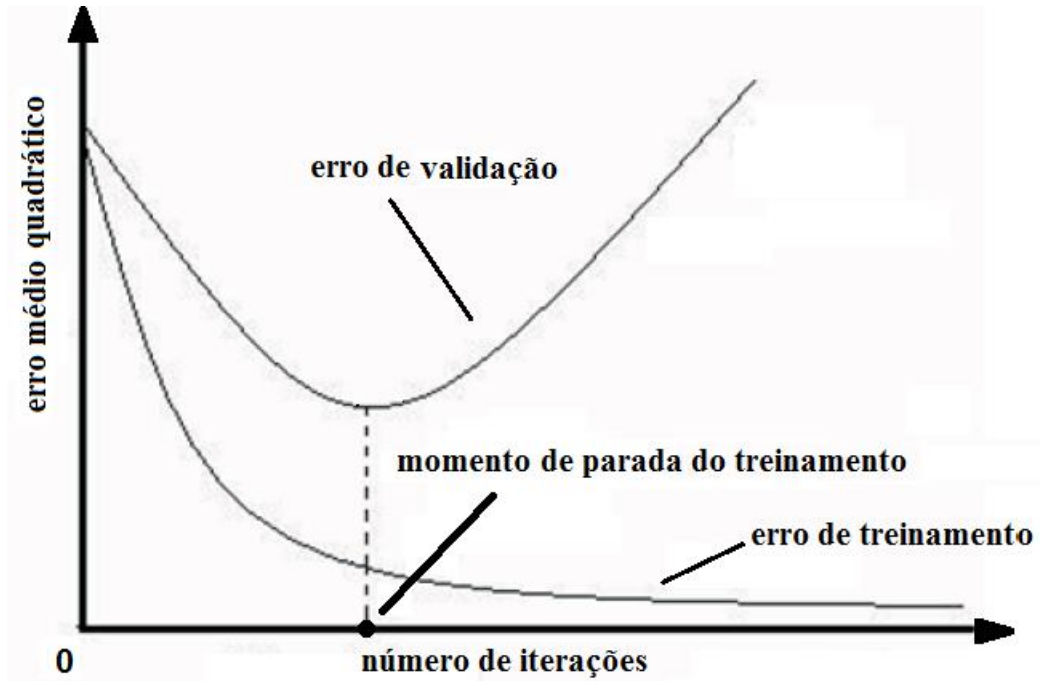


Figura 25 – Validação cruzada
Fonte: adaptado de Haykin (1999)

5 ANÁLISE DOS RESULTADOS

Nesta seção, analisam-se e discutem-se os resultados obtidos após a introdução dos conceitos teóricos e a colocação em prática dos processos envolvidos, com a utilização dos programas *Excel*, *Statistica* e *Statistica Neural Networks* (SNN) e a manipulação dos dados.

5.1 DIREÇÃO DO VENTO

Com os dados do local de estudo, determina-se a direção predominante dos ventos, em função das medições realizadas durante o período de 18 de janeiro de 2008 a 06 de abril de 2009.

A Tabela 12 expõe o número de ocorrências, em resolução de dez minutos, para cada um dos quatro pontos cardeais e colaterais ao longo do período considerado. É observada a predominância de ventos vindos de nordeste e leste, representando mais de 50% dos casos. Os ventos vindos de sudeste e sul, por outro lado, ocorrem em apenas 11,62%.

Tabela 12 – Ventos vindos de cada direção

Direção	Número de ocorrências (resolução de 10 minutos)
Norte (337,5° - 22,5°)	9.078
Nordeste (22,5° - 67,5°)	18.756
Leste (67,5° - 112,5°)	13.511
Sudeste (112,5° - 157,5°)	3.495
Sul (157,5° - 202,5°)	3.941
Sudoeste (202,5° - 247,5°)	4.215
Oeste (247,5° - 292,5°)	4.756
Noroeste (292,5° - 337,5°)	6.256

A Figura 26 ilustra a rosa dos ventos, que quantifica o número de ocorrências em cada direção.




Figura 26 – Rosa dos ventos em Palmas (PR)

5.2 CORREÇÃO DOS DADOS ANEMOMÉTRICOS

A partir das medições de velocidade do vento a 75 metros de altura (resolução de dez minutos), referentes ao período de 18 de janeiro de 2008 a 06 de abril de 2009 para o local de Palmas, foram realizadas as correções dos dados por meio de (11) para a altura do eixo do rotor, 44 metros.

$$\frac{V(z)}{V(h)} = \frac{\ln\left(\frac{z}{z_0}\right)}{\ln\left(\frac{h}{z_0}\right)} \quad (11)$$

onde: $V(z)$ - velocidade de referência (conhecida), em m/s; $V(h)$ - velocidade do vento na altura h , em m/s; z - altura de referência, em m; h - altura para a qual se quer determinar a velocidade $V(h)$, em m; z_0 - “altura de rugosidade”, em função do tipo de ocupação do solo, em m.

No caso, definiu-se z_0 como 0,03 metro, equivalente à vegetação de estepe

conforme informações disponibilizadas na Tabela 1 (LIMA *et al.*, 2013).

5.3 ANÁLISE ESTATÍSTICA DA VELOCIDADE DO VENTO E DA POTÊNCIA

Foram realizados estudos estatísticos dos dados de velocidade do vento convertidos para a altura do rotor e de potência, que cobriam os seguintes períodos:

- Velocidade do vento: 18/01/2008 a 06/04/2009;
- Potência (período quente): 15/12/2008 a 27/01/2009;
- Potência (período frio): 04/06/2008 a 17/07/2008.

5.3.1 Velocidade do vento

A Tabela 13 resume as estatísticas do vento (resolução de dez minutos) para o período de 18/01/2008 a 06/04/2009, e a Figura 27 ilustra o histograma da variável em questão (resolução de dez minutos) e a distribuição empírica acumulada para o período considerado.

Tabela 13 – Estudo estatístico da velocidade do vento em Palmas – resolução de 10 minutos

Média aritmética (m/s)	6,33
Variância amostral (m^2/s^2)	7,05
Desvio padrão amostral (m/s)	2,65
Mínimo (m/s)	0,00
Máximo (m/s)	19,35




Figura 27 – Histograma de velocidade do vento em Palmas

Através do histograma apresentado, é possível notar uma grande parcela dos dados de velocidade de vento está situada entre 3 m/s e 9,5 m/s. De 4,5 m/s a 7,5 m/s, encontram-se os valores mais frequentes e a média aritmética está nesta faixa. Ressalta-se, a existência de períodos de vento inferior à velocidade de *cut-in* (2,5 m/s) e inclusive inexistente. Por outro lado, a maior velocidade registrada é de 19,35 m/s, suficiente para a potência nominal dos aerogeradores.

5.3.2 Potência (período quente)

A Tabela 14 apresenta as estatísticas de potência (resolução de dez minutos) para o período quente, de 15/12/2008 a 27/01/2009.

Tabela 14 – Estudo estatístico da potência em Palmas (período quente)

Média aritmética (kW)	492,36
Variância amostral ((kW) ²)	241.695,24
Desvio padrão amostral (kW)	491,63
Mínimo (kW)	0,00
Máximo (kW)	2.528,00

A Figura 28 ilustra o histograma de potência (resolução de dez minutos) e a distribuição de frequências empíricas para o período quente.

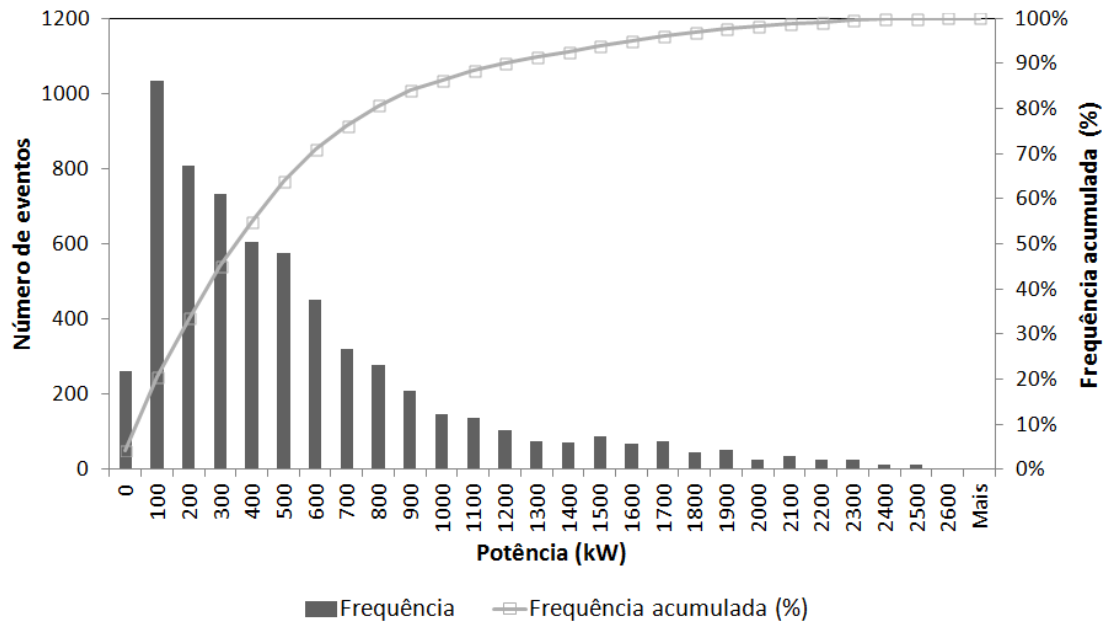


Figura 28 – Histograma de potência em Palmas (período quente)

Observa-se que em uma parcela considerável do tempo, aproximadamente 50% do período, a potência da Usina Eólio-Elétrica de Palmas está entre 100 kW e 600 kW, sendo a média aritmética de 492,36 kW. Há também, situações em que a potência é próxima de ou mesmo equivalente a 0 kW e momentos, mesmo que escassos, nos quais o empreendimento apresenta potência nominal (0,0005% do tempo).

5.3.3 Potência (período frio)

A Tabela 15 resume as estatísticas da potência (resolução de dez minutos) para o período frio, de 04/06/2008 a 17/07/2008.

Tabela 15 – Estudo estatístico da potência em Palmas (período frio)

Média aritmética (kW)	560,17
Variância amostral ((kW) ²)	359.785,37
Desvio padrão amostral (kW)	599,82
Mínimo (kW)	0,00
Máximo (kW)	2.528,00

A Figura 29 ilustra o histograma de potência (resolução de dez minutos) e a distribuição de frequências empíricas para o período frio.




Figura 29 – Histograma de potência em Palmas (período frio)

Como observado no período quente, há momentos de potência nominal e períodos representativos com valores próximos de ou equivalentes a 0 kW. A potência média e o desvio padrão são superiores neste caso: 560,17 kW e 599,82 kW. Possíveis explicações para o maior valor médio são os ventos mais intensos e as menores temperaturas ocorridas no inverno, aumentando o valor da massa específica média do ar úmido e consequentemente da potência.

5.4 ANÁLISE DE VARIABILIDADE DA VELOCIDADE DO VENTO E DA POTÊNCIA

Para os dados de velocidade do vento na altura do eixo do rotor e de potência (períodos quente e frio), foram realizados estudos de variabilidade conforme mostrados a seguir. Destaca-se que as informações são corrigidas automaticamente pelo sistema em caso de horário de verão.

5.4.1 Velocidade do vento

Diferentemente da potência, os dados totais de velocidade do vento não foram separados em períodos quente e frio. Tal divisão foi realizada somente na determinação dos períodos de treinamento, teste e validação para a previsão da velocidade. Para a análise da variabilidade do vento em diferentes períodos do ano, realizada neste momento, optou-se pela partição mostrada a seguir. Os meses citados em cada caso representam aproximadamente os inícios e términos de cada estação astronômica no hemisfério sul da Terra.

- Verão: Janeiro a Março;
- Outono: Abril a Junho;
- Inverno: Julho a Setembro;
- Primavera: Outubro a Dezembro.

A Figura 30 ilustra o ciclo diário da velocidade do vento para os quatro períodos citados, em Palmas (PR).

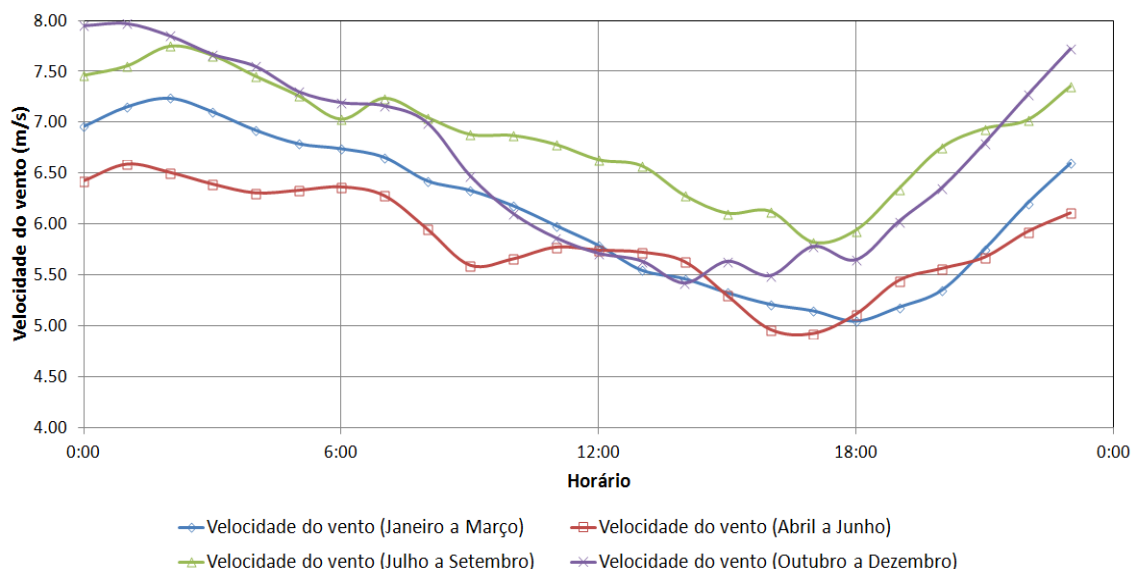


Figura 30 – Ciclo diário da velocidade média do vento

Conforme o gráfico, maiores velocidades são registradas no começo da noite até o amanhecer e os menores ocorrem à tarde. São observados ventos mais

significativos no frio (Julho a Setembro) que no calor (Janeiro a Março) e na primavera, se comparados aos de outono, principalmente nos períodos da noite e da manhã.

A Tabela 16 descreve a variação mensal da velocidade do vento em Palmas (PR) para o período considerado (18/01/2008 a 06/04/2009), sendo a Figura 31 sua representação gráfica. Percebe-se, no caso, o perfil ascendente da velocidade do vento no período de outono e descendente no de primavera.

Tabela 16 – Médias mensais da velocidade do vento em Palmas

Mês	Velocidade média mensal do vento (m/s)
Janeiro	7,10
Fevereiro	5,93
Março	5,61
Abril	5,41
Maio	5,93
Junho	6,28
Julho	6,59
Agosto	6,94
Setembro	7,09
Outubro	6,96
Novembro	6,75
Dezembro	6,23

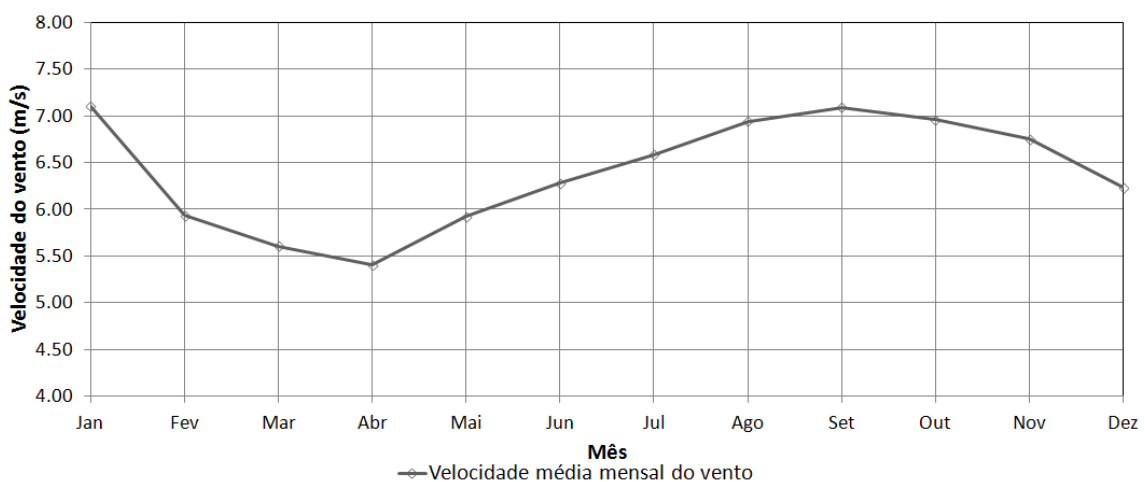


Figura 31 – Variabilidade mensal da velocidade média do vento em Palmas

5.4.2 Potência

A Figura 32 apresenta a variação horária da potência na Usina Eólico-Elétrica de Palmas (PR). O período quente envolve o intervalo de 15 de dezembro de 2008 a 27 de janeiro de 2009 e o período frio, de 04 de junho de 2008 a 17 de julho de 2008.

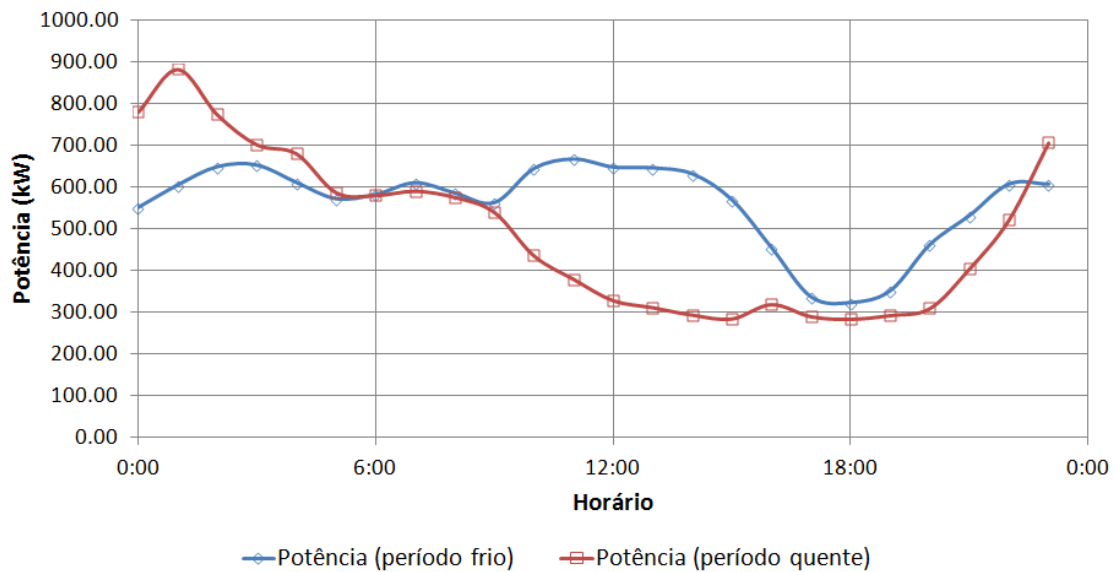


Figura 32 – Ciclo diário da potência nos períodos quente e frio

Observam-se maiores valores de potência durante o período quente somente entre a madrugada e o amanhecer. Em outros horários, especialmente das 10:00 às 16:00, há valores superiores de potência e conseqüentemente de energia gerada ao longo do período frio.

5.5 PREVISÃO DE VELOCIDADE DO VENTO

Neste trabalho, foram realizadas previsões de velocidade do vento em Palmas (PR) para três resoluções: 10 minutos, 1 hora e 3 horas. Todas para até seis passos à frente, ou seja: até 1 hora, 6 horas e 18 horas.

Utilizaram-se como dados de entrada e de saída (para aprendizado supervisionado e comparação das previsões com os valores reais), os dados

históricos de vento que compreendiam o período de 18 de janeiro de 2008 a 06 de abril de 2009. Conforme mostrado na Tabela 17, estas informações foram divididas em três classes (treinamento, teste e validação) para o desenvolvimento dos modelos de previsão em Redes Neurais Artificiais.

Tabela 17 – Intervalos utilizados para treinamento, teste e validação dos modelos de previsão de velocidade do vento

Classe	Intervalos
Treinamento (80%)	09/02/2008 18:00 a 24/06/2008 02:50
	02/08/2008 06:00 a 10/03/2009 11:50
Teste (10%)	24/06/2008 03:00 a 10/07/2008 23:50
	10/03/2009 12:00 a 06/04/2009 23:50
Validação (10%)	18/01/2008 12:00 a 09/02/2008 17:50
	11/07/2008 00:00 a 02/08/2008 05:50

Foi considerada como padrão em todos os modelos, a influência dos ventos ocorridos até seis horas atrás para os valores a serem previstos, ou seja:

- Resolução de 10 minutos: até 36 passos atrás;
- Resolução de 1 hora: até 6 passos atrás;
- Resolução de 3 horas: até 2 passos atrás.

5.5.1 Resolução de 10 minutos

Como mencionado, supôs-se, primeiramente para este caso, que as velocidades de vento a serem previstas (identificadas por p mais o passo temporal considerado) dependiam de diferentes formas, dos dados passados ocorridos até 360 minutos do instante t igual a zero (identificados por t mais o passo temporal considerado).

Porém, devido ao grande número de registros (63990) considerados para o período de estudo, de 18 de janeiro de 2008 a 06 de abril de 2009, e seu consequente custo computacional requisitado, foi utilizada a Mineração de Dados para que se pudesse pré-selecionar quais dessas 36 variáveis de entrada (passos temporais passados ou *delays*) são relevantes aos modelos a serem desenvolvidos.

As quatro técnicas de análise multivariada utilizadas neste trabalho, foram:

- Árvore de Agrupamento (Árvore Hierárquica);
- Método *k-Means*;
- Correlação Linear;
- Análise Fatorial (AF).

5.5.1.1 Análise de agrupamento de dados (Árvore de Agrupamento e Método *k-Means*)

De acordo com o dendograma, ilustrado na Figura 33 e baseado no cálculo das distâncias Euclidianas (13) entre os passos temporais mais próximos, *nearest neighbors*, o ramo à esquerda, composto pela variável de saída (p_1), está agrupando também as variáveis referentes aos *delays* até t_{14} (correspondente às velocidades de vento ocorridas até 140 minutos atrás). Enquanto que o ramo à direita, de maior distância em relação à p_1 , é formado pelos passos temporais 15^o a 36^o atrás.

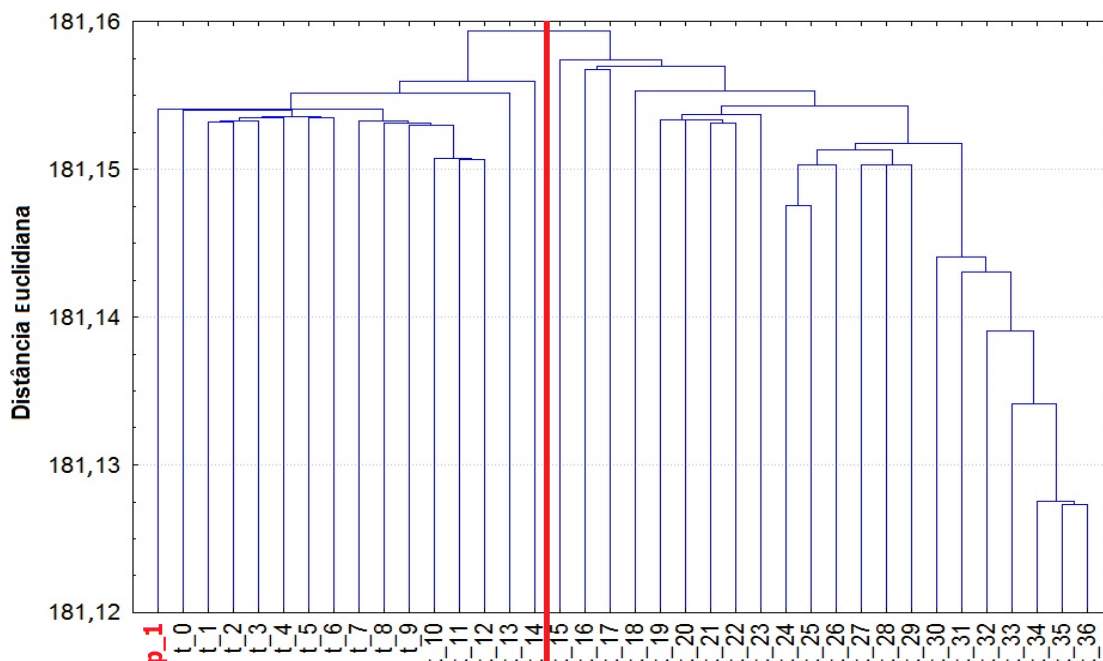


Figura 33 – Árvore de Agrupamento

Para o desenvolvimento do Método *k-Means*, apresentado na Tabela 18, foi considerada a divisão das 36 variáveis de entrada mais a de saída em seis grupos ($k = 6$).

Observa-se neste caso e nas demais técnicas que o valor a ser previsto de 10 minutos à frente (p_1) está mais relacionado aos dados passados mais próximos temporalmente, havendo uma diminuição gradual de importância à medida que se estende os passos considerados.

Como exemplo, o primeiro *cluster* é composto pelo valor a ser previsto e se estende até o quinto dado passado (50 minutos atrás). Com menores influências em relação à p_1 (maiores distâncias Euclidianas médias para p_1), o segundo grupo vai do 6º ao 12º *delay* e o terceiro *cluster*, do 13º ao 18º passo atrás.

Tabela 18 – Método *k-Means*

Cluster 1		Cluster 2		Cluster 3	
Variáveis	Distância	Variáveis	Distância	Variáveis	Distância
t_5	0,872	t_12	0,872	t_18	0,808
t_4	0,712	t_11	0,712	t_17	0,636
t_3	0,602	t_10	0,602	t_16	0,535
t_2	0,561	t_9	0,561	t_15	0,535
t_1	0,602	t_8	0,602	t_14	0,636
t_0	0,712	t_7	0,712	t_13	0,808
p_1	0,872	t_6	0,872		

Cluster 4		Cluster 5		Cluster 6	
Variáveis	Distância	Variáveis	Distância	Variáveis	Distância
t_24	0,808	t_30	0,808	t_36	0,808
t_23	0,636	t_29	0,636	t_35	0,636
t_22	0,535	t_28	0,535	t_34	0,535
t_21	0,535	t_27	0,535	t_33	0,535
t_20	0,636	t_26	0,636	t_32	0,636
t_19	0,808	t_25	0,808	t_31	0,808

5.5.1.2 Análise estatística (Correlação Linear e Análise Fatorial)

A Tabela 19 apresenta apenas uma versão simplificada da matriz de Correlação Linear obtida com o auxílio do programa *Statistica* e destaca a maior relação existente entre a variável de saída com os dados passados mais próximos

temporalmente. Por exemplo, o coeficiente de correlação entre p_1 e o vento ocorrido a 60 minutos do instante t igual a zero, t_6 , é de 0,82. Por outro lado, para o do 36º passo temporal passado (t_{36}), este valor decaiu significativamente para 0,38.

Tabela 19 – Correlação Linear entre as variáveis

Variáveis/Variáveis	t_36	t_30	t_24	t_18	t_12	t_6	p_1
t_36	1,00						
t_30	0,84	1,00					
t_24	0,73	0,84	1,00				
t_18	0,64	0,73	0,84	1,00			
t_12	0,55	0,64	0,73	0,84	1,00		
t_6	0,46	0,55	0,64	0,73	0,84	1,00	
p_1	0,38	0,45	0,53	0,62	0,72	0,82	1,00

Por fim e para a aplicação da Análise Fatorial pelo Método dos Componentes Principais, optou-se pela extração de somente dois fatores, que juntos explicam um valor representativo de 86,59% da variância total.

Sem a rotação, no entanto, há certa dificuldade em interpretar e nomear os fatores. Desta forma, realizou-se a rotação por meio da técnica Varimax, mostrada na Figura 34, na tentativa de simplificar a interpretação.




Figura 34 – Análise Fatorial pelo Método dos Componentes Principais

Pela ilustração, o fator 1 (responsável por 73,74% da variância e de grande

importância para esta seção) carrega o valor a ser previsto de 10 minutos à frente (p_1), além dos dados passados até o 19º passo (190 minutos atrás) e isto se deve a estas variáveis possuírem cargas fatoriais representativas e superiores a 0,60 (eixo horizontal).

Por este critério, portanto, poder-se-ia sugerir que os dados de entrada aos modelos de previsão englobassem os dados até o 19º *delay*.

5.5.1.3 Resultados da previsão de velocidade do vento (resolução de 10 minutos)

A partir dos resultados obtidos pela Mineração de Dados, foram adotados como dados de entrada a todos os modelos de previsão com resolução de 10 minutos, os valores passados de até 170 minutos (17 passos temporais).

As tabelas apresentadas a seguir foram obtidas com o auxílio do programa *Statistica Neural Networks* para as previsões de velocidade do vento para até seis passos à frente (60 minutos). Ressalta-se que a Tabela 20 mostra os resultados para o período quente da validação, de 18/01/2008 a 09/02/2008, e a Tabela 21 para o período frio, de 11/07/2008 a 02/08/2008.

Tabela 20 – Resultados das previsões de velocidade do vento para resolução de 10 minutos (período quente)

Estatísticas	10 min	20 min	30 min	40 min	50 min	60 min
Nash-Sutcliffe	0,932	0,878	0,843	0,814	0,787	0,762
R^2	0,932	0,876	0,844	0,811	0,775	0,745
Erro médio quadrático (m^2/s^2)	0,543	0,980	1,261	1,492	1,709	1,915
Raiz do erro médio quadrático (m/s)	0,737	0,990	1,123	1,222	1,307	1,384
Erro médio absoluto (m/s)	0,547	0,731	0,835	0,918	0,988	1,047
Erro percentual absoluto médio (%)	8,804	12,070	14,011	15,198	16,420	17,523

Tabela 21 – Resultados das previsões de velocidade do vento para resolução de 10 minutos (período frio)

Estatísticas	10 min	20 min	30 min	40 min	50 min	60 min
Nash-Sutcliffe	0,948	0,894	0,847	0,810	0,775	0,744
R^2	0,947	0,890	0,849	0,810	0,765	0,732
Erro médio quadrático (m^2/s^2)	0,390	0,799	1,149	1,425	1,690	1,926
Raiz do erro médio quadrático (m/s)	0,624	0,894	1,072	1,194	1,300	1,388
Erro médio absoluto (m/s)	0,448	0,646	0,791	0,881	0,966	1,036
Erro percentual absoluto médio (%)	7,817	11,322	14,088	15,615	17,180	18,506

As figuras seguintes ilustram a variação da raiz do erro médio quadrático do vento previsto em função do horizonte de previsão e as velocidades do vento previstas e observadas para os períodos quente e frio da validação, com seus respectivos gráficos de dispersão.




Figura 35 – Raiz do erro médio quadrático do vento previsto (resolução de 10 minutos)

De acordo com os resultados apresentados, há diminuições consistentes nos valores de Nash e R^2 e aumentos nos erros, com a expansão do horizonte de tempo. À medida que se avança nos passos, a diferença entre o que foi previsto e a série de dados reais aumenta.

Percebem-se, de uma forma geral, desempenhos similares das previsões para os períodos quente e frio, tendo-se uma *performance* ligeiramente melhor no segundo caso até o terceiro passo à frente.

Conforme os gráficos apresentados a seguir, foram observadas poucas diferenças entre os valores previstos e os dados reais de velocidade do vento para os dois intervalos de validação (quente e frio), sendo os modelos desenvolvidos apropriados a este uso. Há de se considerar, porém, os curtos períodos de tempo estudados nesta etapa.




Figura 36 – Velocidades do vento previstas e observadas durante o período quente – resolução de 10 minutos – 10 minutos à frente

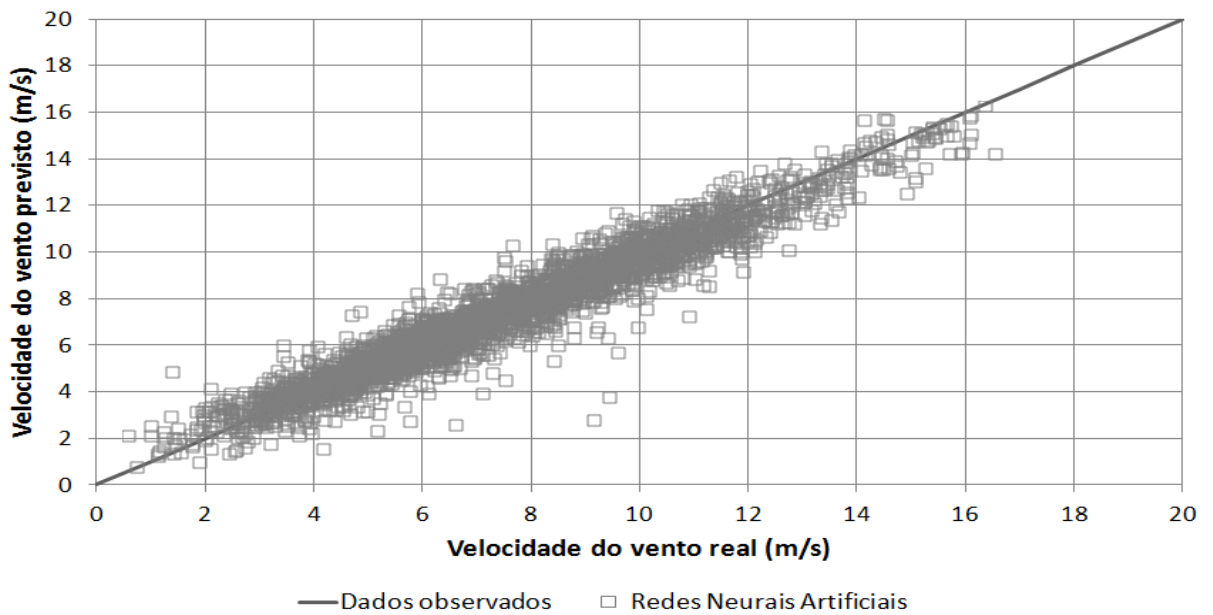


Figura 37 – Resultados da previsão de velocidade do vento durante o período quente – resolução de 10 minutos – 10 minutos à frente




Figura 38 – Velocidades do vento previstas e observadas durante o período quente – resolução de 10 minutos – 20 minutos à frente




Figura 39 – Resultados da previsão de velocidade do vento durante o período quente – resolução de 10 minutos – 20 minutos à frente




Figura 40 – Velocidades do vento previstas e observadas durante o período frio – resolução de 10 minutos – 10 minutos à frente




Figura 41 – Resultados da previsão de velocidade do vento durante o período frio – resolução de 10 minutos – 10 minutos à frente




Figura 42 – Velocidades do vento previstas e observadas durante o período frio – resolução de 10 minutos – 20 minutos à frente




Figura 43 – Resultados da previsão de velocidade do vento durante o período frio – resolução de 10 minutos – 20 minutos à frente

5.5.2 Resolução de 1 hora

Para as previsões de velocidade do vento para as resoluções de 1 hora e de 3 horas (seção 5.5.3), não foram utilizadas técnicas de Mineração de Dados para a pré-seleção das variáveis de entrada aos modelos, devido às menores quantidades de dados de entrada consideradas e, conseqüentemente, menores tempos de processamento requisitados.

Analisou-se estatisticamente a qualidade das previsões realizadas nas amostras de validação das RNA. A Tabela 22 e a Tabela 23 apresentam os resultados obtidos para os períodos quente e frio da validação, respectivamente, e as figuras a seguir apontam as diferenças existentes entre os valores observados e previstos de vento para até 2 horas à frente, com seus gráficos de dispersão, e a variação da raiz do erro médio quadrático com o horizonte de previsão.

Tabela 22 – Resultados das previsões de velocidade do vento para resolução de 1 hora (período quente)

Estatísticas	1 hora	2 horas	3 horas	4 horas	5 horas	6 horas
Nash-Sutcliffe	0,853	0,714	0,590	0,473	0,389	0,311
R^2	0,845	0,697	0,555	0,426	0,305	0,243
Erro médio quadrático (m^2/s^2)	1,112	2,163	3,113	4,001	4,619	5,215
Raiz do erro médio quadrático (m/s)	1,055	1,471	1,764	2,000	2,149	2,284
Erro médio absoluto (m/s)	0,801	1,151	1,370	1,541	1,688	1,800
Erro percentual absoluto médio (%)	12,623	18,492	22,219	25,341	27,869	29,330

Tabela 23 – Resultados das previsões de velocidade do vento para resolução de 1 hora (período frio)

Estatísticas	1 hora	2 horas	3 horas	4 horas	5 horas	6 horas
Nash-Sutcliffe	0,834	0,641	0,480	0,359	0,263	0,183
R^2	0,829	0,645	0,490	0,374	0,266	0,216
Erro médio quadrático (m^2/s^2)	1,183	2,560	3,713	4,589	5,292	5,871
Raiz do erro médio quadrático (m/s)	1,088	1,600	1,927	2,142	2,300	2,423
Erro médio absoluto (m/s)	0,827	1,234	1,482	1,683	1,841	1,931
Erro percentual absoluto médio (%)	14,477	22,122	26,656	30,843	34,437	36,249




Figura 44 – Raiz do erro médio quadrático do vento previsto (resolução de 1 hora)

De acordo com as tabelas e a figura apresentadas e como observado na seção anterior, ocorrem aumentos consistentes nos valores dos erro estudados com o horizonte de previsão e diminuições em Nash e R^2 .

Neste caso, porém, as previsões realizadas para o período de calor são mais aderentes aos dados reais de vento. Adicionalmente, observa-se um melhor desempenho do modelo de resolução de 1 hora para o primeiro passo em comparação ao de resolução de 10 minutos para o sexto passo, destacando que os passos temporais são uma fonte importante de degradação de *performance* dos modelos previsores, como as Redes Neurais Artificiais.

Os gráficos, por outro lado, apontam certa dificuldade dos modelos em prever valores extremos e, apesar disso, mesmo que a qualidade dos resultados diminua com o aumento no horizonte de tempo, as Redes Neurais Artificiais ainda preveem adequadamente o comportamento do vento ao longo dos períodos de validação.




Figura 45 – Velocidades do vento previstas e observadas durante o período quente – resolução de 1 hora – 1 hora à frente




Figura 46 – Resultados da previsão de velocidade do vento durante o período quente – resolução de 1 hora – 1 hora à frente




Figura 47 – Velocidades do vento previstas e observadas durante o período quente – resolução de 1 hora – 2 horas à frente




Figura 48 – Resultados da previsão de velocidade do vento durante o período quente – resolução de 1 hora – 2 horas à frente




Figura 49 – Velocidades do vento previstas e observadas durante o período frio – resolução de 1 hora – 1 hora à frente




Figura 50 – Resultados da previsão de velocidade do vento durante o período frio – resolução de 1 hora – 1 hora à frente




Figura 51 – Velocidades do vento previstas e observadas durante o período frio – resolução de 1 hora – 2 horas à frente




Figura 52 – Resultados da previsão de velocidade do vento durante o período frio – resolução de 1 hora – 2 horas à frente

5.5.3 Resolução de 3 horas

Foram utilizados como variáveis de entrada aos modelos desenvolvidos nesta seção, dois *delays* (equivalentes a seis horas de atraso) e os valores instantâneos de velocidade do vento. Os resultados para os períodos quente e frio

da validação são mostrados na Tabela 24 e na Tabela 25 e os valores da *RMSE* do vento previsto, na Figura 53.

Tabela 24 – Resultados das previsões de velocidade do vento para resolução de 3 horas (período quente)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,701	0,361	0,154	0,124	0,230	0,316
R^2	0,659	0,255	0,112	0,090	0,101	0,192
Erro médio quadrático (m^2/s^2)	2,087	4,515	5,938	6,021	5,254	4,732
Raiz do erro médio quadrático (m/s)	1,445	2,125	2,437	2,454	2,292	2,175
Erro médio absoluto (m/s)	1,151	1,641	1,916	1,950	1,847	1,786
Erro percentual absoluto médio (%)	18,031	25,714	29,400	29,587	29,033	28,180

Tabela 25 – Resultados das previsões de velocidade do vento para resolução de 3 horas (período frio)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,622	0,249	0,105	0,081	0,066	0,052
R^2	0,609	0,224	0,076	0,053	0,086	0,144
Erro médio quadrático (m^2/s^2)	2,455	4,908	5,869	6,037	6,082	6,134
Raiz do erro médio quadrático (m/s)	1,567	2,215	2,423	2,457	2,466	2,477
Erro médio absoluto (m/s)	1,203	1,755	1,930	1,988	2,012	2,010
Erro percentual absoluto médio (%)	20,969	30,542	33,694	35,024	36,985	36,643




Figura 53 – Raiz do erro médio quadrático do vento previsto (resolução de 3 horas)

Para o período quente, há um aumento consistente dos erros calculados e diminuição em Nash e R^2 até o quarto passo, havendo uma melhora de desempenho nas previsões seguintes. Para o frio, ocorrem oscilações e variações consideráveis dos resultados dependendo da variável estatística estudada. Estes efeitos podem ser explicados devido ao maior horizonte de previsão analisado e aos efeitos de ciclo diário. Neste caso, é ressaltado a melhor *performance* das previsões para o verão.




Figura 54 – Velocidades do vento previstas e observadas durante o período quente – resolução de 3 horas – 3 horas à frente




Figura 55 – Resultados da previsão de velocidade do vento durante o período quente – resolução de 3 horas – 3 horas à frente




Figura 56 – Velocidades do vento previstas e observadas durante o período quente – resolução de 3 horas – 6 horas à frente




Figura 57 – Resultados da previsão de velocidade do vento durante o período quente – resolução de 3 horas – 6 horas à frente




Figura 58 – Velocidades do vento previstas e observadas durante o período frio – resolução de 3 horas – 3 horas à frente




Figura 59 – Resultados da previsão de velocidade do vento durante o período frio – resolução de 3 horas – 3 horas à frente




Figura 60 – Velocidades do vento previstas e observadas durante o período frio – resolução de 3 horas – 6 horas à frente




Figura 61 – Resultados da previsão de velocidade do vento durante o período frio – resolução de 3 horas – 6 horas à frente

A partir dos gráficos apresentados, nota-se que à medida que os passos à frente aumentam, as previsões passam a sofrer com um efeito demasiado de suavização (*smoothing effect*), intensificando o problema de previsão de ventos extremos. Passou-se a desenvolver, portanto, demais modelos, que buscassem obter resultados mais aderentes à realidade.

Dentre as redes (Apêndice B), aquelas que apresentaram os resultados mais próximos aos valores observados, possuíam como dados de entrada:

Tabela 26 – Dados de entrada aos modelos aprimorados com resolução de 3 horas

Variáveis de entrada	Passos temporais considerados
Velocidade do vento a 44 metros de altura (V_{44})	Até 4 passos atrás (0, 3, 6, 9 e 12 horas atrás)
Velocidade do vento a 46 metros de altura (V_{46})	Até 4 passos atrás (0, 3, 6, 9 e 12 horas atrás)
Velocidade do vento a 100 metros de altura (V_{100})	Até 4 passos atrás (0, 3, 6, 9 e 12 horas atrás)

Ressalta-se que tal método não foi desenvolvido para as demais resoluções (10 minutos e 1 hora), devido à maior capacidade computacional exigida para estes casos.

A Tabela 27 e a Tabela 28 apresentam os resultados dos modelos desenvolvidos.

Tabela 27 – Resultados das previsões de velocidade do vento dos modelos aprimorados – resolução de 3 horas (período quente)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,739	0,519	0,372	0,309	0,367	0,318
R^2	0,725	0,502	0,234	0,184	0,254	0,225
Erro médio quadrático (m^2/s^2)	1,808	3,325	4,317	4,752	4,359	4,760
Raiz do erro médio quadrático (m/s)	1,344	1,824	2,078	2,180	2,088	2,182
Erro médio absoluto (m/s)	1,070	1,437	1,652	1,760	1,741	1,778
Erro percentual absoluto médio (%)	16,272	23,015	26,059	27,290	28,091	27,331

Tabela 28 – Resultados das previsões de velocidade do vento dos modelos aprimorados – resolução de 3 horas (período frio)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,636	0,289	0,160	0,081	0,007	0,054
R^2	0,651	0,386	0,173	0,117	0,160	0,150
Erro médio quadrático (m^2/s^2)	2,363	4,647	5,508	6,036	6,471	6,119
Raiz do erro médio quadrático (m/s)	1,537	2,156	2,347	2,457	2,544	2,474
Erro médio absoluto (m/s)	1,187	1,674	1,867	1,975	2,075	1,983
Erro percentual absoluto médio (%)	20,037	28,723	32,618	35,018	38,407	35,533

Os resultados obtidos para o período quente são melhorados de forma mais expressiva se comparados aos do frio. Percebe-se através dos gráficos, entretanto, que o problema de suavização em ambos os casos é minimizado com a adoção destas novas redes, em especial para a previsão de 2 passos temporais ou 6 horas à frente.




Figura 62 – Raiz do erro médio quadrático do vento previsto – modelos aprimorados (resolução de 3 horas)




Figura 63 – Velocidades do vento previstas e observadas durante o período quente – modelos aprimorados – resolução de 3 horas – 3 horas à frente




Figura 64 – Resultados da previsão de velocidade do vento durante o período quente – modelos aprimorados – resolução de 3 horas – 3 horas à frente




Figura 65 – Velocidades do vento previstas e observadas durante o período quente – modelos aprimorados – resolução de 3 horas – 6 horas à frente




Figura 66 – Resultados da previsão de velocidade do vento durante o período quente – modelos aprimorados – resolução de 3 horas – 6 horas à frente




Figura 67 – Velocidades do vento previstas e observadas durante o período frio – modelos aprimorados – resolução de 3 horas – 3 horas à frente




Figura 68 – Resultados da previsão de velocidade do vento durante o período frio – modelos aprimorados – resolução de 3 horas – 3 horas à frente




Figura 69 – Velocidades do vento previstas e observadas durante o período frio – modelos aprimorados – resolução de 3 horas – 6 horas à frente




Figura 70 – Resultados da previsão de velocidade do vento durante o período frio – modelos aprimorados – resolução de 3 horas – 6 horas à frente

5.6 CLASSIFICADOR DE GERAÇÃO

Utilizando os mesmos dados de entrada adotados nos modelos previsores de velocidade do vento, com exceção aos da versão aprimorada de resolução de 3 horas, foram desenvolvidos modelos classificadores de geração com o auxílio do programa *Statistica Neural Networks*.

Neste caso, as únicas diferenças estão em como os dados de saída são apresentados ao programa para o aprendizado supervisionado e como os resultados obtidos são expostos.

Os dados utilizados para o aprendizado supervisionado são expressos através de duas classes: GERA, para velocidade do vento equivalente ou superior a 2,5 m/s, e NÃO GERA, para valor inferior a 2,5 m/s. Igualmente, as saídas dos modelos desenvolvidos são expressas em função dessas classes.

Ressalta-se que a velocidade de *cut-in* considerada neste trabalho está em conformidade com os dados apresentados pela COPEL (Tabela 11).

A seguir, são apresentados as matrizes de confusão e os valores correspondentes à precisão, acurácia, sensibilidade e singularidade para o período de validação e para as resoluções de 10 minutos, 1 hora e 3 horas. Tais matrizes são de grande importância aos modelos classificadores (SOUZA; EBECKEN, 2011) e possibilitam uma visualização inequívoca dos resultados obtidos, sendo apresentados em forma de tabela com duas entradas: a primeira formada pelas classes observadas e a segunda, pelas classes previstas. As células são completadas com o número de instâncias correspondentes ao cruzamento das entradas e os valores apresentados na diagonal principal representam as classificações realizadas corretamente pelos modelos.

5.6.1 Resolução de 10 minutos

Para os modelos classificadores desta seção, observam-se diminuições nos valores de precisão (NÃO GERA), singularidade, sensibilidade e acurácia com o aumento do horizonte de previsão. Os números de precisão (GERA) mantêm-se

praticamente constantes. Os resultados apresentados ilustram a excelente identificação para situações em que a velocidade é superior ou equivalente a 2,5 m/s e um pior desempenho para ventos inferiores à *cut-in*. Caso o modelo aponte para a não geração de energia para 10 minutos à frente, por exemplo, há uma probabilidade de 38,06% que esteja correto e em 86,13% dos casos existentes de velocidade inferior a 2,5 m/s, as Redes Neurais Artificiais os conseguem identificar adequadamente.

Tabela 29 – Classificadores de geração (resolução de 10 minutos)
10 minutos à frente

Classe	GERA (97,86%)	NÃO GERA (2,14%)	Precisão (classes)	Acurácia (geral)
Predito como GERA	6061	19	0,997	0,967
Predito como NÃO GERA	192	118	0,381	
Sensibilidade	0,969			
Singularidade	0,861			

20 minutos à frente

Classe	GERA (97,84%)	NÃO GERA (2,16%)	Precisão (classes)	Acurácia (geral)
Predito como GERA	5949	27	0,995	0,948
Predito como NÃO GERA	303	111	0,268	
Sensibilidade	0,952			
Singularidade	0,804			

30 minutos à frente

Classe	GERA (97,84%)	NÃO GERA (2,16%)	Precisão (classes)	Acurácia (geral)
Predito como GERA	5877	27	0,995	0,937
Predito como NÃO GERA	375	111	0,228	
Sensibilidade	0,940			
Singularidade	0,804			

40 minutos à frente

Classe	GERA (97,84%)	NÃO GERA (2,16%)	Precisão (classes)	Acurácia (geral)
Predito como GERA	5833	31	0,995	0,930
Predito como NÃO GERA	419	107	0,203	
Sensibilidade	0,933			
Singularidade	0,775			

50 minutos à frente

Classe	GERA (97,84%)	NÃO GERA (2,16%)	Precisão (classes)	Acurácia (geral)
Predito como GERA	5779	31	0,995	0,921
Predito como NÃO GERA	473	107	0,184	
Sensibilidade	0,924			
Singularidade	0,775			

60 minutos à frente

Classe	GERA (97,84%)	NÃO GERA (2,16%)	Precisão (classes)	Acurácia (geral)
Predito como GERA	5741	37	0,994	0,914
Predito como NÃO GERA	511	101	0,165	
Sensibilidade	0,918			
Singularidade	0,732			

5.6.2 Resolução de 1 hora

Ocorre neste caso, diminuições nos valores de sensibilidade, precisão (NÃO GERA) e acurácia e oscilações em singularidade. Observa-se, um melhor desempenho do modelo de resolução de 1 hora para o primeiro passo à frente em comparação ao de resolução de 10 minutos para o sexto passo.

Como estudado anteriormente, caso o modelo aponte para a não geração de energia para 6 horas à frente, há somente uma probabilidade de 4,74% que isto realmente venha a ocorrer e em 66,67% dos casos existentes de velocidade inferior a 2,5 m/s, as Redes Neurais Artificiais os conseguem identificar corretamente.

Tabela 30 – Classificadores de geração (resolução de 1 hora)
1 hora à frente

Classe	GERA (98,30%)	NÃO GERA (1,70%)	Precisão (classes)	Acurácia (geral)
Predito como GERA	988	2	0,998	0,946
Predito como NÃO GERA	55	16	0,225	
Sensibilidade	0,947			
Singularidade	0,889			

2 horas à frente

Classe	GERA (98,40%)	NÃO GERA (1,60%)	Precisão (classes)	Acurácia (geral)
Predito como GERA	933	5	0,995	0,891
Predito como NÃO GERA	111	12	0,098	
Sensibilidade	0,894			
Singularidade	0,706			

3 horas à frente

Classe	GERA (98,30%)	NÃO GERA (1,70%)	Precisão (classes)	Acurácia (geral)
Predito como GERA	885	8	0,991	0,844
Predito como NÃO GERA	158	10	0,060	
Sensibilidade	0,849			
Singularidade	0,556			

4 horas à frente

Classe	GERA (98,30%)	NÃO GERA (1,70%)	Precisão (classes)	Acurácia (geral)
Predito como GERA	855	7	0,992	0,816
Predito como NÃO GERA	188	11	0,055	
Sensibilidade	0,820			
Singularidade	0,611			

5 horas à frente

Classe	GERA (98,30%)	NÃO GERA (1,70%)	Precisão (classes)	Acurácia (geral)
Predito como GERA	819	8	0,990	0,781
Predito como NÃO GERA	224	10	0,043	
Sensibilidade	0,785			
Singularidade	0,556			

6 horas à frente

Classe	GERA (98,30%)	NÃO GERA (1,70%)	Precisão (classes)	Acurácia (geral)
Predito como GERA	802	6	0,993	0,767
Predito como NÃO GERA	241	12	0,047	
Sensibilidade	0,769			
Singularidade	0,667			

5.6.3 Resolução de 3 horas

Para esta resolução, existem oscilações nos valores de singularidade, pequenas alterações nos valores de precisão (GERA) e diminuição da precisão (NÃO GERA), sensibilidade e acurácia. Para 18 horas à frente, 80% dos casos existentes de vento inferior a 2,5 m/s são identificados corretamente, porém há a pequena probabilidade de 1,69%, de caso o modelo indicar esta situação, a previsão estar correta. Isto se deve ao grande horizonte de previsão e à pequena quantidade de dados utilizados como entrada ao modelo classificador.

Tabela 31 – Classificadores de geração (resolução de 3 horas)
3 horas à frente

Classe	GERA (98,58%)	NÃO GERA (1,42%)	Precisão (classes)	Acurácia (geral)
Predito como GERA	312	1	0,997	0,895
Predito como NÃO GERA	36	4	0,100	
Sensibilidade	0,897			
Singularidade	0,800			

6 horas à frente

Classe	GERA (98,30%)	NÃO GERA (1,70%)	Precisão (classes)	Acurácia (geral)
Predito como GERA	278	3	0,989	0,796
Predito como NÃO GERA	69	3	0,042	
Sensibilidade	0,801			
Singularidade	0,500			

9 horas à frente

Classe	GERA (98,30%)	NÃO GERA (1,70%)	Precisão (classes)	Acurácia (geral)
Predito como GERA	253	3	0,988	0,725
Predito como NÃO GERA	94	3	0,031	
Sensibilidade	0,729			
Singularidade	0,500			

12 horas à frente

Classe	GERA (98,58%)	NÃO GERA (1,42%)	Precisão (classes)	Acurácia (geral)
Predito como GERA	232	4	0,983	0,660
Predito como NÃO GERA	116	1	0,009	
Sensibilidade	0,667			
Singularidade	0,200			

15 horas à frente

Classe	GERA (98,58%)	NÃO GERA (1,42%)	Precisão (classes)	Acurácia (geral)
Predito como GERA	238	4	0,983	0,677
Predito como NÃO GERA	110	1	0,009	
Sensibilidade	0,684			
Singularidade	0,200			

18 horas à frente

Classe	GERA (98,58%)	NÃO GERA (1,42%)	Precisão (classes)	Acurácia (geral)
Predito como GERA	115	1	0,991	0,337
Predito como NÃO GERA	233	4	0,017	
Sensibilidade	0,330			
Singularidade	0,800			

5.7 PREVISÃO DE POTÊNCIA

Realizaram-se previsões de potência na Usina Eólio-Elétrica de Palmas (PR) para três resoluções, 10 minutos, 1 hora e 3 horas, todas para até seis passos temporais à frente: até 1 hora, 6 horas e 18 horas.

Diferentemente do trabalho desenvolvido para a velocidade do vento, foram criados modelos baseados em dois diferentes dados históricos de potência. Estas informações compreendem os intervalos de 15/12/2008 a 27/01/2009 (período quente) e de 04/06/2008 a 17/07/2008 (período frio).

A Tabela 32 e a Tabela 33 mostram como estes intervalos foram divididos em treinamento, teste e validação para o desenvolvimento dos modelos de previsão.

Tabela 32 – Intervalos utilizados para treinamento, teste e validação dos modelos de previsão de potência (período quente)

Classe	Intervalos
Treinamento (80%)	15/12/2008 09:00 a 18/01/2009 11:50 27/01/2009 06:00 a 27/01/2009 23:50
Teste(10%)	18/01/2009 12:00 a 22/01/2009 20:50
Validação (10%)	22/01/2009 21:00 a 27/01/2009 05:50

Tabela 33 – Intervalos utilizados para treinamento, teste e validação dos modelos de previsão de potência (período frio)

Classe	Intervalos
Treinamento (80%)	13/06/2008 03:00 a 17/07/2008 23:50
Teste(10%)	04/06/2008 09:00 a 08/06/2008 17:50
Validação (10%)	08/06/2008 18:00 a 13/06/2008 2:50

Foram considerados os *delays* abaixo como entrada aos modelos de previsão:

- Resolução de 10 minutos: até 17 passos atrás;
- Resolução de 1 hora: até 6 passos atrás;
- Resolução de 3 horas: até 2 passos atrás.

5.7.1 Resolução de 10 minutos

As tabelas a seguir foram desenvolvidas com o auxílio do programa *Statistica Neural Networks* para as previsões de potência para até seis passos temporais ou 60 minutos à frente. A Tabela 34 apresenta os resultados para o período de validação da estação quente, de 22/01/2009 a 27/01/2009, e a Tabela 35 para o da estação fria, de 08/06/2008 a 13/06/2008. As figuras subsequentes apresentam os valores da raiz do erro médio quadrático para a variável estudada, as potências previstas e observadas para os períodos de validação até o segundo passo à frente e os seus respectivos gráficos de dispersão.

Tabela 34 – Resultados das previsões de potência para resolução de 10 minutos (período quente)

Estadísticas	10 min	20 min	30 min	40 min	50 min	60 min
Nash-Sutcliffe	0,91	0,82	0,78	0,74	0,70	0,64
R^2	0,91	0,83	0,78	0,72	0,65	0,61
Erro médio quadrático ((kW) ²)	32.904,25	62.688,81	78.944,48	90.903,67	107.097,47	126.031,94
Raiz do erro médio quadrático (kW)	181,40	250,38	280,97	301,50	327,26	355,01
Erro médio absoluto (kW)	121,74	170,34	197,57	227,01	250,29	272,71

Tabela 35 – Resultados das previsões de potência para resolução de 10 minutos (período frio)

Estadísticas	10 min	20 min	30 min	40 min	50 min	60 min
Nash-Sutcliffe	0,94	0,88	0,83	0,77	0,73	0,71
R^2	0,94	0,88	0,83	0,77	0,74	0,72
Erro médio quadrático ((kW) ²)	25.959,67	54.104,08	76.361,47	100.693,68	118.200,59	128.588,44
Raiz do erro médio quadrático (kW)	161,12	232,60	276,34	317,32	343,80	358,59
Erro médio absoluto (kW)	90,76	134,00	167,17	197,51	211,18	223,28




Figura 71 – Raiz do erro médio quadrático da potência prevista (resolução de 10 minutos)

Para esta resolução, há aumentos consistentes nos erros estudados e diminuições em Nash e R^2 , demonstrando que as Redes Neurais Artificiais foram devidamente treinadas. Em ambos os períodos, ocorre aumento na diferença entre as previsões e os valores reais com a ampliação do horizonte de tempo. Entretanto, há um melhor desempenho, de forma geral, dos modelos desenvolvidos para o frio. Uma possível justificativa está no intervalo selecionado para o estudo, uma vez que não foi possível selecionar um período que sempre houvesse geração para esta situação e fosse, ao mesmo tempo, representativo. Através dos resultados obtidos, percebe-se que, para menores valores reais de potência, os erros absolutos são, normalmente, menos significativos que em casos de potência mais elevada.

Os modelos desenvolvidos nesta seção preveem satisfatoriamente o comportamento da potência ao longo do período de estudo. Para este caso,

entretanto, é destacada uma maior dificuldade em antever valores extremos em ambos os períodos. Como exemplos, têm-se os altos valores observados em 25 de janeiro de 2009 e 10 de junho de 2008.




Figura 72 – Potências previstas e observadas durante o período quente – resolução de 10 minutos – 10 minutos à frente




Figura 73 – Resultados da previsão de potência durante o período quente – resolução de 10 minutos – 10 minutos à frente




Figura 74 – Potências previstas e observadas durante o período quente – resolução de 10 minutos – 20 minutos à frente




Figura 75 – Resultados da previsão de potência durante o período quente – resolução de 10 minutos – 20 minutos à frente




Figura 76 – Potências previstas e observadas durante o período frio – resolução de 10 minutos – 10 minutos à frente




Figura 77 – Resultados da previsão de potência durante o período frio – resolução de 10 minutos – 10 minutos à frente




Figura 78 – Potências previstas e observadas durante o período frio – resolução de 10 minutos – 20 minutos à frente




Figura 79 – Resultados da previsão de potência durante o período frio – resolução de 10 minutos – 20 minutos à frente

5.7.2 Resolução de 1 hora

A Tabela 36 e a Tabela 37 desta subseção expõem os resultados das previsões de potência com resolução de 1 hora para os períodos de validação das estações quente e fria, respectivamente, e as figuras a seguir apontam as diferenças existentes entre os valores observados e previstos de potência através dos modelos desenvolvidos nesta seção, com seus gráficos de dispersão, e as variações existentes em *RMSE*.

Tabela 36 – Resultados das previsões de potência para resolução de 1 hora (período quente)

Estatísticas	1 hora	2 horas	3 horas	4 horas	5 horas	6 horas
Nash-Sutcliffe	0,77	0,47	0,24	0,13	0,09	0,10
R^2	0,73	0,36	0,16	0,10	0,06	0,04
Erro médio quadrático ((kW) ²)	83.474,87	191.810,05	265.288,27	296.161,64	307.610,68	306.176,12
Raiz do erro médio quadrático (kW)	288,92	437,96	515,06	544,21	554,63	553,33
Erro médio absoluto (kW)	221,40	379,46	431,59	445,85	448,95	454,24

Tabela 37 – Resultados das previsões de potência para resolução de 1 hora (período frio)

Estatísticas	1 hora	2 horas	3 horas	4 horas	5 horas	6 horas
Nash-Sutcliffe	0,81	0,66	0,51	0,41	0,31	0,26
R^2	0,81	0,68	0,55	0,45	0,41	0,29
Erro médio quadrático ((kW) ²)	78.196,19	138.979,40	202.560,04	244.993,17	291.322,92	312.127,56
Raiz do erro médio quadrático (kW)	279,64	372,80	450,07	494,97	539,74	558,68
Erro médio absoluto (kW)	173,84	256,01	324,80	376,95	407,46	439,62




Figura 80 – Raiz do erro médio quadrático da potência prevista (resolução de 1 hora)

As mesmas observações realizadas para as previsões de resolução de 10 minutos (seção 5.7.1) podem ser feitas para os resultados desta seção. Nota-se uma melhor *performance* do modelo de resolução de 1 hora para o primeiro passo que de resolução de 10 minutos para o sexto passo à frente e uma degradação no desempenho dos modelos desenvolvidos com o aumento no horizonte de previsão, ainda que para os casos apresentados a seguir (até 2 horas à frente), tais redes acompanhem adequadamente o comportamento dos valores de potência ao longo do tempo.




Figura 81 – Potências previstas e observadas durante o período quente – resolução de 1 hora – 1 hora à frente




Figura 82 – Resultados da previsão de potência durante o período quente – resolução de 1 hora – 1 hora à frente




Figura 83 – Potências previstas e observadas durante o período quente – resolução de 1 hora – 2 horas à frente

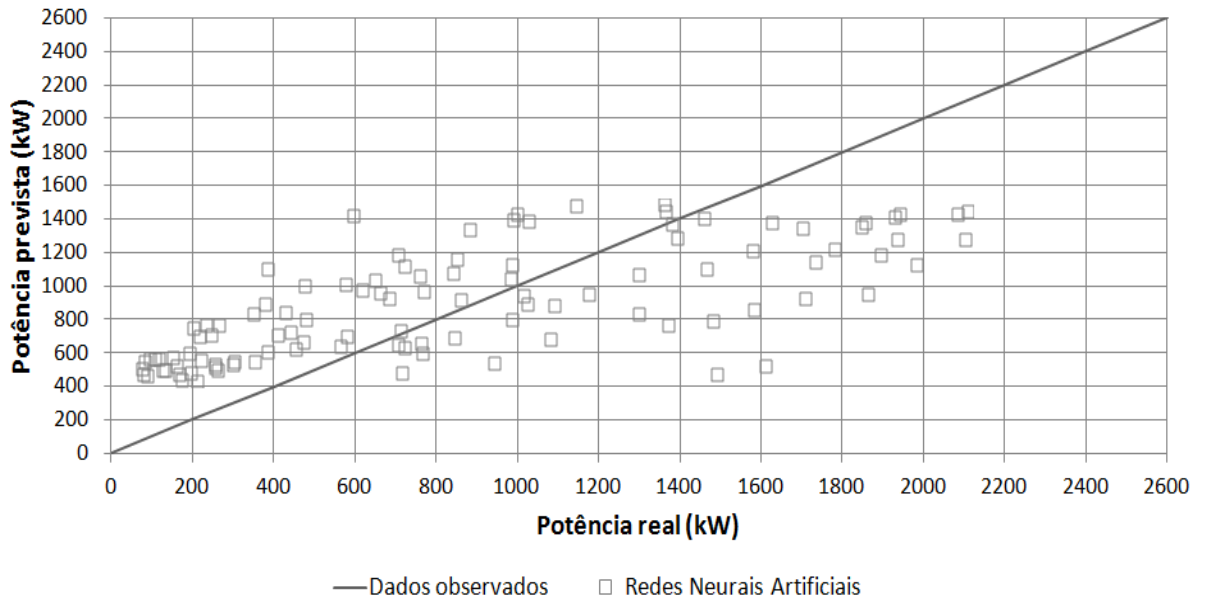


Figura 84 – Resultados da previsão de potência durante o período quente – resolução de 1 hora – 2 horas à frente




Figura 85 – Potências previstas e observadas durante o período frio – resolução de 1 hora – 1 hora à frente




Figura 86 – Resultados da previsão de potência durante o período frio – resolução de 1 hora – 1 hora à frente




Figura 87 – Potências previstas e observadas durante o período frio – resolução de 1 hora – 2 horas à frente

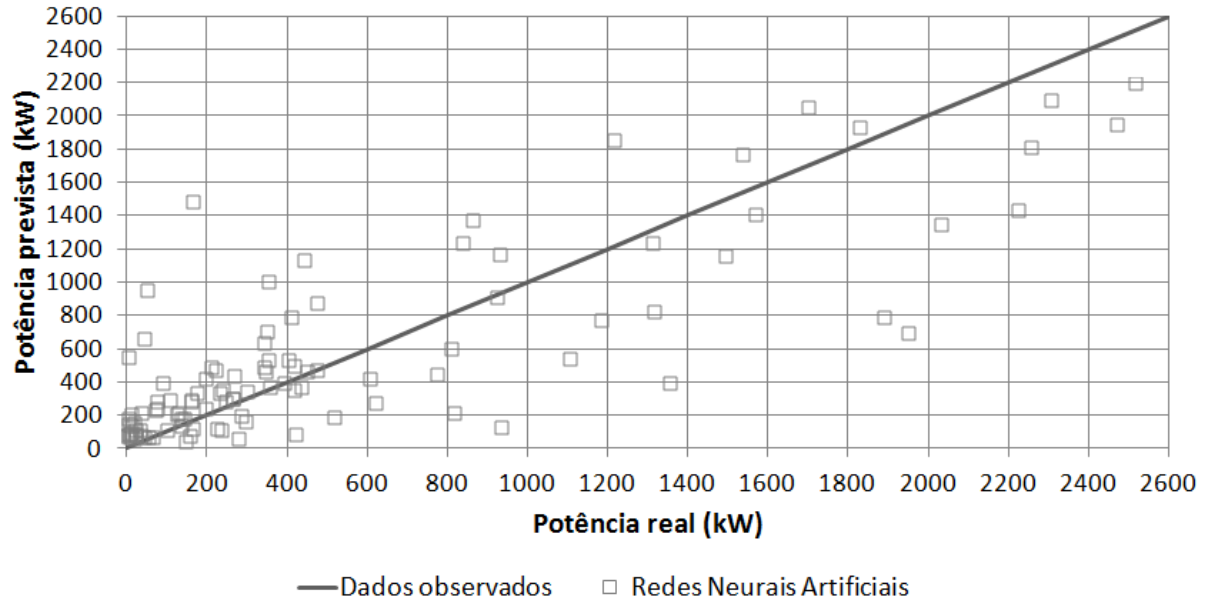


Figura 88 – Resultados da previsão de potência durante o período frio – resolução de 1 hora – 2 horas à frente

5.7.3 Resolução de 3 horas

Foram utilizados como dados de entrada aos modelos de previsão desta seção, apenas dois *delays* e os valores instantâneos de potência da Usina Eólio-Elétrica de Palmas. Os resultados para os períodos de validação são mostrados na Tabela 38 e na Tabela 39 e os valores da raiz do erro médio quadrático da potência prevista em função do horizonte de previsão, na Figura 89.

Tabela 38 – Resultados das previsões de potência para resolução de 3 horas (período quente)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,36	0,11	0,13	0,12	0,22	0,43
R^2	0,28	0,05	0,04	0,06	0,09	0,51
Erro médio quadrático ((kW) ²)	194.030,54	259.492,29	265.586,14	259.529,92	220.872,42	159.390,82
Raiz do erro médio quadrático (kW)	440,49	509,40	515,35	509,44	469,97	399,24
Erro médio absoluto (kW)	348,09	428,89	444,95	438,60	398,20	312,76

Tabela 39 – Resultados das previsões de potência para resolução de 3 horas (período frio)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,67	0,30	0,31	0,36	0,28	0,17
R^2	0,67	0,30	0,21	0,29	0,17	0,22
Erro médio quadrático ((kW) ²)	121.231,34	262.266,42	263.636,57	239.552,01	258.368,22	271.120,34
Raiz do erro médio quadrático (kW)	348,18	512,12	513,46	489,44	508,30	520,69
Erro médio absoluto (kW)	264,68	401,89	415,92	402,43	425,91	414,18




Figura 89 – Raiz do erro médio quadrático da potência prevista (resolução de 3 horas)

Neste caso, há diversas variações de desempenho dos modelos desenvolvidos ao longo do horizonte de tempo. As mesmas justificativas utilizadas para as previsões de velocidade do vento com resolução de 3 horas podem ser aplicadas para este caso e destaca-se, inclusive, uma variação diária mais significativa da variável estudada nesta seção.

Conforme os gráficos apresentados a seguir, as previsões realizadas até 3 horas à frente acompanham as tendências de aumento e diminuição nos valores de potência ao longo do período estudado.




Figura 90 – Potências previstas e observadas durante o período quente – resolução de 3 horas – 3 horas à frente




Figura 91 – Resultados da previsão de potência durante o período quente – resolução de 3 horas – 3 horas à frente




Figura 92 – Potências previstas e observadas durante o período quente – resolução de 3 horas – 6 horas à frente




Figura 93 – Resultados da previsão de potência durante o período quente – resolução de 3 horas – 6 horas à frente




Figura 94 – Potências previstas e observadas durante o período frio – resolução de 3 horas – 3 horas à frente




Figura 95 – Resultados da previsão de potência durante o período frio – resolução de 3 horas – 3 horas à frente

Para 6 horas à frente, entretanto, é possível perceber que os valores previstos passam a sofrer um efeito expressivo de suavização, ficando próximos ao valor médio da série de dados original, como observado a seguir.

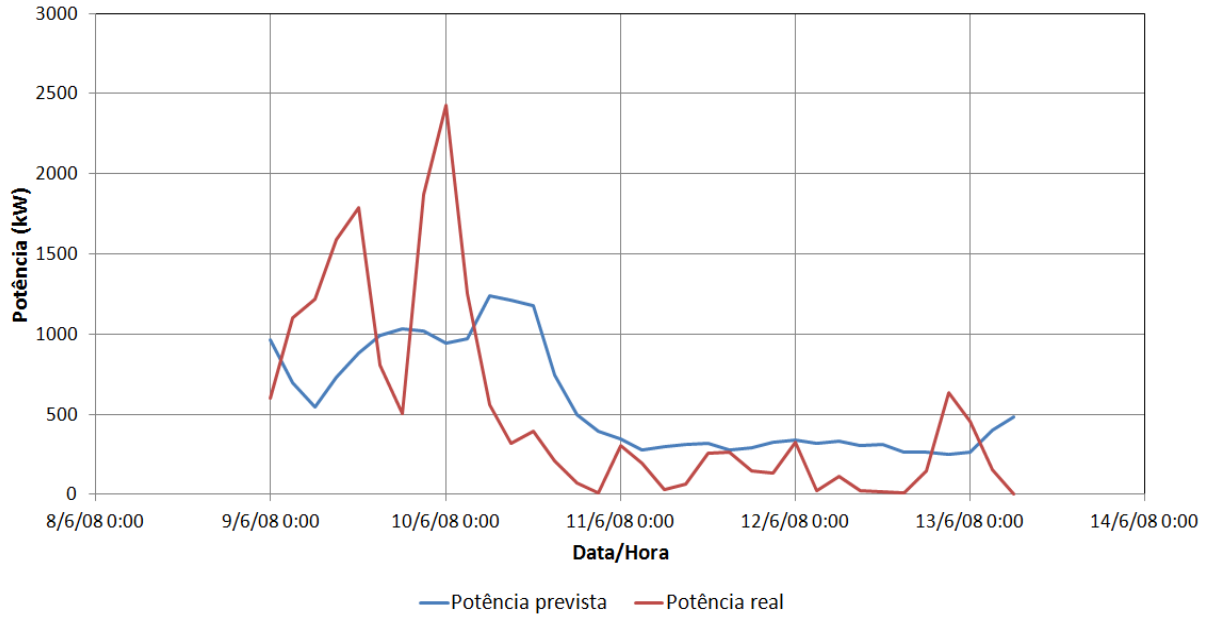


Figura 96 – Potências previstas e observadas durante o período frio – resolução de 3 horas – 6 horas à frente

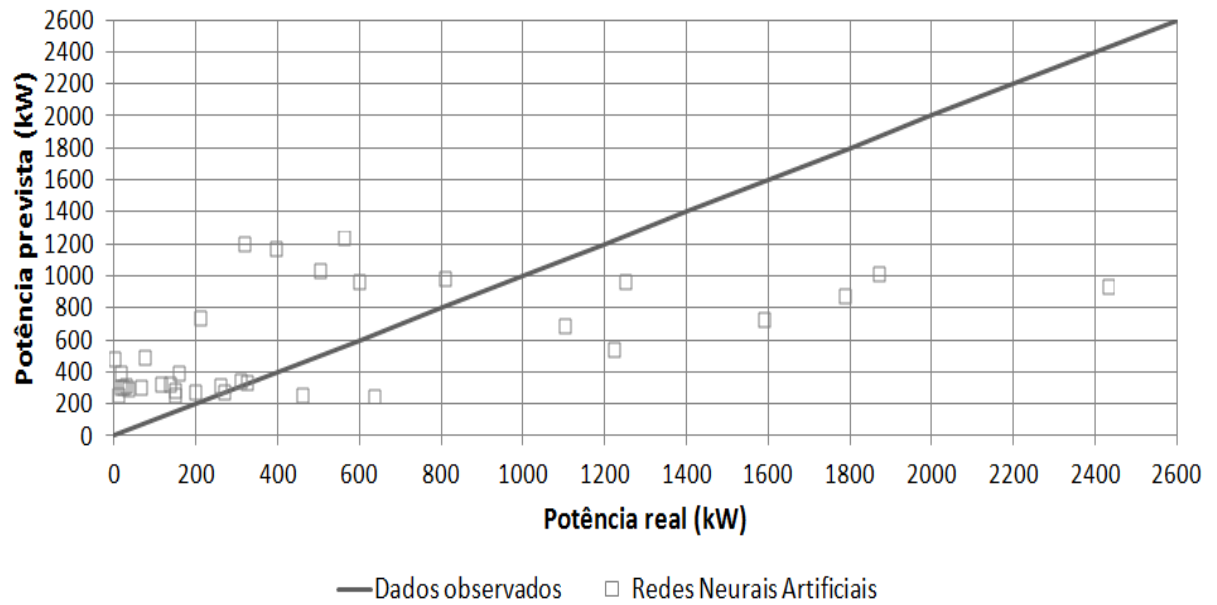


Figura 97 – Resultados da previsão de potência durante o período frio – resolução de 3 horas – 6 horas à frente

5.8 ENERGIA GERADA

A partir dos resultados da seção 5.7 deste trabalho, obtêm-se as estimativas de energia gerada para os períodos de validação considerados. As tabelas a seguir comparam as energias realmente geradas pela UEE de Palmas (PR), com base nos dados disponibilizados pela COPEL para estes períodos, com suas previsões para as resoluções de 10 minutos, 1 hora e 3 horas.

5.8.1 Resolução de 10 minutos

Para os períodos de validação considerados, são observadas oscilações de desempenho dos modelos de previsão, ao focar somente nos dados de energia gerada pela usina. Há, neste caso, uma padronização de momentos em que os valores do erro percentual absoluto médio são superiores e inferiores. Por exemplo, ocorrem menores diferenças entre as energias gerada e prevista nos passos 1, 3 e 5 à frente. Para os períodos quente e frio, os maiores erros são de 4,56% e 3,09%.

Ressalta-se que em todos os resultados apresentados nesta seção, a energia realmente gerada no verão é superior ao valor observado no inverno, pois para este período, não se consegue selecionar intervalos de validação (10% do total) em que o empreendimento esteja sempre gerando eletricidade.

Tabela 40 – Comparativo entre energias geradas e previstas pelos modelos – resolução de 10 minutos (período quente)

	10 min	20 min	30 min	40 min	50 min	60 min
Energia gerada (kWh)	90.843,50	90.831,50	90.812,00	90.747,00	90.676,83	90.624,33
Energia prevista (kWh)	90.986,01	89.571,15	91.171,18	89.489,09	91.445,07	86.492,23
Erro percentual absoluto médio (%)	0,16	1,39	0,40	1,39	0,85	4,56

Tabela 41 – Comparativo entre energias geradas e previstas pelos modelos – resolução de 10 minutos (período frio)

	10 min	20 min	30 min	40 min	50 min	60 min
Energia gerada (kWh)	56.145,50	56.128,17	56.073,83	56.015,50	55.961,83	55.923,33
Energia prevista (kWh)	56.049,22	54.392,20	56.299,35	57.001,94	56.073,28	54.317,23
Erro percentual absoluto médio (%)	0,17	3,09	0,40	1,76	0,20	2,87

5.8.2 Resolução de 1 hora

No período frio, há uma elevação consistente do erro à medida que ocorre a ampliação do horizonte de previsão. Para o calor, acontecem oscilações de desempenho, obtendo o menor valor (0,16%) na previsão de 4 passos temporais à frente. Os maiores erros percentuais são de 6,23% e de 14,78% para os períodos quente e frio.

Tabela 42 – Comparativo entre energias geradas e previstas pelos modelos – resolução de 1 hora (período quente)

	1 hora	2 horas	3 horas	4 horas	5 horas	6 horas
Energia gerada (kWh)	90.624,33	90.136,17	89.122,17	88.218,83	87.509,50	86.401,00
Energia prevista (kWh)	87.471,96	94.875,92	89.586,74	88.076,69	82.054,06	82.700,28
Erro percentual absoluto médio (%)	3,48	5,26	0,52	0,16	6,23	4,28

Tabela 43 – Comparativo entre energias geradas e previstas pelos modelos – resolução de 1 hora (período frio)

	1 hora	2 horas	3 horas	4 horas	5 horas	6 horas
Energia gerada (kWh)	55.923,33	55.643,16	55.311,16	54.863,66	54.392,16	54.042,50
Energia prevista (kWh)	54.621,53	57.911,80	57.494,89	59.462,43	60.566,76	62.029,20
Erro percentual absoluto médio (%)	2,33	4,08	3,95	8,38	11,35	14,78

5.8.3 Resolução de 3 horas

Para esta situação e como observado na resolução de 1 hora, ocorrem oscilações de desempenho das previsões para o período quente e aumento consistente do erro para o período frio. Neste caso, é observado para 6 passos ou 18 horas à frente, um valor máximo significativo de 41,12% de erro percentual. Para o verão, a menor medida ocorre no 2º passo (0,19%) e o maior (3,39%) no horizonte seguinte. Destaca-se, neste caso, a grande diferença existente entre os resultados dos dois períodos, que já podia ser notada na seção anterior (resolução de 1 hora). Possíveis justificativas para esta situação são o insuficiente conhecimento adquirido

através do pequeno banco de dados apresentado às Redes Neurais Artificiais e as variações mais irregulares e os valores baixos de potências reais ocorridos ao longo do frio. Desta forma, as previsões aproximam-se a um valor médio de magnitude, em maior parte do tempo, superior aos dados reais.

Para 18 horas à frente, por exemplo, a média dos dados observados para o período quente da validação é de 754,15 kW e a dos previstos é de 738,20 kW. Enquanto que para o frio, estes valores são de 392,32 kW e de 553,63 kW, respectivamente.

Tabela 44 – Comparativo entre energias geradas e previstas pelos modelos – resolução de 3 horas (período quente)

	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Energia gerada (kWh)	89.122,16	86.401,00	85.011,16	80.552,83	77.942,66	79.185,50
Energia prevista (kWh)	89.652,78	86.565,74	82.130,82	81.600,89	78.583,48	78.022,94
Erro percentual absoluto médio (%)	0,60	0,19	3,39	1,30	0,82	1,47

Tabela 45 – Comparativo entre energias geradas e previstas pelos modelos – resolução de 3 horas (período frio)

	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Energia gerada (kWh)	55.311,17	54.042,50	52.256,00	49.138,67	45.795,00	41.193,17
Energia prevista (kWh)	57.697,47	60.030,28	59.937,98	61.848,15	60.391,54	58.131,01
Erro percentual absoluto médio (%)	4,31	11,08	14,70	25,86	31,87	41,12

6 CONCLUSÕES E RECOMENDAÇÕES

Neste trabalho, foram desenvolvidos modelos computacionais utilizando a técnica de Redes Neurais Artificiais (RNA) para as previsões de velocidade do vento e de geração elétrica na Usina Eólio-Elétrica de Palmas (PR). As resoluções dos horizontes de previsão são de 10 minutos, 1 hora e 3 horas, até 6 passos à frente. Foram utilizados como entradas, seus correspondentes valores históricos e que compreendiam os dados de até 17, 6 e 2 passos temporais passados (*delays*), respectivamente. Para o primeiro caso, foi realizada uma análise multivariada para estudar a importância dos 36 passos temporais previamente considerados. Dentre os métodos utilizados, citam-se: Correlação Linear, Árvore de Agrupamento (Árvore Hierárquica), Algoritmo *k-Means* e Análise Fatorial (AF).

Para os modelos de previsão de ventos ajustados aos seus dados históricos com resolução de 10 minutos, foram observadas pequenas diferenças entre os valores previstos e reais, devido ao curto período de tempo envolvido. Há, neste caso, uma piora à medida que se estende o horizonte preditivo (número de passos à frente) e a resolução temporal da série. Para o caso de 1 hora, começa a surgir certa dificuldade em prever valores extremos, porém as Redes Neurais Artificiais ainda antevêm corretamente o comportamento do vento ao longo do período estudado. Para a resolução de 3 horas e ao considerar apenas os ventos ocorridos a 44 metros de altura, nota-se que as previsões aproximam-se demasiadamente de um valor médio (fenômeno conhecido como reversão à média), havendo menores amplitudes entre os resultados. Foram desenvolvidos, desta forma, novos modelos para minimizar este problema, considerando o aumento no número de variáveis de entrada, tais como a duplicação dos passos temporais e a inserção das velocidades medidas em 46 e 100 metros de altura. Para este caso estudado (resolução de 3 horas), existe uma oscilação de desempenho ao longo dos passos de previsão devido ao maior horizonte de tempo e as consequentes influências do ciclo diário existente.

Para os modelos classificadores de geração, as diferenças em relação aos modelos anteriores estão em como são apresentados os dados para o aprendizado supervisionado e os resultados obtidos pelas redes. Ao contrário de expor valores

numéricos, são utilizadas apenas duas classes: GERA, caso a velocidade do vento seja equivalente ou superior a 2,5 m/s ($V_{cut\ in}$) e NÃO GERA, caso contrário. Nesta situação, há uma melhor *performance* dos modelos em identificar situações da primeira classe. Para 30 minutos à frente, por exemplo, caso as Redes Neurais Artificiais indiquem que haverá geração de energia eólica, existe 99,54% de probabilidade que isto venha a ocorrer. Mas se o modelo apontar que não haverá geração, a chance de realmente não ocorrer é de 22,84%. Ressalta-se, entretanto, que em 80,43% dos casos em que a velocidade do vento é inferior a 2,5 m/s, a RNA consegue-os identificar corretamente.

Os modelos de potência preveem satisfatoriamente o comportamento da variável, porém com uma maior dificuldade em antever valores extremos, mesmo na resolução de 10 minutos. Para a de 1 hora, observa-se a degradação de desempenho com o aumento do horizonte de tempo. Destaca-se, neste caso, a melhor *performance* do modelo de primeiro passo (resolução de 1 hora) em comparação ao seu correspondente da resolução de 10 minutos, demonstrando que os passos temporais são uma importante fonte de degradação de desempenho. As primeiras redes de 3 horas acompanham adequadamente as tendências dos valores de potência. Porém, à medida que se estende o tempo, os efeitos de suavização comprometem significativamente as previsões obtidas devido à pequena extensão dos dados considerados nesta seção do trabalho.

Em suma, este estudo cumpriu plenamente seus objetivos principais, destacando que o método de Redes Neurais Artificiais (RNA) realizou previsões satisfatórias para o horizonte de curtíssimo prazo, tal como verificado no trabalho desenvolvido por Soares (2015), que utilizou, ao invés, a modelagem *Box & Jenkins*.

Por fim, recomenda-se para a continuidade dessa linha de pesquisa:

- Comparar as previsões obtidas através das RNA com as de demais métodos, como Persistência e Regressão Harmônica;
- Concentrar esforços para estimar séries temporais mais longas de velocidade do vento e de energia gerada na Usina Eólio-Elétrica de Palmas (PR);
- Considerar as variáveis meteorológicas (temperatura, pressão e umidade relativa do ar) como dados de entrada ao treinamento das Redes Neurais

Artificiais;

- Desenvolver modelos classificadores através de regras de classificação com o auxílio do programa *Classification Based on Associations* (CBA), como realizado por Souza, Koerner e Chlad (2015);
- Desenvolver modelos que utilizam, além dos valores históricos das variáveis a serem previstas, dados da Previsão Numérica de Tempo (NWP) e modelos híbridos, como o proposto no trabalho desenvolvido por Souza (2013), Redes Neurais Artificiais mais Regra dos k-Vizinhos Mais Próximos.

REFERÊNCIAS

ABEEólica. Associação Brasileira de Energia Eólica. Boletim de Dados. 2015. Disponível em: <<http://www.abeeolica.org.br/pdf/Boletim-de-Dados-ABEEolica-Junho-2015-Publico.pdf>>. Acesso em: 17/06/2015.

ABEEólica. Associação Brasileira de Energia Eólica. Boletim de Dados. 2016. Disponível em: <<http://www.abeeolica.org.br/pdf/Boletim-de-Dados-ABEEolica-Janeiro-2016-Publico.pdf>>. Acesso em: 02/02/2016.

ALEXIADIS, M. C.; DOKOPOULOS, P. S.; SAHSAMANOGLU, H. S. Wind speed and power forecasting based on spatial correlation models. **IEEE Transactions on Energy Conversion**, v. 14, p. 836-842, 1999.

AMARANTE, O. A. C.; BROWER, M.; ZACK, J.; SÁ, A. L. **Atlas do Potencial Eólico Brasileiro**. Ministério de Minas e Energia, 2001.

BARROS, M. M.; VARELLA, Q. S. V. Geração Eólica. 2008. Disponível em: <http://www.solar.coppe.ufrj.br/eolica/eol_txt.htm>. Acesso em: 14/12/2012.

BARTHELMIE, R. J.; MURRAY, F.; PRYOR, S. C. The economic benefit of short-term forecasting for wind energy in the UK electricity market. **Energy Policy**, v. 36, p. 1687-1696, 2008.

BASHEER, I. A.; HAJMEER, M. Artificial Neural Networks: Fundamental, Computing, Design and Application. **Journal of Microbiological Methods**, v. 43, p. 3-31, 2000.

BESSA, R. J. G. S. B. **Treino On Line de Redes Neurais com Critérios de Informação Aplicada à Previsão Eólica**. Dissertação (Mestrado) – Universidade do Porto, Porto, 2008.

BOSSANYI, E. A. Short-Term Wind Prediction Using Kalman Filters. **Wind Engineering**, v. 9, p. 1-8, 1985.

BOX, G. E.; JENKINS, G. **Time Series Analysis, Forecasting and Control**. 2 ed. Holden Day, 1976.

BRAGA, A.; CARVALHO, A.; LUDEMIR, T. **Redes Neurais Artificiais: Teoria e Aplicações**. 1 ed. LTC, 2000.

CABEZON, D.; MARTI, I.; SAN ISIDRO, M. J.; PEREZ, I. Comparison of Methods for Power Curve Modeling. In: Proceedings of the Global Wind Power Conference, Chicago, 2004.

CAM, E.; ARCAKLIOGLU, E.; CAVUSOGLU, A.; AKBIYIK, B. A classification mechanism for determining average wind speed and power in several regions of Turkey using artificial neural network. **Renewable Energy**, v. 30, p. 227-239, 2005.

CAMARGO, A. S. G. **Análise da operação das Usinas Eólicas de Camelinho e Palmas e avaliação do potencial eólico de localidades no Paraná**. Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná, Curitiba, 2005.

CASTRO, R. M. G. **Energias Renováveis e Produção Descentralizada: Introdução à Energia Eólica**. Instituto Superior Técnico, 2007.

CBEE. Centro Brasileiro de Energia Eólica da Universidade Federal de Pernambuco. 2000. Disponível em: <www.ufpe.br>. Acesso em: 13/05/2013.

COPEL. Companhia Paranaense de Energia. 2005. Disponível em: <<http://www.copel.com>>. Acesso em: 19/02/2013.

COPEL. Companhia Paranaense de Energia. 2012. Disponível em: <<http://www.copel.com>>. Acesso em: 15/12/2012.

COPEL. Companhia Paranaense de Energia. 2013. Disponível em: <http://www.copel.com/ci/edicoes/299/usina_eolica_de_palmas.jsp>. Acesso em: 17/11/2015.

COSTA, A.; CRESPO, J.; NAVARRO, G.; LIZCANO, H.; MADSEN, H.; FEITOSA, E. A review on the young history of the wind power short-term prediction. **Renewable and Sustainable Energy**, v. 12, p. 1725-1744, 2008.

CUSTÓDIO, R. S. **Parâmetros de Projeto de Fazendas Eólicas e Aplicação Específica no Rio Grande do Sul**. Dissertação (Mestrado) – Pontifícia Universidade Católica do Rio Grande do Sul, Porto Alegre, 2002.

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

DEWI. Deutsches Windenergie Institut. **Energia Eólica: técnicas básicas, planejamento, financiamento e verificação**. 2005. Disponível em: <<http://www.dewi.de>>. Acesso em: 14/12/2012.

DEWI. Deutsches Windenergie Institut. **Environmental Aspects and Acceptance of Wind**. 2007. Disponível em: <<http://www.dewi.de>>. Acesso em: 14/12/2012.

DUTRA, R. M. **Viabilidade Técnico-Econômica da Energia Eólica Face ao Novo Marco Regulatório do Setor Elétrico Brasileiro**. Dissertação (Mestrado) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2001.

DUTRA, R. M. **Propostas de Políticas Específicas para Energia Eólica no Brasil após a Primeira Fase do PROINFA**. Tese (Doutorado) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2007.

DUTRA, R. M. **Energia Eólica, Princípios e Tecnologia**. Centro de Referências para Energia Solar e Eólica Sérgio de Salvo Brito (CRESESB), 2009.

DWIA. Danish Wind Industry Association. 2008. Disponível em: <<http://www.windpower.org>>. Acesso em: 12/12/2012.

GALLANT, S. **Neural Network Learning and Expert Systems**. MIT Press, 1993.

GAMA, J.; CARVALHO, A. P. L.; OLIVEIRA, M.; LORENA, A. C.; FACELI, K. **Extração de Conhecimento de Dados – Data Mining**. 1 ed. Silabo, 2012.

GASCH, R.; TWELE, J. **Wind Power Plants – Fundamentals, Design, Construction and Operation**. Springer, 2002.

GIEBEL, G.; KARINIOTAKIS, G.; BROWNSWORD, R. **State of the Art on Short-term Wind Power Prediction**. ANEMOS Deliverable Report, 2003.

GIORGI, M. G.; FICARELLA, A.; TARANTINO, M. Assessment of the benefits of numerical weather predictions in wind power forecasting on statistical methods. **Energy**, v. 36, p. 3968-3978, 2011.

GIPE, P. **Wind Energy Comes of Age**. John Willey and Sons, 1993.

GOOGLE MAPS. 2015. Disponível em: <<http://www.google.com.br/maps>>. Acesso em: 14/10/2015.

GWEC. Global Wind Energy Council. Global Wind Statistics 2015. 2016. Disponível em: <http://www.gwec.net/wp-content/uploads/vip/GWEC-PRstats-2015_LR.pdf>. Acesso em: 11/02/2016.

HAIR, J. F.; ANDERSON, R. E.; TATHAM, R. L.; BLACK, W. C. **Multivariate data analysis**. 4 ed. New Jersey: Prentice-Hall, 1998.

HAN, J.; KAMBER, H. **Data Mining – Concepts and Techniques**. Morgan Kaufmann, 2001.

HAYKIN, S. **Neural networks, a comprehensive foundation**. 1 ed. New Jersey: Prentice-Hall, 1994.

HAYKIN, S. **Neural networks, a comprehensive foundation**. 2 ed. New Jersey: Prentice-Hall, 1999.

IEC. International Electrotechnical Commission. Wind turbines – Part 12-1: Power performance measurements of electricity producing wind turbines. 2005. Disponível em: <http://www.iec.ch/dyn/www/f?p=103:23:0::::FSP_ORG_ID,FSP_LANG_ID:1282,25>. Acesso em: 23/11/2015.

KONICEK, A. R.; LEFMAN, J.; SZAKAI, C. Automated correlation and classification of secondary ion mass spectrometry images using a k-means cluster method. **Analyst**, v. 15, p. 3479-3487, 2012.

LANGE, M.; FOCKEN, U. **Physical Approach to Short-Term Wind Power Prediction**. Springer, 2005.

LARA, O. A.; JENKINS, N.; EKANAYAKE, J.; CARTWRIGHT, P.; HUGHES, M. **Wind Energy Generation – Modeling Control**. Wiley, 2009.

LEVINE, M. W.; SHEFNER, J. M. **Fundamentals of sensation and perception**. Pacific Grove, CA: Brooks/Cole, 1991.

LIMA, J. M.; GUETTER, A. K.; FREITAS, S. R.; PANETTA, J.; LAMOSA, D.; OLIVEIRA, F. Previsão da geração de energia eólica no horizonte de curtíssimo prazo utilizando um modelo regional de previsão do tempo. In: XXII Seminário Nacional de Produção e Transmissão de Energia Elétrica, Brasília, 2013.

LOBO, M. G. **Métodos de predicción de la geración agregada de energia eólica.** Tese (Doutorado) – Universidad Carlos III de Madrid, Madrid, 2010.

LOPES, S.; ROSSO, S. **Biologia.** Saraiva, 2010.

LYSEN, E. H. **Introduction to Wind Energy.** CWD, 1982.

MACKENSEN, R.; LANGE, B.; SCHLOGL, F. Integrating wind energy into public power supply systems – German state of the art. In: Proceedings of the Second International Conference on Integration of Renewable and Distributed Energy Resources, Napa Valley, 2006.

MAKRIDAKIS, S. G.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting: Methods and Application.** John Willey & Sons, 1997.

MELO, E. Investimentos em energia eólica no Brasil: aspectos de inserção, tecnologia e competitividade. 2014. Disponível em: <<http://www.portalabeeolica.org.br/index.php/artigos/2476-investimentos-em-energia-eolica-no-brasil-aspectos-de-insercao,-tecnologia-e-competitividade.html>>. Acesso em: 26/10/2014.

MENDES, D.; MARENGO, J. A. Temporal downscaling: a comparison between artificial neural network and autocorrelation techniques over the Amazon Basin in present and future climate change scenarios. **Theoretical and Applied Climatology**, v. 100, p. 1-9, 2009.

MOHANDÉS, M. A.; HALAWANI, T. O.; REHMAN, S.; HUSSAIN, A. A. Support Vector Machines for Wind Speed Prediction. **Renewable Energy**, v. 29, p. 939-947, 2004.

MONTEIRO, C.; BESSA, R.; MIRANDA, V.; BOTTERUD, A.; WANG, J.; CONZELMANN, G. **Wind Power Forecasting: State-of-the-Art 2009.** Argonne National Laboratory, 2009.

MORI, H.; UMEZAWA, Y. Application of NB tree to selection of meteorological variables in wind speed prediction. In: Proceedings of the IEEE transmission &

distribution conference & exposition: Asia and Pacific, Seoul, 2009.

NAGHETTINI, M.; PINTO, E. J. de A. **Hidrologia Estatística**. CPRM, 2007.

NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models: a discussion of principles. **Journal of Hydrology**, v. 10, p. 282-290, 1970.

PARKES, J.; WASEY, J.; TINDAL, A.; MUNOZ, L. Wind energy trading benefits through short-term forecasting. In: Proceedings of the European Wind Energy Conference, Atenas, 2006.

PATEL, M. R. **Wind and Solar Power Systems**. CRC Press, 1999.

PINSON, P. **Estimation of the uncertainty in wind power forecasting**. Tese (Doutorado) – École Nationale Supérieure des Mines de Paris, Paris, 2006.

REIS, L. B. **Geração de Energia Elétrica**. Manole, 2003.

ROHATGI, J. S.; NELSON, V. **Wind Characteristics – An Analysis for the Generation of Wind Power**. Alternative Energy Institute, 1994.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, v. 323, p. 533-536, 1986.

SCHWARTZ, M.; MILLIGAN, M. Statistical Wind Forecasting at the U.S. National Renewable Energy Laboratory. In: Proceedings of the First IEA Joint Action Symposium on Wind Forecasting Techniques, Norrköping, 2002.

SFETSOS, A. A comparison of various forecasting techniques applied to mean hourly wind speed time series. **Renewable Energy**, v. 21, p. 23-35, 2000.

SIEBERT, N. **Development of methods for regional Wind Power Forecasting**. Tese (Doutorado) – École Nationale Supérieure des Mines de Paris, Paris, 2008.

SILVA, S. R. **Energia Eólica**. Universidade Federal de Minas Gerais, 2004.

SOARES, P. H.; HIRUMA, F. S.; GUETTER, A. K. Estimativa Estocástica da Geração Eólica em Palmas (PR). In: XVIII Congresso Brasileiro de Meteorologia, Recife, 2014.

SOARES, P. H. **Previsão da Geração de Energia Eólica de Curtíssimo Prazo Aplicada ao Parque Eólico de Palmas (PR)**. Dissertação (Mestrado) – Universidade Federal do Paraná, Curitiba, 2015.

SOUZA, F. T.; EBECKEN, N. F. F. A Data Based Model to Predict Landslide Induced by Rainfall in Rio de Janeiro City. **Geotechnical and Geological Engineering**, v. 30, p. 85-94, 2011.

SOUZA, F. T. A data-based model to locate mass movements triggered by seismic events in Sichuan, China. **Environmental Monitoring and Assessment**, v. 186, p. 575-587, 2013.

SOUZA, F. T.; KOERNER, T. C.; CHLAD, R. A data-based model for predicting wildfires in Chapada das Mesas National Park in the State of Maranhão. **Environmental Earth Sciences**, v. 74, p. 3603-3611, 2015.

STATHOPOULOS, C.; KAPERONI, A.; GALANIS, G.; KALLOS, G. Wind power prediction based on numerical and statistical models. **Journal of Wind Engineering and Industrial Aerodynamics**, v. 112, p. 25-38, 2013.

STIEBLER, M. **Wind Energy Systems for Electric Power Generation**. Springer, 2008.

TANDE, J. Grid integration of wind farms. **Wind Energy**, v. 6, p. 281-295, 2003.

TONG, W. **Wind Power Generation and Wind Turbine Design**. WIT Press, 2010.

TORRES, J. L.; GARCIA, M.; BLAS, M.; FRANCISCO, A. Forecast of hourly averages wind speed with ARMA models in Navarre. **Solar Energy**, v. 79, p. 65-77, 2005.

UGP Wind Energy. Upper Great Plains Wind Energy. 2015. Disponível em: <www.plainswindeis.anl.gov/eis/index.cfm>. Acesso em: 06/07/2015.

USDOE. United States Department of Energy. **Wind Energy Information Guide**.

National Renewable Energy Laboratory, 1996.

VALENÇA, M. J. S. **Aplicando Redes Neurais**. Livro Rápido, 2005.

VIHRIALA, H.; RIDANPAA, P.; PERALA, R.; SODERLUND, L. Control of a Variable Speed Wind Turbine with Feedforward of Aerodynamic Torque. In: Proceedings of the European Wind Energy Conference EWEC'99, Nice, 1999.

WANG, X.; GUO, P.; HUANG, X. A Review of Wind Power Forecasting Models. **Energy Procedia**, v. 12, p. 770-778, 2011.

WIDROW, B.; LEHR, M. A. 30 Years of Adaptive Neural Networks: Perceptron, Madaline and Backpropagation. **Proceedings of the IEEE**, v. 78, n. 9, 1990.

WIEN, F. **Power Quality and Utilization Guide, Wind Power**. Copper Development Association, 2006.

ZHU, B.; CHEN, M. Y.; WADE, N.; RAN, L. A Prediction Model for Wind Generation Based on Fuzzy Modeling. **Procedia Environmental Sciences**, v. 12, p. 122-129, 2012.

APÊNDICE A

Nesta seção são apresentadas as Redes Neurais Artificiais aplicadas e os passos temporais utilizados em cada modelo de previsão e sistema classificador desenvolvido nesse trabalho.

PREVISÃO DE VELOCIDADE DO VENTO

Tabela 46 – Redes desenvolvidas e *delays* considerados em cada horizonte de previsão de velocidade do vento – resolução de 10 minutos

Horizonte de previsão	Rede	<i>Delays</i> utilizados como dados de entrada
10 minutos	Linear	V_{44} : 0, 1, 2, 3, 4, 5, 6, 8, 9, 10, 12, 13, 14, 15, e 16
20 minutos	Linear	V_{44} : 0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16 e 17
30 minutos	MLP	V_{44} : 0, 1, 2, 3, 4, 7, 8, 10, 11, 14 e 16
40 minutos	MLP	V_{44} : 0, 2, 3, 4, 6, 7, 8, 11, 13 e 16
50 minutos	Linear	V_{44} : 0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14 e 15
60 minutos	Linear	V_{44} : 0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14 e 15

Tabela 47 – Redes desenvolvidas e *delays* considerados em cada horizonte de previsão de velocidade do vento – resolução de 1 hora

Horizonte de previsão	Rede	<i>Delays</i> utilizados como dados de entrada
1 hora	MLP	V_{44} : 0, 1, 2, 4 e 5
2 horas	MLP	V_{44} : 0
3 horas	MLP	V_{44} : 0
4 horas	MLP	V_{44} : 0
5 horas	MLP	V_{44} : 0
6 horas	MLP	V_{44} : 0 e 6

Tabela 48 – Redes desenvolvidas e *delays* considerados em cada horizonte de previsão de velocidade do vento – resolução de 3 horas

Horizonte de previsão	Rede	<i>Delays</i> utilizados como dados de entrada
3 horas	MLP	V_{44} : 0 e 1
6 horas	MLP	V_{44} : 0, 1 e 2
9 horas	MLP	V_{44} : 0, 1 e 2
12 horas	MLP	V_{44} : 0, 1 e 2
15 horas	MLP	V_{44} : 0, 1 e 2
18 horas	MLP	V_{44} : 0, 1 e 2

Tabela 49 – Redes desenvolvidas e *delays* considerados em cada horizonte de previsão de velocidade do vento – resolução de 3 horas (modelos aprimorados)

Horizonte de previsão	Rede	Delays utilizados como dados de entrada
3 horas	MLP	V_{44} : 0 V_{46} : 0, 2, 3 e 4 V_{100} : 0, 1, 2 e 3
6 horas	MLP	V_{44} : 0, 2, 3 e 4 V_{46} : 0, 1, 2, 3 e 4 V_{100} : 0, 1, 2, 3 e 4
9 horas	MLP	V_{44} : 0, 1, 3 e 4 V_{46} : 0, 1, 2 e 4 V_{100} : 0, 2 e 4
12 horas	MLP	V_{44} : 0, 1, 2, 3 e 4 V_{46} : 0, 1, 3 e 4 V_{100} : 0, 2 e 4
15 horas	MLP	V_{44} : 1, 2, 3 e 4 V_{46} : 0, 1, 2, 3 e 4 V_{100} : 0, 2, 3 e 4
18 horas	MLP	V_{44} : 1, 2, 3 e 4 V_{46} : 0, 1, 2 e 3 V_{100} : 2, 3 e 4

CLASSIFICADOR DE GERAÇÃO

Tabela 50 – Redes desenvolvidas e *delays* considerados em cada horizonte de previsão – resolução de 10 minutos (classificador de geração)

Horizonte de previsão	Rede	Delays utilizados como dados de entrada
10 minutos	MLP	V_{44} : 0
20 minutos	MLP	V_{44} : 0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16 e 17
30 minutos	MLP	V_{44} : 0, 1, 2, 8 e 13
40 minutos	MLP	V_{44} : 0 e 1
50 minutos	MLP	V_{44} : 0 e 13
60 minutos	MLP	V_{44} : 0, 1 e 2

Tabela 51 – Redes desenvolvidas e *delays* considerados em cada horizonte de previsão – resolução de 1 hora (classificador de geração)

Horizonte de previsão	Rede	Delays utilizados como dados de entrada
1 hora	MLP	V_{44} : 0 e 1
2 horas	MLP	V_{44} : 0 e 1
3 horas	MLP	V_{44} : 0
4 horas	MLP	V_{44} : 0 e 1
5 horas	MLP	V_{44} : 0, 1, 2, 3, 4, 5 e 6
6 horas	MLP	V_{44} : 0

Tabela 52 – Redes desenvolvidas e *delays* considerados em cada horizonte de previsão – resolução de 3 horas (classificador de geração)

Horizonte de previsão	Rede	Delays utilizados como dados de entrada
3 horas	MLP	V ₄₄ : 0
6 horas	MLP	V ₄₄ : 0
9 horas	MLP	V ₄₄ : 0, 1 e 2
12 horas	MLP	V ₄₄ : 0
15 horas	MLP	V ₄₄ : 0, 1 e 2
18 horas	MLP	V ₄₄ : 2

PREVISÃO DE POTÊNCIA

Tabela 53 – Redes desenvolvidas e *delays* considerados em cada horizonte de previsão de potência – resolução de 10 minutos (período quente)

Horizonte de previsão	Rede	Delays utilizados como dados de entrada
10 minutos	MLP	0, 1, 2 e 5
20 minutos	MLP	0 e 1
30 minutos	MLP	0, 1, 6 e 17
40 minutos	MLP	0, 16 e 17
50 minutos	MLP	0, 2, 6, 8, 11, 13, 16 e 17
60 minutos	MLP	0, 1, 2, 3, 5, 6, 7, 9, 10 e 11

Tabela 54 – Redes desenvolvidas e *delays* considerados em cada horizonte de previsão de potência – resolução de 10 minutos (período frio)

Horizonte de previsão	Rede	Delays utilizados como dados de entrada
10 minutos	MLP	0, 1, 2, 3, 5, 8 e 11
20 minutos	MLP	0, 5, e 14
30 minutos	MLP	0, 5, 8, 12, 14 e 15
40 minutos	MLP	0, 1, 2, 13 e 15
50 minutos	MLP	0, 1 e 2
60 minutos	MLP	0, 2 e 17

Tabela 55 – Redes desenvolvidas e *delays* considerados em cada horizonte de previsão de potência – resolução de 1 hora (período quente)

Horizonte de previsão	Rede	Delays utilizados como dados de entrada
1 hora	MLP	0, 1, 2, 3, 4, 5 e 6
2 horas	MLP	0, 1 e 2
3 horas	MLP	0, 1, 2 e 3
4 horas	MLP	0, 1, 2, 3, 4 e 6
5 horas	MLP	0, 1, 2, 5 e 6
6 horas	MLP	6

Tabela 56 – Redes desenvolvidas e *delays* considerados em cada horizonte de previsão de potência – resolução de 1 hora (período frio)

Horizonte de previsão	Rede	Delays utilizados como dados de entrada
1 hora	MLP	0, 1, 2, 4 e 6
2 horas	MLP	0, 2, 3, 4 e 5
3 horas	MLP	0, 1, 2, 3, 4 e 5
4 horas	MLP	0, 1, 2, 3, 4, 5 e 6
5 horas	MLP	0, 1, 2, 3, 4, 5 e 6
6 horas	MLP	0, 1, 2, 3, 4, 5 e 6

Tabela 57 – Redes desenvolvidas e *delays* considerados em cada horizonte de previsão de potência – resolução de 3 horas (período quente)

Horizonte de previsão	Rede	Delays utilizados como dados de entrada
3 horas	MLP	0, 1 e 2
6 horas	MLP	0, 1 e 2
9 horas	MLP	1 e 2
12 horas	MLP	0 e 1
15 horas	MLP	0, 1 e 2
18 horas	MLP	1 e 2

Tabela 58 – Redes desenvolvidas e *delays* considerados em cada horizonte de previsão de potência – resolução de 3 horas (período frio)

Horizonte de previsão	Rede	Delays utilizados como dados de entrada
3 horas	MLP	0, 1 e 2
6 horas	MLP	0, 1 e 2
9 horas	MLP	0, 1 e 2
12 horas	MLP	0, 1 e 2
15 horas	MLP	0, 1 e 2
18 horas	MLP	0, 1 e 2

Tabela 60 – 1º modelo complementar desenvolvido para resolução de 3 horas (período quente)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,706	0,427	0,303	0,329	0,332	0,345
R^2	0,688	0,349	0,175	0,246	0,229	0,246
Erro médio quadrático (m^2/s^2)	2,036	3,957	4,790	4,620	4,607	4,568
Raiz do erro médio quadrático (m/s)	1,427	1,989	2,189	2,149	2,146	2,137
Erro médio absoluto (m/s)	1,123	1,540	1,726	1,748	1,751	1,770
Erro percentual absoluto médio (%)	17,258	23,618	26,706	26,534	26,658	27,754

Tabela 61 – 1º modelo complementar desenvolvido para resolução de 3 horas (período frio)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,624	0,275	0,124	0,066	0,049	0,024
R^2	0,639	0,288	0,131	0,152	0,140	0,163
Erro médio quadrático (m^2/s^2)	2,443	4,735	5,745	6,138	6,195	6,315
Raiz do erro médio quadrático (m/s)	1,563	2,176	2,397	2,478	2,489	2,513
Erro médio absoluto (m/s)	1,197	1,721	1,922	1,981	1,996	2,030
Erro percentual absoluto médio (%)	20,301	29,567	34,192	34,804	35,367	36,593

Tabela 62 – 2º modelo complementar desenvolvido para resolução de 3 horas (período quente)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,703	0,361	0,169	0,157	0,243	0,304
R^2	0,676	0,255	0,084	0,059	0,107	0,164
Erro médio quadrático (m^2/s^2)	2,073	4,520	5,836	5,795	5,164	4,813
Raiz do erro médio quadrático (m/s)	1,440	2,126	2,416	2,407	2,273	2,194
Erro médio absoluto (m/s)	1,157	1,640	1,943	1,952	1,837	1,793
Erro percentual absoluto médio (%)	18,681	25,556	31,247	31,550	29,054	28,270

Tabela 63 – 2º modelo complementar desenvolvido para resolução de 3 horas (período frio)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,614	0,251	0,098	0,067	0,077	0,064
R^2	0,622	0,213	0,079	0,066	0,086	0,112
Erro médio quadrático (m^2/s^2)	2,503	4,892	5,914	6,133	6,013	6,059
Raiz do erro médio quadrático (m/s)	1,582	2,212	2,432	2,476	2,452	2,461
Erro médio absoluto (m/s)	1,229	1,747	1,960	2,025	2,006	1,994
Erro percentual absoluto médio (%)	21,699	30,308	35,573	37,721	36,900	36,278

Tabela 64 – 3º modelo complementar desenvolvido para resolução de 3 horas (período quente)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,705	0,360	0,144	0,140	0,211	0,314
R^2	0,679	0,299	0,106	0,051	0,087	0,218
Erro médio quadrático (m^2/s^2)	2,061	4,524	6,010	5,908	5,384	4,740
Raiz do erro médio quadrático (m/s)	1,435	2,127	2,452	2,431	2,320	2,177
Erro médio absoluto (m/s)	1,153	1,627	1,943	1,971	1,873	1,776
Erro percentual absoluto médio (%)	17,858	24,821	29,915	31,715	29,412	27,348

Tabela 65 – 3º modelo complementar desenvolvido para resolução de 3 horas (período frio)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,607	0,245	0,098	0,056	0,062	0,054
R^2	0,613	0,254	0,071	0,062	0,076	0,152
Erro médio quadrático (m^2/s^2)	2,550	4,929	5,917	6,204	6,112	6,119
Raiz do erro médio quadrático (m/s)	1,597	2,220	2,433	2,491	2,472	2,474
Erro médio absoluto (m/s)	1,237	1,751	1,946	2,047	2,031	1,988
Erro percentual absoluto médio (%)	21,609	30,554	34,273	37,989	37,296	35,474

Tabela 66 – 4º modelo complementar desenvolvido para resolução de 3 horas (período quente)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,702	0,356	0,181	0,153	0,256	0,294
R^2	0,673	0,277	0,089	0,076	0,102	0,161
Erro médio quadrático (m^2/s^2)	2,078	4,555	5,747	5,817	5,076	4,882
Raiz do erro médio quadrático (m/s)	1,442	2,134	2,397	2,412	2,253	2,209
Erro médio absoluto (m/s)	1,148	1,640	1,935	1,937	1,824	1,802
Erro percentual absoluto médio (%)	17,392	25,285	31,524	30,158	29,934	28,158

Tabela 67 – 4º modelo complementar desenvolvido para resolução de 3 horas (período frio)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,606	0,238	0,096	0,111	0,103	0,073
R^2	0,608	0,244	0,086	0,048	0,090	0,111
Erro médio quadrático (m^2/s^2)	2,558	4,979	5,930	5,840	5,844	6,001
Raiz do erro médio quadrático (m/s)	1,599	2,231	2,435	2,417	2,417	2,450
Erro médio absoluto (m/s)	1,233	1,765	1,972	1,957	1,971	1,978
Erro percentual absoluto médio (%)	21,615	31,174	36,136	34,967	36,720	35,755

Tabela 68 – 5º modelo complementar desenvolvido para resolução de 3 horas (período quente)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,713	0,408	0,200	0,153	0,271	0,330
R^2	0,677	0,282	0,093	0,081	0,129	0,211
Erro médio quadrático (m^2/s^2)	2,006	4,188	5,613	5,821	4,975	4,631
Raiz do erro médio quadrático (m/s)	1,416	2,046	2,369	2,413	2,231	2,152
Erro médio absoluto (m/s)	1,132	1,626	1,908	1,924	1,812	1,765
Erro percentual absoluto médio (%)	17,891	27,222	30,752	29,527	29,352	27,856

Tabela 69 – 5º modelo complementar desenvolvido para resolução de 3 horas (período frio)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,646	0,301	0,133	0,094	0,075	0,059
R^2	0,634	0,267	0,075	0,040	0,094	0,127
Erro médio quadrático (m^2/s^2)	2,297	4,565	5,685	5,951	6,024	6,087
Raiz do erro médio quadrático (m/s)	1,515	2,137	2,384	2,439	2,454	2,467
Erro médio absoluto (m/s)	1,155	1,724	1,916	1,969	2,011	1,993
Erro percentual absoluto médio (%)	20,191	31,585	34,419	34,862	37,239	35,879

Tabela 70 – 6º modelo complementar desenvolvido para resolução de 3 horas (período quente)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,717	0,394	0,177	0,148	0,249	0,328
R^2	0,694	0,288	0,079	0,047	0,141	0,225
Erro médio quadrático (m^2/s^2)	1,973	4,281	5,780	5,855	5,125	4,644
Raiz do erro médio quadrático (m/s)	1,405	2,069	2,404	2,420	2,264	2,155
Erro médio absoluto (m/s)	1,128	1,600	1,932	1,948	1,807	1,765
Erro percentual absoluto médio (%)	17,515	25,541	30,810	30,730	27,751	27,545

Tabela 71 – 6º modelo complementar desenvolvido para resolução de 3 horas (período frio)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,619	0,268	0,118	0,085	0,086	0,046
R^2	0,632	0,259	0,081	0,045	0,095	0,155
Erro médio quadrático (m^2/s^2)	2,470	4,785	5,788	6,013	5,956	6,172
Raiz do erro médio quadrático (m/s)	1,572	2,187	2,406	2,452	2,441	2,484
Erro médio absoluto (m/s)	1,228	1,738	1,928	1,993	1,977	2,004
Erro percentual absoluto médio (%)	21,591	30,332	34,619	35,957	35,432	36,145

Tabela 72 – 7º modelo complementar desenvolvido para resolução de 3 horas (período quente)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,728	0,427	0,228	0,232	0,294	0,350
R^2	0,703	0,310	0,124	0,135	0,150	0,257
Erro médio quadrático (m^2/s^2)	1,897	4,053	5,420	5,277	4,817	4,492
Raiz do erro médio quadrático (m/s)	1,377	2,013	2,328	2,297	2,195	2,119
Erro médio absoluto (m/s)	1,102	1,549	1,868	1,816	1,768	1,751
Erro percentual absoluto médio (%)	17,591	24,544	30,670	27,916	27,806	27,855

Tabela 73 – 7º modelo complementar desenvolvido para resolução de 3 horas (período frio)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,635	0,304	0,119	0,116	0,100	0,034
R^2	0,631	0,270	0,103	0,075	0,079	0,150
Erro médio quadrático (m^2/s^2)	2,372	4,544	5,779	5,806	5,866	6,252
Raiz do erro médio quadrático (m/s)	1,540	2,132	2,404	2,410	2,422	2,500
Erro médio absoluto (m/s)	1,184	1,710	1,943	1,913	1,944	2,026
Erro percentual absoluto médio (%)	21,083	29,605	35,630	32,768	34,758	36,642

Tabela 74 – 8º modelo complementar desenvolvido para resolução de 3 horas (período quente)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,738	0,443	0,308	0,213	0,358	0,336
R^2	0,718	0,363	0,144	0,272	0,238	0,219
Erro médio quadrático (m^2/s^2)	1,830	3,937	4,859	5,410	4,383	4,592
Raiz do erro médio quadrático (m/s)	1,353	1,984	2,204	2,326	2,094	2,143
Erro médio absoluto (m/s)	1,088	1,566	1,747	1,819	1,706	1,765
Erro percentual absoluto médio (%)	17,038	26,314	28,022	25,350	28,101	27,927

Tabela 75 – 8º modelo complementar desenvolvido para resolução de 3 horas (período frio)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,648	0,283	0,168	-0,036	-0,024	0,042
R^2	0,643	0,374	0,128	0,218	0,128	0,147
Erro médio quadrático (m^2/s^2)	2,287	4,686	5,459	6,809	5,632	6,200
Raiz do erro médio quadrático (m/s)	1,512	2,165	2,336	2,609	2,373	2,490
Erro médio absoluto (m/s)	1,166	1,769	1,844	2,016	1,974	2,009
Erro percentual absoluto médio (%)	20,539	31,877	31,874	32,145	44,687	36,657

Tabela 76 – 9º modelo complementar desenvolvido para resolução de 3 horas (período quente)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,747	0,454	0,351	0,303	0,306	0,324
R^2	0,724	0,421	0,210	0,299	0,291	0,166
Erro médio quadrático (m^2/s^2)	1,750	3,773	4,460	4,798	4,783	4,720
Raiz do erro médio quadrático (m/s)	1,323	1,942	2,112	2,191	2,187	2,172
Erro médio absoluto (m/s)	1,060	1,478	1,691	1,706	1,697	1,784
Erro percentual absoluto médio (%)	17,616	20,954	28,031	23,806	23,763	29,069

Tabela 77 – 9º modelo complementar desenvolvido para resolução de 3 horas (período frio)

Estatísticas	3 horas	6 horas	9 horas	12 horas	15 horas	18 horas
Nash-Sutcliffe	0,624	0,265	0,207	0,046	0,021	0,047
R^2	0,615	0,278	0,168	0,171	0,140	0,096
Erro médio quadrático (m^2/s^2)	2,443	4,799	5,202	6,266	6,378	6,166
Raiz do erro médio quadrático (m/s)	1,563	2,191	2,281	2,503	2,525	2,483
Erro médio absoluto (m/s)	1,237	1,737	1,834	1,933	1,948	2,005
Erro percentual absoluto médio (%)	22,277	28,194	33,302	31,727	32,506	36,902

ANEXO

TORRE

Posiciona o rotor em uma altura adequada para a captura do vento e o seu correto funcionamento, fornecendo suporte estrutural junto com a fundação para o equipamento (DUTRA, 2009). Usualmente é constituída em aço ou concreto, garantindo uma maior segurança na sustentação da nacelle em grandes alturas. Durante a determinação de seu *design*, procura-se evitar a vibração e a resultante fadiga. As principais configurações existentes são:

- Tubular: formada por seções cônicas metálicas e aparafusadas, que possibilitam sua sustentação por cabos tensores;
- Treliçada: necessita de uma menor quantidade de material em comparação à tubular, garantindo redução dos custos. Porém, o impacto visual é o grande empecilho por não se adotá-la nos aerogeradores modernos.

Ao determinar a altura da torre, devem-se considerar os seguintes aspectos: o custo por metro de altura, o custo da energia complementar que pode ser obtida e a variabilidade e disponibilidade do vento (DWIA, 2008).

NACELE

Sua cobertura é geralmente composta por fibra de vidro e sua função é de abrigar os componentes principais do aerogerador como a caixa de engrenagens, o gerador e todo o sistema de medição e de controle do vento incidente, assim como os motores para a rotação do sistema para um melhor posicionamento em relação ao vento. Protege-os de quaisquer intempéries, como chuva e radiação solar.




Figura 98 – Vista da nacela de um aerogerador
Fonte: Wien (2006)

PÁS

Estruturas encarregadas da interação com o vento, convertendo uma fração de sua energia cinética em energia rotacional no eixo do rotor. Devido às constantes vibrações, são consideradas as partes mais frágeis do aerogerador e são alvos de intensos estudos por meio de soluções em *design*, com o objetivo de evitar a fadiga prematura das estruturas (PATEL, 1999). Exibem diversas formas e configurações e podem ser compostas de variados materiais, como a madeira, que apresenta baixa massa específica e usualmente é utilizada na fabricação de pás com pequeno comprimento, e fibra de vidro reforçada com epóxi, leve e resistente à fadiga (CASTRO, 2007).

Existe uma grande diferença na concepção do *design* das pás de pequeno e grande comprimento. Enquanto que o primeiro caracteriza-se pela necessidade de pouca manutenção, o segundo caso busca aperfeiçoar o desempenho aerodinâmico para a captura máxima de energia (PATEL, 1999).

CAIXA DE ENGRENAGENS

Também denominada por caixa multiplicadora. Encontra-se entre o rotor e o gerador e aumenta a velocidade de rotação disposta pelo rotor, que geralmente encontra-se entre 20 e 150 rotações por minuto, tornando-a acessível ao funcionamento do gerador elétrico, especialmente os síncronos, que operam na faixa de 1.300 a 1.800 rotações por minuto. Recentemente, tem-se desenvolvido o conceito de “*direct drive*” como opção ao uso da caixa de engrenagens. Neste caso, os geradores de grandes dimensões atuam em baixa velocidade, possibilitando a conexão direta ao eixo principal.

ANEMÔMETRO E ANEMOSCÓPIO

Os dados dos ventos incidentes, como velocidade e direção, são obtidos através do anemômetro e do anemoscópio, respectivamente (BARROS; VARELLA, 2008).

FREIO

Utilizado em situações de emergência para parar o equipamento, sendo acionado por dispositivos elétricos, por exemplo.

MECANISMOS DE CONTROLE

Podem ser aerodinâmicos (posicionamento do rotor), eletrônicos (controle da carga) ou mecânicos (freio e velocidade). Supervisionam continuamente o aerogerador, visando à orientação do rotor, ao controle de carga e de velocidade e em casos de falha do equipamento, agem para minimizar os possíveis danos

(BARROS; VARELLA, 2008).

Os principais itens de controle, que limitam a extração da potência nominal, encontrados nos aerogeradores modernos são: controle pela variação do passo da pá e controle *stall*. O primeiro refere-se a um sistema de controle ativo que usualmente requer dados do gerador de potência. Sendo ultrapassada a potência nominal do equipamento devido à alta velocidade do vento incidente, as pás giram em torno do seu eixo, ou seja, alteram seu ângulo de passo, reduzindo o ângulo de ataque do fluxo de ar, as forças atuantes e a potência (DUTRA, 2009). Neste caso, o fluxo de ar é aderente à superfície da pá, conforme ilustrado na Figura 99, gerando sustentação e forças de arrasto.



Figura 99 – Fluxo de ar aderente à pá
Fonte: Custódio (2009)

Como vantagens, tem-se a possibilidade de potência nominal mesmo em situações de baixa massa específica do ar, maior geração de energia sob mesmas condições e redução da dimensão do freio. Por outro lado, o aerogerador torna-se mais passível às falhas devido à maior complexidade do sistema.




Figura 100 – Curva de potência típica de um aerogerador com controle de passo
Fonte: DEWI (2007)

O controle *stall* representa um sistema passivo que age conforme o vento incidente no aerogerador. Diferentemente do controle de passo, as pás não giram ao longo de seu eixo, sendo fixas em seu ângulo de passo. Em situações de velocidades de ventos superiores à nominal, o fluxo do ar é relativamente descolado da superfície da estrutura, conforme ilustrado na Figura 101. Com isto, há redução nas forças de sustentação e aumento nas de arrasto, agindo contra um aumento da potência do aerogerador. Tal sistema apresenta como vantagem uma menor necessidade de manutenção (DUTRA, 2001).



Figura 101 – Fluxo separado em torno da pá
Fonte: Custódio (2009)




Figura 102 – Curva de potência típica de um aerogerador com controle tipo *stall*
Fonte: DEWI (2007)

Atualmente, há o mecanismo conhecido por “*stall* ativo”, combinação do controle de passo e *stall*. Neste caso, as pás giram na mesma direção do controle *stall*, diferentemente do que ocorre no controle pela variação do passo normal. (DUTRA, 2007)

GERADOR

Transforma a energia mecânica de rotação em energia elétrica. Há várias alternativas de conjuntos motogeradores existentes, como de corrente contínua e de comutador de corrente alternada. Os tipos básicos utilizados, porém, são os assíncronos ou de indução e síncronos ou alternador.

Os geradores assíncronos apresentam custos gerais e de manutenção reduzidos e longa vida útil. Entretanto, apresentam problema na parcela reativa necessária para excitá-los (BARROS; VARELLA, 2008; CASTRO, 2007; WIEN, 2006).

Os geradores síncronos são eficientes e podem ser conectados diretamente à rede. Porém, para isto, é imprescindível que a velocidade de rotação seja constante, evitando problemas de instabilidade. Estes são utilizados principalmente em sistemas de energia de médio e grande porte.

AEROGERADORES DE VELOCIDADE CONSTANTE E VARIÁVEL

O aerogerador com velocidade constante tem o gerador conectado diretamente à rede elétrica e sua frequência define a rotação do gerador e da turbina. As máquinas utilizam geradores elétricos assíncronos ou de indução, conforme mostrado na Figura 103.

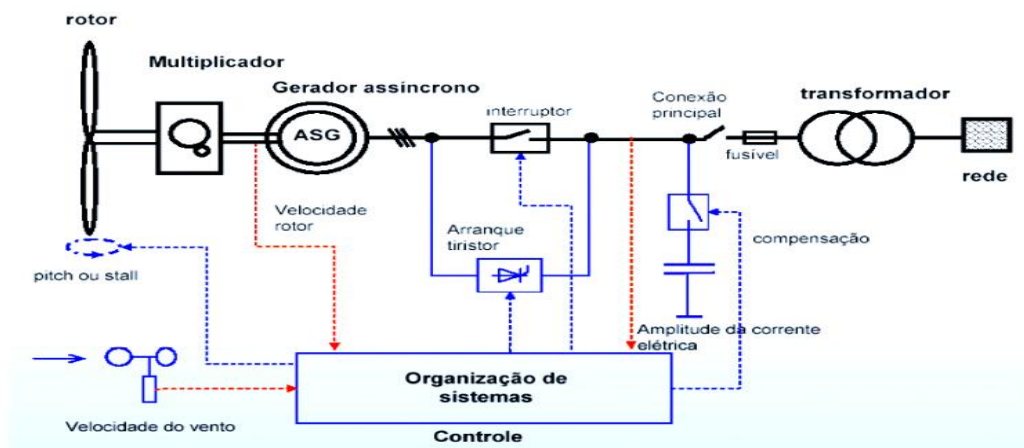


Figura 103 – Esquema de um gerador com velocidade constante
Fonte: DEWI (2005)

O aerogerador com velocidade variável, ilustrado na Figura 104, pode usar tanto os geradores assíncronos como os síncronos. Neste caso, há o desacoplamento da velocidade de rotação e do rotor do equipamento. Como a velocidade do vento é variável, para operação com razão de velocidade λ em que C_p seja máximo, é necessário que a velocidade do rotor varie conforme a do vento incidente, para um melhor aproveitamento dos recursos eólicos (CUSTÓDIO, 2002).

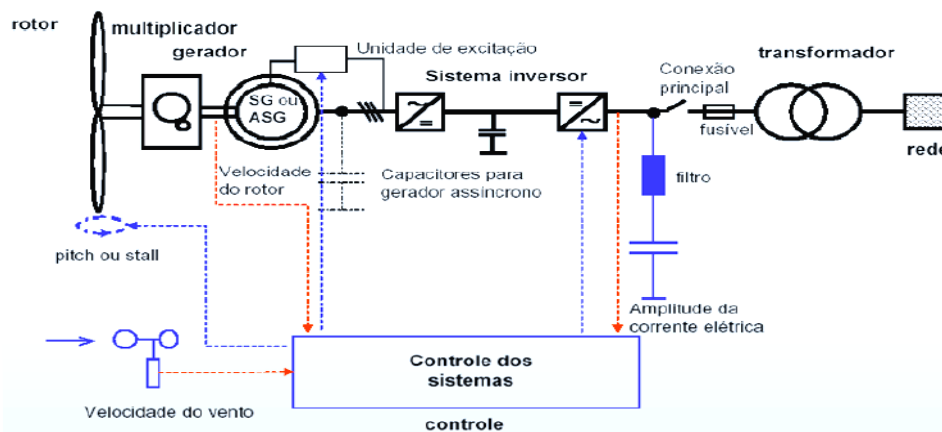


Figura 104 – Esquema de um gerador com velocidade variável
Fonte: DEWI (2005)

A Tabela 78 compara qualitativamente os atributos dos aerogeradores com velocidade fixa e variável.

Tabela 78 – Vantagens dos aerogeradores de velocidades fixa e variável

Velocidade fixa	Velocidade variável
Sistema elétrico simples e barato	Maior eficiência do rotor
Maior confiabilidade devido à menor quantidade de peças	Não há a necessidade de sistema de amortecimento
Menor custo	Não há problemas de sincronização