

Programa de Pós-Graduação em Engenharia Elétrica

DANIELA JARDIN ROSSI

**Previsão da Velocidade dos Ventos por Redes Neurais
Artificiais e ARIMA de Box & Jenkins**

DANIELA JARDIN ROSSI

**Previsão da Velocidade dos Ventos por Redes Neurais
Artificiais e ARIMA de Box & Jenkins**

Dissertação apresentada à Faculdade de Engenharia do Campus de Ilha Solteira - UNESP, como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica. Área de conhecimento: Automação.

Prof^a.Dr^a. Anna Diva Plasencia Lotufo
Orientadora.
Prof^a. Dr^a. Mara Lúcia Martins Lopes
Coorientadora

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

R831p Rossi, Daniela Jardim.
Previsão da velocidade dos ventos por redes neurais artificiais e arima de box & jenkins / Daniela Jardim Rossi. -- Ilha Solteira: [s.n.], 2014
76 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2014

Orientador: Anna Diva Plasencia Lotufo
Co-orientador: Mara Lúcia Martins Lopes
Inclui bibliografia

1. Previsão da velocidade dos ventos. 2. Arima. 3. Redes neurais artificiais.
4. Metodologia híbrida.



UNIVERSIDADE ESTADUAL PAULISTA
CAMPUS DE ILHA SOLTEIRA
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA

CERTIFICADO DE APROVAÇÃO

TÍTULO: Previsão da Velocidade dos Ventos por Redes Neurais Artificiais e ARIMA de Box & Jenkins

AUTORA: DANIELA JARDIN ROSSI

ORIENTADORA: Profa. Dra. ANNA DIVA PLASENCIA LOTUFO

CO-ORIENTADORA: Profa. Dra. MARA LÚCIA MARTINS LOPES

Aprovada como parte das exigências para obtenção do Título de Mestre em Engenharia Elétrica ,
Área: AUTOMAÇÃO, pela Comissão Examinadora:

Profa. Dra. ANNA DIVA PLASENCIA LOTUFO
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

Profa. Dra. LILIAN YULI ISODA
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira

Profa. Dra. ALESSANDRA BONATO ALTRAN
Universidade Federal do Mato Grosso do Sul - Campus de Três Lagoas

Data da realização: 07 de junho de 2013.

Dedico

Em primeiro lugar a Deus. Aos meus pais Aurea Jardim e Osvaldo Luiz Rossi, minha querida irmã Bruna Jardim Rossi. E a meu namorado Danilo de Carvalho Storti. Aos meus amigos

“Feliz aquele que transfere o que sabe e aprende o que ensina.”
Cora Coralina

Agradecimentos

Primeiramente a Deus pelo dom da vida, fé, força, luz e sabedoria que me oferecestes durante toda a caminhada para o alcance dos meus objetivos, mesmo nos momentos de dificuldades.

Agradeço a minha família, especialmente aos meus pais Aurea Jardim e Osvaldo Luiz Rossi pelo empenho, coragem e dedicação a realização dos meus sonhos. Minha mais que irmã, amiga Bruna Jardim Rossi pelo companheirismo incansável. Ao meu namorado Danilo de Carvalho Storti pela paciência, força, palavras de incentivo e consolação em cada tropeço. Pelo carinho e companheirismo sem igual.

A minha amiga irmã Elizângela pelo privilégio da amizade e parceria insubstituíveis.

Aos meus amigos de graduação, repúblicas que tornaram a caminhada mais fácil e alegre. Os companheiros do Laboratório de Sistemas Inteligentes. Aos amigos em especial Patrícia, Ana Cláudia, Rodrigo pelo apoio e ajuda imprescindível. Aos de longa data que sempre estiveram do meu lado Silvia, Ana Alice, Raiane, Juliana, Graziela, Elaine, Muriel pelo apoio necessário.

Agradeço, em especial, à professora e orientadora Anna Diva Plasencia Lotufo pela dedicação, paciência e carinho para que os objetivos fossem alcançados. À professora Mara Lúcia Martins Lopes pelo empenho dedicado a realização deste trabalho. A todos os professores que contribuíram a minha formação.

Ao CNPq pelo apoio financeiro.

RESUMO

Nesta pesquisa apresenta-se o desenvolvimento de uma metodologia híbrida utilizando a rede neural artificial *perceptron* multicamadas e os modelos estatísticos ARIMA com a abordagem de Box e Jenkins, com o objetivo de prever séries temporais de velocidade dos ventos. Os modelos estatísticos ARIMA realizam a previsão das séries de dados, que ainda conservam os padrões não lineares, juntamente com a rede MLP e o algoritmo de aprendizagem retropropagação que, através do erro de previsão obtido, desenvolvem um Modelo Híbrido aditivo para previsão de séries temporais. Os testes de validação foram realizados com dois bancos de dados de séries de velocidade dos ventos. No Teste 1 os dados foram fornecidos de um banco de dados agrometereológicos localizado na região de Ilha Solteira - SP, e no Teste 2 os dados são oriundos de um projeto desenvolvido pelo INPE (Instituto Nacional de Pesquisas Espaciais) que fornece dados anemométricos e solarimétricos em alturas de 25 e 50 metros, possuindo bases em várias regiões do Brasil. Analisando os erros médios quadráticos (MAPE) conclui-se que estão dentro dos limites encontrados na literatura.

Palavras-chave: Redes neurais artificiais. Metodologia de Box e Jenkins. Previsão de séries temporais. Modelo híbrido.

ABSTRACT

This work presents a hybrid methodology using MLP (multilayer perceptron) neural network and statistical ARIMA of Box and Jenkins to predict wind time series. The ARIMA models predict the time series data that are nonlinear, and the error obtained is introduced in the MLP by backpropagation training, forming the hybrid additive model. Tests were done with two data sets. Test 1 uses data from Ilha Solteira, SP region developed by an Agrometeorological project of UNESP Campus of Ilha Solteira. Test 2 the data are from a project developed by INPE (National Space Research Institute) which provides solar and wind data in adequate high to energy generation in several regions of Brazil. Results are analyzed by MAPE (mean absolute percent error) and are in accordance with those found in the specialized literature.

Keywords: Artificial neural network. Box & Jenkins methodology. Times series forecasting. Hybrid model.

LISTA DE FIGURAS

FIGURA 1- FILTRO LINEAR, COM ENTRADA AT, SAIDA ZT E FUNÇÃO DE TRANSFÊNCIA $\psi(B)$	26
FIGURA 2 - ESQUEMA DA METODOLOGIA DESENVOLVIDA	42
FIGURA 3 - CURVAS DO RESULTADO 1 COM O MAPE DE 3,7479 %	46
FIGURA 4 - CURVAS DO RESULTADO 2 COM O MAPE DE 4,5240 %	46
FIGURA 5 - CURVAS DO RESULTADO 3 COM O MAPE DE 5,9161%	47
FIGURA 6 - CURVAS DO RESULTADO 1 COM O MAPE DE 22,4838 %	50
FIGURA 7 - CURVAS DO RESULTADO 2 COM O MAPE DE 26,9939 %	51
FIGURA 8 - CURVAS DO RESULTADO 3 COM O MAPE DE 29,1994 %	51
FIGURA 9 - CURVAS DO RESULTADO 4 COM O MAPE DE 30,4435 %	52
FIGURA 10 - MOINHO DE VENTO EM HOLAMBRA-SP	61
FIGURA 11 - NEURÔNIOS BIOLÓGICOS	67
FIGURA 12 - MODELO DO NEURÔNIO DE MCCULLOCH AND PITTS.	68
FIGURA 13- (A) FUNÇÃO RELÉ, (B) FUNÇÃO LÓGICA THERESHOLD, (C) FUNÇÃO SIGMOIDAL	69
FIGURA 14 - ESTRUTURA DE UMA REDE NEURAL ARTIFICIAL	700

LISTA DE QUADRO

QUADRO 1 - QUADRO 1- CARACTERÍSTICAS DE FAC E FACP DE UM PROCESSO ARIMA (P, D, Q)	35
QUADRO 2 - CARACTERÍSTICAS DE FAC E FACP DE UM PROCESSO ARIMA (P, D, Q)	36
QUADRO 3 - CARACTERÍSTICAS DE FAC E FACP DE UM PROCESSO ARIMA (P, D, Q)	36
QUADRO 4 - MODELO ENCONTRADO MAIS ADEQUADO PARA A PREVISÃO	44
QUADRO 5 - TOPOLOGIA E PARÂMETROS DOS TESTES REALIZADOS	45
QUADRO 6 - O MAPE DO MODELO ARIMA, RNA E DO MODELO HÍBRIDO	47
QUADRO 7 - MODELO ARIMA ENCONTRADO MAIS ADEQUADO PARA A PREVISÃO	49
QUADRO 8 - TOPOLOGIA UTILIZADA NA REDE MLP NOS RESULTADOS ENCONTRADOS	50
QUADRO 9 - MAPE DA PREVISÃO DA VELOCIDADE DOS VENTOS PARA O MODELO ARIMA, RNA E MODELO HÍBRIDO, PARA O TESTE 2: PROJETO SONDA	52

LISTA DE ABREVIATURAS E SIGLAS

ADALINE	Adaptive linear element
AR	Autorregressivo
ARIMA	Autorregressivo integrado e de médias móveis
ARMA	Autorregressivos de médias móveis
ART	Adaptive resonance theory
ARTMAP	Adaptive resonance theory mapping
BP	Backpropagation
GMR	Generalized mapping regressor
INPE	Instituto nacional de pesquisas espaciais
kW	Kilo watts
M/S	Metros por segundo
MA	Médias móveis
MADALINE	Multiple adaptive linear element
MAPE	Mean absolute percentage error
MATLAB	Matrix laboratory
MC	Cadeia de Markov
MH	Modelo híbrido
MLP	Multilayer perceptron
MPE	Mean absolute error
MW	Mega watts
RBF	Função de base radial
RNA	Rede neural artificial
RPE	Previsão de erro recursivo
SARIMA	Autorregressivos integrados de médias móveis sazonais
SONDA	Sistema de organização nacional de dados ambientais
TWh/ano	Tera watts hora por ano

SUMÁRIO

1	INTRODUÇÃO	13
2	ESTADODA ARTE	16
3	SERIES TEMPORAIS	23
3.1	INTRODUÇÃO	23
3.2	MODELOS LINEARES ESTACIONÁRIOS	25
3.3	MODELOS AUTOREGRESSIVOS – AR (P)	27
3.3.1	<i>MODELOS DE MÉDIAS MÓVEIS DE ORDEM 1 – MA (1)</i>	29
3.4	MODELOS DE MEDIAS MÓVEIS – MA (Q)	29
3.4.1	<i>MODELOS DE MÉDIAS MÓVEIS DE ORDEM 1 – MA (1)</i>	30
3.5	MODELOS AUTOREGRESSIVOS E DE MÉDIAS MÓVEIS ARMA (P,Q)	31
3.5.1	<i>MODELOS AUTOREGRESSIVOS E DE MÉDIAS MÓVEIS DE ORDEM (1,1)</i>	31
3.6	MODELOS NÃO-ESTACIONÁRIOS	32
3.6.1	<i>MODELOS AUTOREGRESSIVOS INTEGRADOS E DE MÉDIAS MÓVEIS – ARIMA (p, d, q)</i>	32
3.6.2	<i>MODELOS SARIMA</i>	34
3.6.2.1	IDENTIFICAÇÃO DE MODELOS ARIMA	34
3.6.2.2	ESTIMAÇÃO DE MODELOS ARIMA	36
3.6.2.4	PREVISÃO COM MODELOS ARIMA	37
3.6.2.4.1	FORMAS BASICAS DE PREVISÃO	38
4	METODOLOGIA	39
5	TESTES E RESULTADOS	43
5.1	TESTE 1 AGROMETEREOLÓGICOS	43
5.1.1	<i>RESULTADOS: TESTE 1</i>	44
5.2	TESTE 2 – DADOS PROJETO SONDA (SISTEMA DE ORGANIZAÇÃO NACIONAL DE DADOS AMBIENTAIS)	48
5.2.1	<i>RESULTADOS: TESTE 2</i>	49
6	CONCLUSÕES	54

6.1	PRINCIPAIS CONCLUSÕES	54
6.2	SUGESTÕES TRABALHOS FUTUROS	55
	REFERÊNCIAS	56
	APÊNDICE A - TRABALHO PUBLICADO EM ANAIS DE CONGRESSO	60
	APÊNDICE B – EMBASAMENTO TEÓRICO	61
B.1	ENERGIA EÓLICA	61
B.1.1.1	<i>O RECURSO EÓLICO</i>	62
B.2	NO BRASIL E NO MUNDO	63
	APÊNDICE C – REDES NEURAIS ARTIFICIAIS	65
C.1	INTRODUÇÃO	65
C.2	REFLEXÃO HISTÓRIA	66
C.2.1	NEURÔNIO BIOLÓGICO	66
C.2.3	MODELO NEURÔNIO ARTIFICIAL	68
C.2.4	ESTRUTURA REDE NEURAL ARTIFICIAL	6969
C.2.5	TIPOS DE TREINAMENTO DAS REDES NEURAIS ARTIFICIAIS	71
C.2.6	ALGORITMO RETROPAGAÇÃO	711

1 INTRODUÇÃO

A previsão da série de dados é uma área que se encontra em grande desenvolvimento, em consequência da necessidade de modelos confiáveis e com grande precisão. Há algumas décadas, muitos estudos e pesquisas vêm sendo desenvolvidos na área de Rede Neurais Artificiais, visando criar novas tecnologias, métodos e produtos que proporcionem praticidade e agilidade na previsão das séries temporais (ZHANG, 2003). O objetivo desse estudo é automatizar os processos de previsão dessas séries, proporcionando rapidez e confiabilidade na execução de tarefas e, principalmente, na tomada de decisões.

Segundo Zhang (2003), a previsão de séries temporais é uma área relevante e essencial, na qual previsões de observações passadas (de uma mesma variável) são coletadas e analisadas, para desenvolver um modelo que descreve relações que não se situam claras e definidas. Muito esforço está sendo dedicado para o desenvolvimento e melhoria dos modelos de previsão de séries temporais.

Um modelo de previsões de séries temporais que deve ser destacado, devido a sua importância e utilidade é o modelo Autorregressivo Integrado e de Médias Móveis (ARIMA). Este tipo de modelo é muito popular por causa de suas propriedades estatísticas, bem como a conhecida metodologia de Box e Jenkins (BOX; JENKINS, 1976) no processo de construção do modelo. Os modelos ARIMA possuem características flexíveis, permitindo ajustes e adaptações em seus parâmetros, contribuindo para que diferentes tipos de séries temporais sejam representados, assumindo assim, uma estrutura de correlação linear entre os valores das séries temporais (MORETTIN; TOLOI, 2006).

As técnicas de Inteligência Artificial são muito utilizadas em problemas complexos. Recentemente as Redes Neurais Artificiais (RNAs) vêm se destacando na aplicação a problemas de previsão e, assim, têm sido amplamente estudadas para sua utilização em previsões de séries temporais, pois possui a grande vantagem de modelagem não linear.

Em busca de crescimento econômico, diversos países passaram a investir em estudos e pesquisas para o desenvolvimento de novas formas de geração de energia, as chamadas energias alternativas. Este novo tipo de energia deve possuir características que preserve o meio ambiente e que seja renovável. Entre os tipos de energia alternativa, destaca-se a energia eólica, provida dos ventos. A energia eólica tem sido usada, de forma significativa, em todo o mundo, a fim de obter um ideal para um futuro com eletricidade sem poluição. A crescente

demanda por energia, aliada à escassez de fontes de energias tradicionais, tem acelerado os esforços de investigação do mundo científico e industrial para uma exploração eficiente de fontes renováveis de energia (BECCALI, 2010).

Deste modo, o Brasil inicia a exploração desse meio de geração de energia e começa a desenvolver pesquisas para modelos de previsão viáveis. Nesta pesquisa, pretende abordar apenas a previsão do vento e não serão considerados os problemas pertinentes da inclusão das usinas de vento no sistema elétrico.

Por ser uma variável de caráter muito intermitente e aleatório, a série temporal da velocidade do vento, torna-se de difícil previsão. Com base na literatura especializada, foi verificado que um modelo híbrido é capaz de superar cada modelo de componente utilizado de forma isolada, pois utilizam vantagens de um e de outro. A combinação desses distintos modelos pode aumentar a chance de capturar padrões diferentes nos dados e melhorar o desempenho da previsão.

A precisão da previsão das velocidades dos ventos reduz os problemas de planejamento e geração de energia elétrica. Por isso, um modelo adequado deve ser empregado para a realização da previsão de séries temporais de velocidade dos ventos (ERNST, 2007).

O vento é considerado uma das variáveis de clima mais difíceis de ser prevista. Considera-se, então, a necessidade de administrar os recursos energéticos e os princípios da energia alternativa. Particularmente, a energia eólica exige a utilização de ferramentas avançadas para a previsão a curto prazo da velocidade do vento, ou seja, da produção eólica (AHLSTROM; 2005).

Várias abordagens são sugeridas, na literatura, para o problema de previsão de série de velocidade dos ventos. Vários métodos para prever as séries temporais têm sido relatados, bem como os métodos físicos e estatísticos. Os métodos físicos exigem uma variedade de considerações físicas, tais como orografia, rugosidade, temperatura e pressão. Esses métodos possuem vantagens na previsão a longo prazo. Já os métodos estatísticos usam o histórico dos dados do parque eólico, e sua vantagem é maior quando utilizado em previsões a curto prazo (ZHANG, 2003).

Diversos estudos empíricos sugerem a combinação de modelos diferentes, viabilizando, assim, o modelo híbrido, por uma melhoria na qualidade da previsão, no caso em questão tão imprevisível. Assim, na presente pesquisa tem-se por objetivo desenvolver

uma metodologia aditiva para a previsão de séries temporais da velocidade do vento, fazendo a combinação entre o modelo estatístico ARIMA (Autorregressivos Integrados e de Médias Móveis), utilizando a metodologia de Box e Jenkins (BOX; JENKINS, 1976), e a técnica de Inteligência Artificial com o uso das Redes Neurais Artificiais, do tipo *feedforward* (MLP) e seu algoritmo de aprendizagem retropropagação (*Backpropagation*) (HAYKIN, 1999). Neste trabalho, consideram-se os dados da série histórica de medição de velocidade do vento para duas determinadas regiões em especial.

A ideia inicial era realizar previsões de séries temporais de velocidade do vento na região de Ilha Solteira. Neste caso, usando-se os dados das séries de variáveis agrometereológicas oriundos de um projeto desenvolvido na Faculdade de Engenharia de Ilha Solteira-FEIS/UNESP, chamado Portal CLIMA, oferecido pela Área de Hidráulica e Irrigação do Programa de Graduação e Pós-Graduação do curso de Agronomia, obtidas pelas estações automáticas que compõem a Rede Agrometeorológica do Noroeste Paulista.

Visto que a metodologia realizada com os dados agrometereológicos mostrou resultados satisfatórios, partiu-se para testes com dados possuindo altura ideal das velocidades de ventos para geração de energia eólica procedentes do projeto SONDA (Sistema de Organização Nacional de Dados Ambientais), desenvolvido pelo INPE (Instituto Nacional de Pesquisas Espaciais) que disponibiliza dados solarimétricos e anemométricos com bases em várias regiões do Brasil. Pelo portal: www.sonda.ccst.inpe.br/clima.php, tem-se o acesso a todos os dados. Serão apresentados os testes e resultados obtidos da metodologia desenvolvida na pesquisa em questão.

2 ESTADODA ARTE

A pesquisa em previsão de séries temporais de velocidade dos ventos foi iniciada com o aprofundamento nos estudos envolvendo a rede *multilayer perceptron* (MLP), e de seu algoritmo de aprendizagem *backpropagation* (HAYKIN, 1999). Requereu-se, também, para a sua realização, o estudo da modelagem estatística empregada, o ARIMA, com a metodologia de destaque para previsões de séries temporais de Box e Jenkins (BOX; JENKIS, 1976).

Juntamente, foi realizada uma análise englobando o tema “energias renováveis” para o aprofundamento das diferentes técnicas e aspectos de previsão de séries temporais de velocidade dos ventos. Serão citadas, a seguir, algumas referências e sua metodologia correspondente que serviram para a construção do método híbrido proposto no trabalho:

Ahlstrom et al. (2005) propuseram um relato de como é importante o entendimento e gerenciamento do impacto da geração eólica nos sistemas de operação de energia. Recentes estudos e simulações fornecem um melhor entendimento desses impactos, e, assim, o progresso está sendo realizado no desenvolvimento de ferramentas e métodos para minimizar custos e aumentar a confiança nas operações, fornecendo altos níveis de produção para geração de energia eólica. Sistemas de aprendizagem computacional, tais como RNAs, mostram que é possível o fornecimento de previsão de entrega de energia eólica significativamente melhor que previsões clássicas baseadas em climatologia (valores históricos). Os autores propõem o uso de previsão de energia provida dos ventos, para que ocorra a integração nas salas de controle e nos sistemas de energia, facilitando dessa forma o custo efetivo da energia eólica.

Palomares–Salas et al. (2009) empregam a previsão de séries temporais envolvendo medições da velocidade dos ventos, no qual os resultados são comparados entre o desempenho da rede neural retropropagação com o algoritmo de aprendizagem Levenberg-Marquardt e o modelo estatístico ARIMA. Os dados foram adquiridos de uma unidade localizada no Sul da Andalusia, na Espanha. Apenas um simples modelo de previsão foi usado a fim de administrar as previsões. Os resultados mostram que o modelo ARIMA possui melhor desempenho que a rede MLP com algoritmo retropropagação para intervalos de tempo de previsão a curto prazo, pois o tempo de cálculo foi mais baixo.

Khashei e Bijari (2010) propuseram um novo modelo híbrido para previsão de séries temporais das taxas de câmbio de três conjuntos de dados diferentes, a fim de produzir um

modelo de previsão mais preciso do que o de redes neurais artificiais utilizados isoladamente. O modelo proposto é baseado na modelagem linear ARIMA, no qual faz uso da metodologia de Box e Jenkins, juntamente com as redes neurais que utilizam o algoritmo de aprendizagem retropropagação do erro. Resultados com três conjuntos de dados indicam que o modelo proposto pode ser uma forma eficaz, a fim de produzir um modelo mais preciso se comparado ao tradicional de redes neurais. Portanto, esse modelo híbrido pode ser utilizado como uma alternativa apropriada, especialmente, quando é necessária uma maior precisão na previsão.

Em Valenzuela et al. (2008) sugeriram um modelo híbrido, para vários tipos de séries temporais tais como: níveis do Lago Erie, manchas solares, estoque de leite condensado, dados Australianos mensais de produção de eletricidade, número de usuários conectados a um servidor de internet, poluição, séries caóticas de Mackey-Glass, entre outras. A metodologia proposta combina o modelo ARIMA tendo como vantagem seu uso relativamente fácil e redes neurais artificiais (RNAs) e seu poder computacional. Para obtenção da ordem da diferenciação da parte integrada do modelo ARIMA e as fundamentais partes AR e MA propõem-se o uso de um sistema especialista baseado em lógica *fuzzy*, cujas regras são ponderadas de uma forma automática, sem a intervenção de um especialista. Para resolver este problema, designou-se um algoritmo evolutivo no qual as funções *fitness*, condições de parada, *crossover*. Operadores de mutação têm sido especificamente escolhidos. O desempenho das simulações mostra que a sinergia dos diferentes paradigmas e técnicas usadas produzem excelentes resultados para a construção de sistemas inteligentes na previsão de séries temporais.

Zhang (2003) adotou uma metodologia híbrida para a previsão de séries temporais. O modelo linear ARIMA e o não-linear das RNAs são usados em conjunto, com o objetivo de capturar diferentes formas de relacionamento nos dados das séries temporais. Os resultados empíricos com três conjuntos de dados sugerem que o modelo híbrido é capaz de superar cada modelo de componente utilizado de forma isolada. Utilizando o método híbrido pode-se também reduzir a incerteza que geralmente ocorre em inferência estatística e em previsão de séries temporais. Além disso, ao ajustar primeiro os dados no modelo ARIMA, o problema de *overfitting*, que é fortemente relacionado aos modelos de rede neural, pode ser flexibilizado.

Cao, Ewing e Thompson (2012) realizaram uma análise comparativa da precisão da previsão de velocidade dos ventos a diversas alturas entre os modelos lineares ARIMA univariados e multivariados, assim como os modelos não-lineares das redes neurais, também univariados e multivariados. As alturas escolhidas, pelos autores, para as comparações foram

de 8, 13, 33, 70 e 160 pés. Os resultados indicam um MAPE superior no modelo ARIMA, consequentemente, considerando-se a modelagem não-linear das RNA, foram obtidos MAPES menores em todas as alturas quando comparadas com os do ARIMA.

Diferentes métodos de previsão da velocidade do vento foram realizados no trabalho de Chen e Lai (2011), sendo as margens de previsão 1, 2, 3 e 4 horas à frente nos meses de Maio a Outubro de 2005. Os dados foram extraídos de um parque eólico em Da Wu, China, sendo que, para todos os métodos, foi usada a medição dos valores da velocidade média horária, destacando que os anemômetros estavam localizados a 10 metros de altura. O comparativo da precisão das previsões foi realizado pelo modelo ARIMA e pelas Redes Neurais Artificiais. A rede neural utilizada foi *feedforward* multicamadas com o algoritmo de treinamento *backpropagation*. A série da velocidade dos ventos utilizada na pesquisa foi o verão de 2008.

López, Velo e Maseda (2008) realizaram estudo de um método de estimativa da velocidade dos ventos média anual, na região de Galícia, que está localizada a noroeste da Espanha, usando redes neurais artificiais. A região possui elevado potencial eólico por causa dos recursos geográficos. A configuração utilizada na rede foi composta por uma camada escondida possuindo quinze neurônios. O treinamento foi realizado pela rede MLP e seu algoritmo de aprendizagem Levenberg-Marquadt. Os dados coletados, da velocidade média dos ventos anuais, foram obtidos em intervalos de 10 minutos e a direção dos ventos nas estações-alvo. O método de simulação da rede neural proposta pelos autores fornece uma confiança estimada em 3 %.

Catalão, Pousinho e Mendes (2009) propuseram uma abordagem das redes neurais artificiais para previsão de energia eólica a curto prazo, em Portugal. O algoritmo de aprendizagem utilizado foi o retropropagação possuindo uma estrutura de três camadas. O MAPE obtido foi de 7,26 %, enquanto o tempo médio computacional foi de menos de 5 segundos. A proposta abordada apresentou um bom desempenho, segundo os autores.

Li, Shi e Zhou (2011) realizaram estudos utilizando uma metodologia de duas robustas técnicas para melhorar a precisão da previsão da velocidade eólica, com base no algoritmo de combinação Bayesiana e a utilização de três modelos de redes neurais artificiais. Ou seja, a rede *ADaptive LINear Element* (ADALINE), a rede retropropagação e uma função de base radial (RBF). Foi utilizada a média horária dos dados das velocidades dos ventos de dois lugares do estado americano de Dakota do Norte, para demonstrar a eficácia da abordagem proposta. Os resultados indicam que, enquanto o desempenho das redes neurais não é

consistente na previsão de uma hora à frente, o método de combinação Bayesiana sempre fornece resultados mais precisos. A metodologia proposta pelos autores resulta em uma abordagem unificada para lidar com a questão de seleção de modelo na previsão da velocidade dos ventos.

Em estudo de Li e Shi (2010) foi proposta a previsão da velocidade dos ventos em que foram realizadas as comparações de três diferentes redes neurais artificiais, para a previsão de uma hora à frente. As RNAs investigadas foram a ADALINE e a MLP com o treinamento pelo algoritmo de Levenberg-Marquadt, e a função de base radial (RBF). Os dados usados são os da média horária da velocidade dos ventos coletados de dois lugares de observações do estado de Dakota do Norte, nos EUA. Os resultados foram baseados em três métricas, isto é, no erro absoluto, no erro quadrático médio das raízes e no erro percentual absoluto médio. Eles observaram que, diferentes entradas, taxas de aprendizado e modelo de estrutura influenciam diretamente a precisão da previsão da velocidade dos ventos.

Blonbou (2011) propôs a adaptação de um esquema de previsão de energia eólica, de curto prazo, usando uma rede neural artificial *perceptron* com a arquitetura de três camadas juntamente com a Aprendizagem Adaptativa Bayesiana e uma aproximação do Método de Gauss. Uma avaliação deste esquema de previsão foi feita em dois testes. No primeiro, o indicador foi criado para estimar os valores de energia eólica para os seguintes horizontes de previsão: 5 min, 10 min e 15 min. E no segundo, os horizontes de previsão foram: 10 min, 20 min e 30 min. Observou-se que a previsão, através da rede neural funciona melhor do que o modelo persistente em ambos os casos. Além disso, o quadro Bayesiano permite também prever, para um nível especificado de probabilidade, o intervalo dentro do qual a energia gerada deve ser observada.

Kani e Ardehali (2011) utilizaram as redes neurais artificiais juntamente com a Cadeia de Markov (MC) para desenvolver um novo modelo (RNA-MC) para prever a velocidade dos ventos a curto prazo, utilizando a rede *multilayer perceptron* (MLP). Padrões de curto prazo em dados de velocidades dos ventos são capturados pelas RNAs e a longo prazo são considerados utilizando a abordagem MC. Foi notório que os erros de previsão e tempo de cálculo foram reduzidos. Os resultados mostram que o modelo RNA-MC proposto reduz os erros estatísticos MAPE e MPE tão bem como as incertezas.

Barbounis e Theocharis (2006) sugeriram a previsão da velocidade dos ventos e de energia provida do vento a longo prazo em fazendas eólicas usando redes neurais artificiais *multilayer* localmente recorrentes. Para lidar com a complexidade do processo e melhorar o

desempenho dos modelos é empregado para treinamento das RNAs localmente recorrentes o algoritmo Previsão de Erro Recursivo (RPE). Resultados experimentais exibiram aprimorado desempenho em termos de velocidade de convergência e de precisão das soluções atingidas, comparados com métodos convencionais baseados em gradiente. Tornou-se evidente que o modelo sugerido de previsão fornece melhor desempenho que modelos atmosféricos e de séries temporais.

Grassi e Vecchio (2010) propuseram a previsão da saída da velocidade dos ventos para geração de energia eólica por uma ferramenta muito útil. A previsão é realizada, através do algoritmo de aprendizagem retropropagação, usando uma rede neural de duas camadas. Os dados foram coletados durante três anos (Janeiro de 2005 - Dezembro de 2007) de uma fazenda eólica do sul da Itália. Os resultados simulados mostraram um bom ajuste dos valores medidos experimentalmente.

Faruk (2009) sugeriu a previsão de séries temporais da qualidade da água, através de uma abordagem híbrida entre o modelo ARIMA e redes neurais artificiais (RNA) para previsão de séries temporais usando observações de 108 meses de dados de qualidade de água, incluindo dados como a temperatura da água, boro, oxigênio dissolvido, durante os anos de 1996 a 2004, no Rio Menderes Buyuk, na Turquia. O estudo teve como metodologia o ARIMA de Box e Jenkins e a estrutura da rede é a *feedforward* juntamente com o algoritmo retropropagação. As previsões do modelo híbrido foram comparadas com as obtidas das séries temporais tradicionais do ARIMA e da RNA separadamente. Como consequência da capacidade de reconhecer os padrões lineares através do ARIMA e as características não-lineares pelas RNAs ficou demonstrado que, o modelo híbrido fornece melhor precisão que os métodos ARIMA e RNA para previsão da qualidade da água usados de forma isolada.

Flores, Tapia e Tapia G. (2005) previram a velocidade dos ventos em uma fazenda eólica usando redes neurais artificiais. A RNA baseou-se no algoritmo de aprendizagem retropropagação, cuja avaliação foi realizada com medição de dados reais de duas diferentes localizações. Em um primeiro momento, os dados foram coletados de uma área não muito ventosa e na segunda, de uma fazenda eólica localizada em Navarre (Norte da Espanha), que possui como características a alta velocidade dos ventos. Assim a previsão pôde ser estabelecida de modo a obter o máximo de benefícios econômicos para produtores e utilitários. Consequentemente, a geração de energia eólica passou a ser considerada como uma fonte de alimentação reserva para situações de consumo diferentes na rede elétrica e, em seguida, ser combinadas com outras fontes de energia tradicionais.

Beccali et al. (2010) utilizaram a rede neural auto-organizável a *Generalized Mapping Regressor* (GMR) para estimar a velocidade dos ventos na Ilha de Sicília, na Itália. Esta rede neural está acoplada com as técnicas de análises de dados exploratórios, para obter um mapeamento da distribuição espacial da velocidade dos ventos média em toda a região. Primeiramente, a superfície topográfica da ilha foi modelada usando duas diferentes técnicas neurais. Os resultados dos modelos matemáticos foram tomados como guia para a escolha do lugar de operações das fazendas eólicas, e mesmo sendo pequenos os montantes de monitoramento das áreas selecionadas é sempre aconselhável realizá-lo antes de começar um investimento econômico.

No trabalho de Bilgili, Sahin e Yasar (2007) foi proposta a previsão média mensal da velocidade dos ventos de algumas estações alvo, usando a média mensal da velocidade dos ventos de estações vizinhas, nas quais são indicadas como estações de referência. Os dados foram coletados de oito estações de medições do Serviço de Meteorologia do Estado Turco. O algoritmo de aprendizagem utilizado foi o *resilient backpropagation*. A vantagem desse modelo é que ele considera os dados das velocidades dos ventos das estações de referência nas avaliações. A velocidade dos ventos futura da estação alvo pode também ser prevista imediatamente e satisfatoriamente sem o uso de alguns detalhes topográficos ou outros dados meteorológicos.

Os trabalhos a seguir, serviram para um forte embasamento e construção da metodologia presente neste trabalho.

No trabalho de Cadenas e Rivera (2007) os autores previram a velocidade dos ventos na Costa Sul do Estado de Oaxaca, no México. Realizou-se a comparação de duas técnicas, o modelo estatístico ARIMA e uma rede neural artificial a *Adaptive Linear Element* (ADALINE) possuindo na sua estrutura três neurônios na camada de entrada e um na camada de saída. O modelo ARIMA sazonal apresentou uma melhor sensibilidade para o ajustamento e previsão da velocidade dos ventos. Mas de forma razoável, ambos os modelos desenvolvidos podem ser usados para previsão de energia mensal da estação de energia eólica de Oaxaca, para atender o Centro de Controle de Serviços de Eletricidade.

Cadenas e Rivera (2009) propuseram a previsão da velocidade dos ventos a curto prazo na região de La Venta, no estado de Oaxaca, no México, utilizando as redes neurais artificiais. Os dados foram coletados durante sete anos, através de uma estação de medições, na qual foram utilizadas diversas configurações de RNAs recorrendo ao final para o algoritmo retropropagação do erro. A geração e comparação através de medições do erro quadrado

médio e do erro absoluto médio garantiram o desempenho e a precisão dos modelos. O primeiro modelo gerado foi o de três camadas e sete neurônios; o segundo foi o de três camadas e seis neurônios; e o terceiro modelo gerado foi o de duas camadas e três neurônios. Apesar da recomendação de diversos autores pela utilização de um modelo com três camadas, o melhor modelo de treinamento e estágios de previsão foi o de duas camadas e três neurônios.

Em trabalho complementar, Cadenas e Rivera (2010) previram a velocidade dos ventos em três diferentes locais no México. Foi desenvolvida uma modelagem híbrida entre o modelo estatístico ARIMA e Redes Neurais Artificiais. Primeiramente foi realizada a previsão da velocidade dos ventos utilizando a modelagem matemática do ARIMA, pela sua facilidade em encontrar tendências lineares na série. Depois, utilizou-se o erro de saída do ARIMA que ainda conserva o comportamento não-linear, para realizar a previsão através da rede neural. Foram comparados através de várias medições estatísticas os erros e constatou-se uma maior precisão do modelo híbrido comparado com a previsão realizada pelo ARIMA e pela rede neural isoladamente.

3 SERIES TEMPORAIS

3.1 INTRODUÇÃO

Previsão de séries temporais é uma área importante em que observações passadas de uma mesma variável são coletadas e analisadas para desenvolver um modelo (BOX; JENKINS, 1976). O modelo é, então, usado para extrapolar séries temporais para o futuro. Esta abordagem de modelagem é particularmente útil quando pouco conhecimento está disponível sobre o processo de produção de dados, ou quando não há explicação satisfatória do modelo que relaciona a variável de previsão com outras variáveis. Ao longo das últimas décadas um esforço enorme tem sido dedicado para o desenvolvimento e melhoria dos modelos de séries temporais. Um dos modelos de séries temporais mais importantes e amplamente utilizados é o autorregressivo integrado de médias móveis (ARIMA).

Devido as suas propriedades estatísticas, o ARIMA possui uma popularidade muito grande, bem como a conhecida metodologia de Box e Jenkins nos processos de construção dos modelos. Embora os modelos ARIMA sejam bastante flexíveis, podem representar tipos diferentes de séries temporais, ou seja, autorregressivo puro (AR), médias móveis puro (MA), e a série combinada ARMA, no entanto sua principal limitação é a forma pré-assumida linear do modelo, isto é, uma estrutura de correlação linear assume-se entre os valores de séries temporais e, portanto, padrões não-lineares podem ser capturados pelo modelo ARIMA.

Segundo Morettin e Tolo (2006), uma série temporal é qualquer conjunto de observações ordenadas no tempo. A série é dita discreta se o conjunto de instantes de tempo for discreto (enumerável), já se for não enumerável, diz-se que a série é contínua. Generalizando, descreve-se uma série temporal como uma realização ou uma trajetória de um processo estocástico. Pode-se considerar um processo estocástico como sendo uma família de variáveis aleatórias $\{Z_t; t \in T\}$ que são definidas em um mesmo espaço de probabilidades.

Consideremos alguns exemplos de séries temporais:

- a) Consideração dos valores diários de poluição na cidade de São Paulo;
- b) Valores mensais de temperatura na cidade de Cananéia-SP;
- c) Os índices diários da Bolsa de Valores de São Paulo;
- d) A precipitação atmosférica anual na cidade de Fortaleza;

- e) O número médio anual de manchas do sol;
- f) O registro de marés no porto de Santos.

Assim uma série temporal $Z(t_1), \dots, Z(t_n)$, sendo observada nos instantes $t_1, \dots, t_n$, a análise pode ter por objetivo:

- a) A investigação do mecanismo gerador da série temporal;
- b) Realizar a previsão de valores futuros, que podem ser a curto, ou a longo prazo;
- c) Analisar o comportamento da série;
- d) Encontrar alguma periodicidade importante nos dados.

Tem-se que as séries temporais são estruturadas por quatro elementos:

1. Tendência: realiza a verificação do sentido de deslocamento da série ao longo de vários anos;

2. Ciclo: movimento ondulatório que ao longo de vários anos tende a ser periódico;

3. Sazonalidade: movimento ondulatório de curta duração, geralmente inferior a um ano, sendo associada na maioria dos casos a mudanças climáticas;

4. Erro ou Ruído Aleatório: engloba a variabilidade intrínseca dos dados.

É de fácil constatação que, a média $\mu(t)$ e a variância $V(t)$ de $Z(t)$ são consideradas constantes para todo $t \in T$, isto é:

$$\mu(t) = E [Z_t] = \mu, \quad (1)$$

no qual E é a esperança e

$$V(t) = \text{Var} [Z_t] = E [(Z_t - \mu)^2] = \sigma^2, \text{ sendo } \sigma \text{ é o desvio padrão.}$$

Denominamos função de autocovariância (facv), tratando-se da covariância entre Z_t e Z_{t+k} , como sendo,

$$\gamma_k = \text{Cov} [Z_t, Z_{t+k}] = E [(Z_t - \mu) (Z_{t+k} - \mu)], \text{ em que Cov = covariância.}$$

Temos que pela definição de γ_k , que $\gamma_0 = \text{Var} [Z_t] = \sigma^2$, e o processo sendo estacionário, $|\gamma_k| \rightarrow 0$, quando $k \rightarrow \infty$.

A função de autocorrelação (fac) ρ_k também é muito comum, podendo ser escrita na equação (2) como:

$$\rho_k = \frac{\text{Cov}[Z_t, Z_{t+k}]}{\sqrt{\text{Var}[Z_t]\text{Var}[Z_{t+k}]}} , \quad \text{para } k \in T. \quad (2)$$

Então, a variância $\sigma^2 = \gamma_0$, sempre que a série for estacionária, tanto se tratando do tempo $t+k$ como do tempo t . Então, tem-se,

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{\gamma_k}{\sigma^2} , \quad \text{para } k \in T. \quad (3)$$

Dentre os vários modelos existentes para se descrever o comportamento de uma série temporal, devem-se escolher critérios de comparação que sejam parcimoniosos, ou seja, modelos que contenham uma quantidade mínima de parâmetros e que nos deem previsões precisas. Pode-se dizer que uma escolha adequada dos modelos a serem utilizados é baseada em um ciclo iterativo da modelagem de Box e Jenkins (1976) nos seguintes passos:


1. Inicialmente, tem-se a fase de especificação, na qual uma classe geral de modelos vem a ser considerada para análise;
2. Na sequência, segue-se para a identificação de um modelo, baseando-se na análise de autocorrelações, autocorrelações parciais e outros critérios;
3. Na fase seguinte, a da estimação, os parâmetros dos modelos identificados são estimados;
4. Por último, a fase de verificação, na qual o modelo que se encontra já ajustado, faz-se a verificação, através de uma análise de resíduos. Então, devendo-se observar se o modelo é ou não adequado, no caso em questão, para previsão.

Caso o modelo não seja adequado, repete-se o ciclo, retornando-se à fase de identificação. Na maioria das vezes, é adequada a estimação e verificação de vários modelos ao invés de apenas um.

3.2 MODELOS LINEARES ESTACIONÁRIOS

De maneira intuitiva, um processo Z_t é estacionário se ele se desenvolve ao longo do tempo de maneira que a escolha de uma origem dos tempos não seja relevante. Os modelos lineares estacionários sugerem que a série temporal seja gerada através de um filtro linear (ou sistema linear), na qual a entrada é ruído branco, ver figura 1:

Figura 1 - Filtro Linear, com entrada a_t , saída Z_t e função de transferência $\psi(B)$.



Fonte: Morettin e Toloi (2006).

Para que a manipulação dos modelos seja facilitada, adota-se o operador de translação para o passado, que será denotado por B , e definido nas equações (3) e (4) por:

$$BZ_t = Z_{t-1} \quad (3)$$

$$B^m Z_t = Z_{t-m}. \quad (4)$$

Denomina-se função de transferência do filtro, a equação (5):

$$\begin{aligned} Z_t &= \mu + a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots \\ &= \mu + \psi(B) a_t, \end{aligned} \quad (5)$$

Em que μ é um parâmetro que determina o nível da série e a_t é o ruído.

Sempre lembrando que:

$$E(a_t) = 0, \forall t;$$

$$\text{Var}(a_t) = \sigma_a^2, \forall t;$$

$$E(a_t a_s) = 0, s \neq t.$$

Se a série de pesos $\psi_1, \psi_2, \dots$ for finita ou infinita e convergente, pode-se dizer que o filtro é estável e Z_t é estacionária. Tem-se, neste caso, μ como sendo a média do processo. Caso isto não aconteça, passa-se a considerar Z_t como sendo não-estacionária e μ passa a não ter um significado específico (MORETTIN; TOLOI, 2006).

Entretanto, para $j = 0$, tem-se a variância de Z_t como sendo:

$$\gamma_0 = \text{Var}(Z_t) = \sigma_a^2 \sum_{k=0}^{\infty} \psi_k^2 \quad (6)$$

Escreve-se a série $\tilde{Z}_t = Z_t - \mu$ como uma soma ponderada de valores passados mais um ruído a_t , isto é:

$$\tilde{Z}_t = \pi_1 \tilde{Z}_{t-1} + \pi_2 \tilde{Z}_{t-2} + \dots + a_t, \quad (7)$$

ou,

$$\tilde{Z}_t - \pi_1 \tilde{Z}_{t-1} - \pi_2 \tilde{Z}_{t-2} - \dots = a_t.$$

em que,

$$\pi(B) \tilde{Z}_t = a_t, \quad (8)$$

no qual $\pi(B) = 1 - \pi_1 B - \pi_2 B^2 - \dots$.

De (5) e (8) tem-se:

$$\pi(B) \psi(B) a_t = a_t, \quad (9)$$

assim:

$$\pi(B) = \psi^{-1}(B), \quad (10)$$

os quais podem ser usados para obtenção dos pesos ψ_k e vice e versa.

Um processo linear é estacionário, segundo Morettin e Toloi (2006), se a série $\psi(B)$ convergir para $|B| \leq 1$. Este mesmo processo será invertível, se $\pi(B)$ convergir para $|B| \leq 1$.

3.3 MODELOS AUTOREGRESSIVOS – AR (p)

Considerando a equação (8), em que $\pi_k = 0$, $k > p$, renomeando os pesos de π_k para ϕ_k , obtém-se um modelo autorregressivo de ordem p, que se denotará por AR (p)

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \phi_2 \tilde{Z}_{t-2} + \dots + \phi_p \tilde{Z}_{t-p} + a_t \quad (11)$$

Definindo o operador autorregressivo, de ordem p, como sendo:

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad (12)$$

Pode-se dizer então que:

$$\phi(B) \tilde{Z}_t = a_t. \quad (13)$$

Para que o processo Z_t seja estacionário, a série $\psi(B) = \phi^{-1}(B)$ tem de convergir. A série $\pi(B) = \phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ é finita, então, $\pi(B)$ é convergente para $|B| \leq 1$. Assim, as restrições sobre os parâmetros de um processo autorregressivo, para garantir a inversibilidade de Z_t , não existem.

Tratando-se de um processo autorregressivo, tem-se que para encontrar a função de autocorrelação, devem-se multiplicar todos os membros da equação (11) por Z_{t-k} e logo após calcular o valor esperado:

$$E[\tilde{Z}_t \tilde{Z}_{t-k}] = \phi_1 E[\tilde{Z}_{t-1} \tilde{Z}_{t-k}] + \phi_2 E[\tilde{Z}_{t-2} \tilde{Z}_{t-k}] + \dots + \phi_p E[\tilde{Z}_{t-p} \tilde{Z}_{t-k}] + E[a_t \tilde{Z}_{t-k}] \quad (14)$$

Tem-se que $E[a_t \tilde{Z}_{t-k}] = 0$, para $k > 0$, já que $\tilde{Z}_{t-k}$ envolve ruídos apenas até a_{t-k} , não correlacionados. Assim,

$$\gamma_k = \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2} + \dots + \phi_p \gamma_{k-p}, \quad k > 0 \quad (15)$$

Logo, dividindo-se ambos os membros dessa expressão por $\gamma_0 = \text{Var}[Z_t]$, obtém-se a função de autocorrelação:

$$\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + \dots + \phi_p \rho_{k-p}, \quad k > 0 \quad (16)$$

Uma função de autocorrelação (fac) de um processo AR (p) pode-se dizer, segundo Box e Jenkins (1976), que é uma mistura de exponenciais e senóides amortecidas.

Pode-se obter a variância do processo fazendo $k = 0$ na expressão (14), assim:

$$\text{Var}(\tilde{Z}_t) = \text{Var}(Z_t) = \gamma_0 = \phi_1 \gamma_1 + \dots + \phi_p \gamma_p. \quad (17)$$

Dividindo todos os membros por γ_0 , obtém-se:

$$1 = \phi_1 \rho_1 + \dots + \phi_p \rho_p + \frac{\sigma_a^2}{\rho_0}, \quad (18)$$

Logo:

$$\gamma_0 = \frac{\sigma_a^2}{1 - \phi_1 \rho_1 - \dots - \phi_p \rho_p}. \quad (19)$$

Os parâmetros autorregressivos $\phi_1, \dots, \phi_p$ podem ser escritos em termos de $\rho_1, \dots, \rho_p$. Substituindo $k = 1, 2, \dots, p$ na equação (16), obtém-se um sistema com p equações lineares, chamadas equações de Yule-Walker:

$$\begin{aligned} \rho_1 &= \phi_1 + \phi_2 \rho_1 + \dots + \phi_p \rho_{p-1} \\ \rho_2 &= \phi_1 \rho_1 + \phi_2 + \dots + \phi_p \rho_{p-2} \\ &\vdots \\ \rho_p &= \phi_1 \rho_{p-1} + \phi_2 \rho_{p-2} + \dots + \phi_p \end{aligned}$$

Na qual sua representação matricial é dada por:

$$P_p \phi = \rho_p,$$

Em que,

$$P_p = \begin{bmatrix} 1 & \rho_1 & \dots & \rho_{p-1} \\ \rho_1 & 1 & \dots & \rho_{p-2} \\ & \vdots & \ddots & \vdots \\ \rho_{p-1} & \rho_{p-2} & \dots & 1 \end{bmatrix}, \quad \phi = \begin{bmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_p \end{bmatrix} \quad \text{e} \quad \rho_p = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_p \end{bmatrix}.$$

Obtém-se então,

$$\Phi = P_p^{-1} \rho_p. \quad (20)$$

Ao utilizar a expressão (20), pode-se estimar os coeficientes $\phi_1, \dots, \phi_p$ ao fazer a substituição das funções de autocorrelação teóricas ρ_k por suas estimativas r_k .

3.3.1 *MODELOS DE MÉDIAS MÓVEIS DE ORDEM 1 – MA (1)*

O modelo AR (1) é dado por:

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + a_t \quad (21)$$

Ou seja,

$$\phi(B) \tilde{Z}_t = a_t, \quad (22)$$

cujo $\phi(B) = 1 - \phi_1(B)$.

O processo é estacionário se $-1 < \phi_1 < 1$. Pela equação (16), a função de autocorrelação de um processo AR (1) pode ser escrito da seguinte forma:

$$\rho_k = \phi_1 \rho_{k-1}, \quad k > 0. \quad (23)$$

Na qual a solução é:

$$\rho_k = \phi_1^k, \quad k \geq 0. \quad (24)$$

A variância de um processo AR (1) é dada por:

$$\gamma_0 = \frac{\sigma_a^2}{1 - \phi_1^2} \Rightarrow \gamma_0 = \frac{\sigma_a^2}{1 - \phi_1^2}. \quad (25)$$

3.4 *MODELOS DE MEDIAS MÓVEIS – MA (Q)*

Considerando a equação (12), na qual se tem $\psi_k = 0, k > q$, obtém-se o modelo de médias móveis de ordem q, denotado por MA (q). Assim, renomeando os pesos ψ_k para $-\theta_k$, tem-se:

$$Z_t = \mu + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (26)$$

Ou:

$$\tilde{Z}_t = Z_t - \mu = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t = \theta(B) a_t,$$

cujo $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ chama-se operador de médias móveis de ordem q .

Tem-se que $\psi(B) = \theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ é finita. Assim, não existe restrições sobre os parâmetros de um processo MA(q) que garanta a estacionariedade de Z_t .

Para um processo MA (q), a condição de inversibilidade é que $\pi(B) = \theta^{-1}(B)$ convirja para $|B| \leq 1$, ou seja, as raízes de $\theta(B) = 0$ devem permanecer fora do círculo unitário.

Tendo que:

$$E[a_t a_{t-k}] = \begin{cases} \sigma_a^2, & k = 0 \\ 0, & k \neq 0 \end{cases}$$

Obtém-se:

$$\gamma_0 = \text{Var}[Z_t] = (1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2) \sigma_a^2, \quad (27)$$

e

$$\gamma_k = \begin{cases} (-\theta_k \theta_1 + \theta_{k+1} + \dots + \theta_{q-k} \theta_q) \sigma_a^2, & k = 1, 2, \dots, q \\ 0, & k > q. \end{cases} \quad (28)$$

Logo, a função de autocorrelação (fac) de Z_t é dada por:

$$\rho_k = \begin{cases} \frac{-\theta_k \theta_1 + \theta_{k+1} + \dots + \theta_{q-k} \theta_q}{1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2}, & k = 1, 2, \dots, q \\ 0, & k > q. \end{cases} \quad (29)$$

Diferente do que se passa com um modelo AR(p), os atrasos maiores do que “ q ” da fac no modelo MA (q) se anulam.

3.4.1 MODELOS DE MÉDIAS MÓVEIS DE ORDEM 1 – MA (1)

O modelo MA (1) é representado pela equação (30) a seguir:

$$\tilde{Z}_t = a_t - \theta_1 a_{t-1} = \theta(B) a_t, \quad (30)$$

No qual $\theta(B) = 1 - \theta_1 B$. O processo é invertível se $-1 < \theta_1 < 1$. Tem-se que substituindo $q = 1$ na expressão (27), obtém-se a variância do processo:

$$\gamma_0 = (1 + \theta_1^2) \sigma_a^2.$$

Usando a equação (29), encontramos a função de autocorreção, para $k = 0$ na primeira equação e $k > 0$ na segunda:

$$\gamma_k = \begin{cases} -\frac{\theta_1}{1+\theta_1^2}; \\ 0. \end{cases}$$

3.5 MODELOS AUTOREGRESSIVOS E DE MÉDIAS MÓVEIS ARMA (P,Q)

Para que um modelo se torne mais econômico, consideremos simultaneamente termos autorregressivos e de médias móveis. Assim, surge uma classe de modelos mistos os autorregressivos e de médias móveis de ordem (p, q), denotado por ARMA (p, q), dado pela equação (31):

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \phi_2 \tilde{Z}_{t-2} + \dots + \phi_p \tilde{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}. \quad (31)$$

Ou seja,

$$\phi(B) \tilde{Z}_t = \theta(B) a_t,$$

no qual $\phi(B)$ e $\theta(B)$ são os operadores autorregressivos e de médias móveis, respectivamente.

Para um processo ARMA (p, q), as condições de estacionariedade e de inversibilidade são que as raízes de $\phi(B) = 0$ e de $\theta(B) = 0$ devem estar fora do círculo unitário.

3.5.1 *MODELOS AUTOREGRESSIVOS E DE MÉDIAS MÓVEIS DE ORDEM (1,1)*

O modelo ARMA (1,1) é dado pela equação (32):

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + a_t - \theta_1 a_{t-1}. \quad (32)$$

Equivalentemente,

$$\phi(B) \tilde{Z}_t = \theta(B) a_t,$$

no qual $\phi(B) = 1 - \phi_1 B$ e $\theta(B) = 1 - \theta_1 B$.

Pode-se dizer que o processo é estacionário se $-1 < \phi_1 < 1$ e inversível se $-1 < \theta_1 < 1$.

3.6 MODELOS NÃO-ESTACIONÁRIOS

Os modelos apresentados acima são adequados para séries estacionárias, isto é, aquela em que a média se mantém constante no tempo. Mas, em geral, as séries são não estacionárias, como por exemplo, as séries econômicas e de velocidade dos ventos.

3.6.1 *MODELOS AUTORREGRESSIVOS INTEGRADOS E DE MÉDIAS MÓVEIS – ARIMA (P, D, Q)*

Os Autorregressivos Integrados e de Médias Móveis (ARIMA), são modelos matemáticos que possuem por objetivo compreender o comportamento da correlação seriada ou autocorrelação entre os valores da série temporal, e com o embasamento nesse comportamento realizar previsões futuras. Se for bem modelada à estrutura da correlação fornecerá bons resultados de previsões.

Pode-se, segundo Morettin e Toloi (2006), dizer que os modelos ARIMA descrevem séries temporais não-estacionárias homogêneas, isto é, são séries que não evoluem em torno de uma média constante ao longo do tempo, mas podem ser diferenciadas d-vezes para tornarem-se estacionárias. Por exemplo, se uma série for diferenciada $d = 1$ vez, diz-se que a série é não-estacionária quanto ao nível. Assim, calcula-se apenas uma diferença. Já se forem realizadas duas diferenças para a série se tornar estacionária, ou seja, $d = 2$, a série é não-estacionária quanto a sua inclinação.

Se $W_t = \Delta^d Z_t$ for estacionária, pode-se representá-la através de um modelo ARMA (p, q), como descrito na equação (33) a seguir:

$$\phi(B) W_t = \theta(B) a_t \quad (33)$$

Para este caso, diz-se que Z_t é uma integral de W_t , pois se diferenciarmos Z_t (no sentido de diferenciações sucessivas) obtém-se W_t . Diz-se, ainda, que Z_t segue um modelo autorregressivo integrado e de médias móveis de ordem (p, d, q), que se denota por ARIMA (p, d, q), de acordo com a equação abaixo:

$$\phi(B) \Delta^d Z_t = \theta(B) a_t \quad (34)$$

Considerando-se W_t estacionária, então, todas as raízes de $\phi(B) = 0$ situam-se fora do círculo unitário.

Outra forma de escrever a expressão (34) é a seguinte:

$$\varphi(B) Z_t = \theta(B) a_t, \quad (35)$$

no qual:

$$\varphi(B) = \phi(B) \Delta^d = \phi(B) (1 - B)^d \quad (36)$$

é um operador autorregressivo não-estacionário, de ordem $p + d$, com d raízes sobre o círculo unitário e as p restantes fora do círculo.

Assim, o modelo ARIMA pode ser representado pela seguinte equação (37):

$$Z_t = \varphi_1 Z_{t-1} + \dots + \varphi_{p+d} Z_{t-p-d} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}, \quad (37)$$

que é chamada equação das diferenças, muito útil para o cálculo de previsões.

Se o intuito for calcular a variância dos erros de previsão, o melhor procedimento é estimar os modelos ARIMA na forma de choques aleatórios, isto é, em termos dos valores atuais e prévios de a_t , ou seja:

$$Z_t = a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots = \psi(B) a_t. \quad (38)$$

Tem-se também a forma invertida do modelo ARIMA, que expressa Z_t em termos dos seus valores prévios e do valor atual de a_t , ou seja,

$$Z_t = \pi_1 Z_{t-1} + \pi_2 Z_{t-2} + \dots + a_t. \quad (39)$$

O modelo ARIMA é uma generalização dos modelos anteriores:

ARIMA $(p, 0, 0) = \text{AR}(p)$;

ARIMA $(0, 0, q) = \text{MA}(q)$;

ARIMA $(p, 0, q) = \text{ARMA}(p, q)$.

3.6.2 *MODELOS SARIMA*

Na prática, raramente encontram-se processos estocásticos estacionários. Além disso, muitas vezes apresentam componentes sazonais. Sem hesitar, Box e Jenkins formularam seus modelos para séries temporais que possuem componentes sazonais, denominando-os por Autorregressivos Integrados de Médias Móveis Sazonais (SARIMA). O modelo mais usual pode ser dado pela equação (40) abaixo:

$$\phi(B)\Phi(B^S)\Delta_S^D\Delta^dZ_t = \theta(B)\Theta(B^S)a_t \quad (40)$$

em que:

$\phi(B)$: operador não-sazonal autorregressivo;

$\Phi(B^S)$: operador sazonal autorregressivo;

$\Delta_S^D = (1 - B^S)^D$: operador diferença sazonal de ordem D;

$\Delta^d = (1 - B)^d$: operador diferença não-sazonal de ordem d;

$\theta(B)$: operador não sazonal de médias móveis;

$\Theta(B^S)$: operador sazonal de médias móveis.

Um modelo que possui essa estrutura é chamado SARIMA (p, d, q) x (P, D, Q)_s, possuindo sazonalidade de período S. Ressaltando que o procedimento para obter os modelos identificados, estimados e para realizar as previsões seguem os mesmos passos do modelo ARIMA não-sazonal.

3.6.2.1 *IDENTIFICAÇÃO DE MODELOS ARIMA*

Uma das etapas mais críticas do ciclo iterativo do método de Box e Jenkins é a identificação do modelo ARIMA, pois pesquisadores diferentes podem identificar modelos variados. Na fase de identificação o principal objetivo é encontrar os valores p, d, e q dos modelos ARIMA (p, d, q) e também determinar estimativas preliminares dos parâmetros que vão ser úteis nas etapas que virão a seguir.

Primeiramente, é necessário verificar se existe a necessidade de transformar a série original, com a finalidade de estabilizar sua variância.

Segundo Morettin e Toloi (2006), a segunda etapa do processo de identificação consiste em diferenciar a série, que foi obtida na primeira etapa, até conseguir sua estacionariedade, isto é, até que o processo $W_t = \Delta^d Z_t$ se reduza a um ARMA (p, q). Uma forma de saber a quantidade de diferenças, d, necessárias para que o processo se torne estacionário consiste em observar quando a função de autocorrelação (fac) amostral de W_t decresce rapidamente para zero. Na prática, quase sempre $d = 0, 1$ ou 2 .

Já a terceira etapa do processo de identificação consiste em analisar o comportamento das autocorrelações e autocorrelações parciais estimadas. Através desta análise identifica-se o processo ARMA (p, q). Nas tabelas 1, 2 e 3 é apresentado um resumo das principais características dos modelos mais usados.

Quadro 1- Características de fac e facp de um processo ARIMA (p, d, q).

Ordem	(1, d, 0)	(0, d, 1)
Comportamento de ρ_k	Decai exponencialmente	Somente $\rho_1 \neq 0$
Comportamento de ϕ_{kk}	Somente $\phi_{11} \neq 0$	Decaimento exponencialmente dominante
Estimativas iniciais	$\phi_1 = \rho_1$	$\rho_1 = -\theta_1 / (1 + \theta_1^2)$
Região de admissibilidade	$-1 < \phi_1 < 1$	$-1 < \theta_1 < 1$

Fonte: Morettin e Toloi (2006).

Quadro2- Características de fac e facp de um processo ARIMA (p, d, q).

Ordem	(2, d, 0)	(0, d, 2)
Comportamento de ρ_k	Mistura de exponenciais ou ondas senoides amortecidas	Somente $\rho_1 \neq 0$ e $\rho_2 \neq 0$
Comportamento de ϕ_{kk}	$\phi_{11} \neq 0$ e $\phi_{22} \neq 0$	Dominada por uma mistura de exponenciais ou senoides amortecidas
Estimativas iniciais	$\begin{cases} \phi_1 = \frac{\rho_1(1 - \rho_2)}{1 - \rho_1^2} \\ \phi_2 = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2} \end{cases}$	$\rho_1 = -\frac{\theta_1(1 - \theta_2)}{1 + \theta_1^2 + \theta_2^2}$ $\rho_2 = -\frac{\theta_2}{1 + \theta_1^2 + \theta_2^2}$
Região de admissibilidade	$\begin{cases} -1 < \phi_2 < 1 \\ \phi_2 - \phi_1 < 1 \\ \phi_2 + \phi_1 < 1 \end{cases}$	$\begin{cases} -1 < \theta_2 < 1 \\ \theta_2 - \theta_1 < 1 \\ \theta_2 + \theta_1 < 1 \end{cases}$

Fonte: Morettin e Toloi (2006)

Quadro 3- Características de fac e facp de um processo ARIMA (p, d, q).

Ordem	(1, d, 1)
Comportamento de ρ_k	Decai exponencialmente depois o <i>lag</i> 1
Comportamento de ϕ_{kk}	Dominada por decaimento exponencial após o <i>lag</i> 1
Estimativas iniciais	$\rho_1 = \frac{(1 - \phi_1\theta_1)(\phi_1 - \theta_1)}{1 + \theta_1^2 - 2\phi_1\theta_1}$, $\rho_2 = \rho_1\phi_1$
Região de admissibilidade	$-1 < \phi_1 < 1$, $-1 < \theta_1 < 1$

Fonte: Morettin e Toloi (2006).

3.6.2.2 ESTIMAÇÃO DE MODELOS ARIMA

Depois da identificação de um modelo provisório a ser ajustado à série temporal, e conhecidos seus parâmetros, deve-se obter estimativas eficientes.

Supondo-se que um processo ARIMA (p, d, q) tenha vindo a gerar a série original $Z = (Z_1, Z_2, \dots, Z_N)$, assim, pode-se considerar d diferenças gerando uma série estacionária $W_t = (W_1, W_2, \dots, W_n)$ no qual, $W_t = \Delta^d Z_t$ e $n = N - d$. Logo, o problema de estimar um modelo ARIMA (p, d, q) é o mesmo que estimar os parâmetros do modelo ARMA (p, q) estacionário e inversível, que pode ser representado pela equação (41) descrita abaixo:

$$a_t = \tilde{W}_t - \phi_1 \tilde{W}_{t-1} - \phi_2 \tilde{W}_{t-2} - \dots - \phi_p \tilde{W}_{t-p} + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q} \quad (41)$$

Sendo,

$$W_t = \Delta^d Z_t,$$

$$\tilde{W}_t = W_t - \mu_\omega \text{ e}$$

$$\mu_\omega = E[W_t].$$

Se $d > 0$ considera-se $\mu_\omega = 0$, senão μ_ω deve ser mais um parâmetro a ser estimado.

3.6.2.3 DIAGNÓSTICO DOS MODELOS ARIMA

Depois das fases de identificação e estimação dos parâmetros, deve-se verificar se foram bem representados, para isso umas das técnicas é o superajustamento, no qual consiste em estimar um modelo com parâmetros extras e examinar se são significativos, logo após verificar se sua inclusão diminui significativamente a variância residual. Assim, é necessário analisar os resíduos do modelo ajustado. Se a equação (42):

$$\phi(B) W_t = \theta(B) a_t, \quad (42)$$

for verdadeira, com $W_t = \Delta^d Z_t$, então, os “erros verdadeiros” $a_t = \theta^{-1}(B)\phi(B)W_t$ serão ruído branco (MORETTIN; TOLOI, 2006).

3.6.2.4 PREVISÃO COM MODELOS ARIMA

Após os modelos já identificados, estimados e diagnosticados para que representem adequadamente os dados observados, utilizam-se os modelos agora para realizar previsões.

Supondo que se tenha as observações ..., Z_{t-2} , Z_{t-1} , Z_t , até o instante t , o atrativo de interesse é a previsão Z_{t+h} , $h \geq 1$. Diz-se, então, que t é a origem das previsões, h é o seu horizonte e denota-se $\hat{Z}_t(h)$ a previsão de Z_{t+h} .

Assume-se que $W_t = (1-B)^d Z_t$ é estacionário e inversível e que os parâmetros dos modelos são conhecidos. Assim, substituindo t por $t+h$ nas equações (37), (38) e (39), obtemos o modelo ARIMA (p, d, q) nas três formas básicas:

i. Forma de equação de diferenças

$$Z_{t+h} = \varphi_1 Z_{t+h-1} + \dots + \varphi_{p+d} Z_{t+h-p-d} - \theta_1 a_{t+h-1} - \dots - \theta_q a_{t+h-q} + a_{t+h}; \quad (43)$$

ii. Forma de choques aleatórios

$$Z_{t+h} = a_{t+h} + \psi_1 a_{t+h-1} + \psi_2 a_{t+h-2} + \dots = \sum_{j=0}^{\infty} \psi_j a_{t+h-j} = \sum_{j=-\infty}^{t+h} \psi_{t+h-j} a_j; \quad (44)$$

iii. Forma invertida

$$Z_{t+h} = \pi_1 Z_{t+h-1} + \pi_2 Z_{t+h-2} + \dots + a_{t+h}. \quad (45)$$

3.6.2.4.1 FORMAS BÁSICAS DE PREVISÃO

É possível expressar a previsão $\hat{Z}_t(h)$ nas três formas básicas do modelo ARIMA acima.

i. Previsão utilizando a equação das diferenças.

Tomando a esperança condicional em (43), tem-se:

$$\begin{aligned} \hat{Z}_t(h) = & \varphi_1(Z_{t+h-1}) + \dots + \varphi_{p+d}(Z_{t+h-p-d}) - \theta_1(a_{t+h-1}) - \dots - \theta_q(a_{t+h-q}) \\ & + (a_{t+h}), \text{ para } h \geq 1. \end{aligned}$$

ii. Previsão utilizando a forma de choques aleatórios.

Ao considerar a esperança condicional em (44), obtém-se:

$$\hat{Z}_t(h) = \psi_1(a_{t+h-1}) + \psi_2(a_{t+h-2}) + \dots + \psi_{h-1}(a_{t+1}) + \psi_h(a_t) + \dots + (a_{t+h}).$$

iii. Previsão utilizando a forma invertida.

Da mesma forma, considerando a esperança condicional em (45), tem-se:

$$\hat{Z}_t(h) = \sum_{j=1}^{\infty} \pi_j(Z_{t+h-j}) + (a_{t+h}).$$

4 METODOLOGIA

A Metodologia utilizada no desenvolvimento desta pesquisa é apresentada neste capítulo. O presente estudo pretende utilizar um modelo híbrido contendo Redes Neurais Artificiais com um da classe ARIMA de Box e Jenkins (1976), que possivelmente melhora a representatividade da série temporal de velocidade do vento para realizar previsões. O modelo estatístico ARIMA (Autorregressivos Integrados e de Médias Móveis), por sua vez, muito utilizado em previsões de séries temporais, no qual pode capturar padrões lineares, juntamente com a técnica de Inteligência Artificial, na qual recorrerá as Redes Neurais Artificiais, que com embasamento na literatura especializada, fará uso da rede *perceptron* multicamadas (MLP) e seu algoritmo de aprendizagem retropropagação (*backpropagation*) (CADENAS; RIVERA, 2007). Pretende-se abordar apenas a previsão para vento e, portanto, não serão considerados os problemas pertinentes da inclusão das usinas de vento na programação de geração e despacho econômico.

A metodologia, proposta no trabalho, foi idealizada e embasada nos principais resultados encontrados na literatura especializada. Posteriormente, realizou-se o aperfeiçoamento dos recursos de implementação, no *Software* MATLAB (*MATrix LABoratory*), que foi originalmente desenvolvido para prover um acesso amigável ao tratamento de vetores e matrizes. O MATLAB é um *software* interativo de alto desempenho voltado para o cálculo numérico da rede, dos parâmetros e variáveis a serem empregadas para que fosse viável treinar a rede, validar e, portanto, realizar uma previsão confiável e precisa. Por isso é importante que esses elementos e suas operações sejam bem entendidos para que se obtenha o seu melhor desempenho. Atualmente, o MATLAB dispõe de uma biblioteca bastante abrangente de funções matemáticas, geração de gráficos e manipulação de dados que auxiliam muito o trabalho do programador. E, ainda, possui uma vasta coleção de bibliotecas - denominadas *toolboxes* - para áreas específicas como no caso em questão de Inteligência Artificial (BEALE; HAGAN; DEMUTH, 1996).

Utilizou-se o *Software* R para a modelagem dos parâmetros, simulação e previsão dos dados do modelo estatístico ARIMA. O Ambiente R, ou somente R, torna-se, portanto, uma importante ferramenta na análise e na manipulação de dados, com testes paramétricos e não-paramétricos, modelagem linear e não-linear, análise de séries temporais, análise de sobrevivência, simulação e estatística espacial, entre outros. Além de apresentar facilidade na

elaboração de diversos tipos de gráficos, no qual o usuário tem pleno controle sobre o gráfico criado (VENABLES; SMITH, 2008).

No trabalho realizado por Zhang (2003), foi proposta uma abordagem híbrida para previsão de séries temporais, pois a ideia básica consistia que a combinação de modelos podem capturar padrões diferentes nos dados. Os modelos estatísticos são capazes de capturar os padrões lineares. Entretanto, por causa da sua flexível capacidade de modelagem não-linear, tem-se empregado fortemente o uso da RNAs para previsões de séries temporais.

Cadenas e Rivera (2010) propuseram um modelo híbrido baseado no ARIMA e nas Redes Neurais Artificiais para a previsão da velocidade dos ventos em três locais diferentes do México. Uma vez que o ARIMA é um modelo linear e assumindo que os erros gerados com a utilização dessa técnica ainda conservam os comportamentos não-lineares, a rede neural, por sua vez, é utilizada por ser um método não-linear, para modelar os erros e para obter tal comportamento. Assim, considerando os pressupostos supracitados, a observação dos dados reais com o modelo híbrido pode ser estimada segundo Cadenas e Rivera (2010) como:

$$Z_t = L_t + nL_t + e_t, \quad (46)$$

em que, Z_t é a observação real, L_t é a parte linear, nL_t é a parte não-linear e e_t é o erro final.

O primeiro termo da equação (46) é obtido dos modelos ARIMA, o segundo dos modelos da rede neural artificial e e_t são os erros finais de previsão. Os autores verificaram, por vários testes, que os erros de previsão são bem menos significativos no modelo híbrido, se comparados aos obtido usando o modelo ARIMA, para os locais onde foram realizadas as previsões. Assim, concluíram que o modelo híbrido proposto vem a ser uma melhor alternativa para a previsão da velocidade dos ventos, em que tendências lineares e não-lineares são encontradas.

Embasado nos resultados obtidos por Cadenas e Rivera (2010) e, de acordo com sua proposta de modelo Híbrido, elaborou-se a metodologia do presente trabalho.

Primeiramente, realizou-se a previsão da velocidade dos ventos utilizando a modelagem estatística do ARIMA, através do *Software R*. Como dados de entrada, empregou-se a própria série temporal. Em seguida, foram estimados os melhores parâmetros e, então, a

previsão foi obtida e reservada. Após esta etapa, lançou-se mão do *Software* MATLAB, para implementação de um programa com as *toolboxes* adequadas, para realizar as previsões e os demais cálculos necessários ao desenvolvimento da metodologia.

Através dessa previsão, conseguiu-se obter o erro da rede neural, que pode ser representado por meio da seguinte equação:

$$E_{(RNA)} = S_r - S_{p(RNA)}, \quad (47)$$

$E_{(RNA)}$ = erro obtido pela rede neural;

S_r = série real;

$S_{p(RNA)}$ = série prevista pela rede neural.

Possuindo o erro da rede neural e a previsão reservada – proveniente do ARIMA, procedeu-se o somatório do erro da rede neural com o resultado da previsão da série de velocidade dos ventos obtida através da modelagem estatística, como exibido em seguida:

$$MH = S_{p(ARIMA)} + E_{(RNA)} \quad (48)$$


MH = modelo híbrido ou previsão híbrida;

$S_{p(ARIMA)}$ = série prevista pelo ARIMA;

$E_{(RNA)}$ = erro obtido pela rede neural.

O Modelo Híbrido proposto pode ser descrito pelo esquema abaixo na figura 2:

Figura 2- Esquema da metodologia desenvolvida.



Fonte: Elaborado pelo próprio autor.

Apresentou-se a metodologia utilizada para o desenvolvimento do Modelo Híbrido para previsão de séries temporais de velocidade do vento, o qual utiliza a modelagem estatística ARIMA juntamente com a rede neural artificial MLP e seu algoritmo de treinamento *backpropagation*.

Através da aplicação desta metodologia, em dois conjuntos de dados para testes, serão comparados os resultados no próximo capítulo.

5 TESTES E RESULTADOS

Em seguida, são apresentados os testes e resultados obtidos por dois conjuntos de dados para a comparação da metodologia.

Com o objetivo de abordar a previsão da velocidade do vento, testou-se a capacidade das redes neurais para esta tarefa, uma vez que o uso dessa fonte alternativa renovável tende a crescer. As séries das velocidades dos ventos foram utilizadas para uma previsão de 24 vetores à frente, referentes a 24 dias (Teste 1 – Dados Agrometereológicos) e um dia, 24 horas à frente (Teste 2 – Dados Projeto SONDA).

5.1 TESTE 1 AGROMETEREOLÓGICOS

Primeiramente, vislumbrou-se a possibilidade de prever a série da velocidade do vento a curto prazo, com a ajuda de uma base de dados oriunda de um projeto desenvolvido na Faculdade de Engenharia de Ilha Solteira- FEIS/UNESP, chamado Portal CLIMA, disponibilizado pela Área de Hidráulica e Irrigação e que pode ser acessado pelo portal: www.clima.feis.unesp.br; na qual variáveis agrometereológicas obtidas pelas estações automáticas que compõem a Rede Agrometeorológica do Noroeste Paulista são disponibilizadas aos interessados. Os dados são obtidos a uma altura de 2 metros, diariamente, ideal para fins agrícolas.

Entre as variáveis oferecidas, tem-se a variação da velocidade máxima e a média diária. Optou-se pela velocidade máxima, pois ela mostrou-se, para os devidos fins, mais adequados. Empregaram-se os dados da série real de velocidade dos ventos do ano de 2011 para realizar a previsão do dia 1º ao 24º dia de Janeiro-2012. Os dados são apresentados em metros por segundo (m/s). No Portal Clima também são fornecidos vários dados climáticos como, por exemplo: temperatura, umidade relativa do ar, pressão atmosférica, direção do vento, entre outros que poderiam ajudar no treinamento na rede, mas decidiu-se não utilizar, pois em um primeiro momento de análise dos dados selecionados não foi constatada nenhuma correlação, que só seria possível através de uma análise estatística mais aprimorada. O objetivo da pesquisa é constatar a previsão e não a precisão do modelo em questão.

Baseado no trabalho de Cadenas e Rivera (2010) foi proposta uma configuração contendo duas camadas (entrada e saída). Os autores realizaram vários testes para verificar que essa configuração não seria a mais adequada. Na realização dos incontáveis testes que são

necessários para o treinamento da rede, a configuração de 3 camadas (entrada, intermediária ou escondida e saída) apresentou um desempenho mais adequado.

5.1.1 RESULTADOS: TESTE 1

Para a realização da estimação dos melhores parâmetros e da previsão da série temporal, pelo modelo estatístico ARIMA, foi utilizada como ferramenta o *Software R* e sua biblioteca *forecast* (VENABLES; SMITH; DEVELOPMENT CORE TEAM, 2008), especializada em previsão de séries temporais. O treinamento utilizado foi o gradiente descendente com momento (*traingda*). O modelo encontrado mais adequado é descrito abaixo:

$$\text{ARIMA}(2, 1, 1)(1, 0, 0)_{[12]}$$

Quadro 4- Modelo encontrado mais adequado para a previsão.

AR 1	AR 2	MA 1	SAR 1
0.0624	0.0679	-0.9355	-0.1055

Fonte: Elaborado pelo próprio autor.

Consequentemente, os parâmetros encontrados são:

$$\phi_1 = 0.0624, \phi_2 = 0.0679;$$

$$\theta_1 = -0.9355;$$

$$\Phi_1 = -0.1055.$$

Salienta-se que ocorreu uma variação considerável nas velocidades dos ventos a cada estação do ano. Considerando vários testes, concluíram que a sazonalidade igual a 90 proporcionou uma previsão mais confiável.

Assim, ajustando o modelo tem-se a equação (49):

$$\phi(B)\Phi(B^{12})\Delta_{12}^0\Delta^1Z_t = \theta(B)\Theta(B^{12})a_t, \quad (49)$$

Para a previsão, empregando-se as redes neurais, usou-se a rede MLP com o algoritmo de aprendizagem retropropagação do erro (*Backpropagation*). Através do *Software* MATLAB e suas *toolboxes* de redes neurais, foi possível a implementação da programação pertinente, para realizar a previsão da série temporal da velocidade dos ventos e calcular o erro entre a série real e a prevista pela RNA. Os resultados dos testes foram comparados através do MAPE (*Mean Absolute Percentage Error*) (BEALE; HAGAN; DEMUTH, 1996), isto é, através do Erro Percentual Médio Absoluto, entre os resultados da RNA, do modelo ARIMA e do modelo híbrido; e que pode ser calculado usando-se a seguinte equação:

$$MAPE = \frac{1}{N} \cdot \sum_{i=1}^N \left| \frac{r_i - p_i}{r_i} \right| \cdot 100, \quad (50)$$

Na qual, N é o número de dados da série real, r_i é a série real e p_i é a série prevista.

Os resultados de topologia e alguns dos parâmetros utilizados para os resultados obtidos estão descritos na tabela a seguir:


Quadro 5- Topologia e parâmetros dos testes realizados.

Resultados	Número de camadas	Número de neurônios por camada				Número de iterações	Treinamento
		entrada	intermediária		saída		
1	4	4	12	12		100.000	<i>traingda</i>
2	4	4	8	8	1	100.000	<i>traingda</i>
3	3	4	10	0	1	100.000	<i>traingda</i>

Fonte: Elaborado pelo próprio autor.


Nas figuras 3, 4 e 5 são ilustrados os gráficos das curvas da série real de velocidade dos ventos, das séries de previsão da RNA, do modelo ARIMA, e a série do Modelo Híbrido. Realizando a comparação da curva da série real com as da velocidade dos ventos da RNA e do modelo ARIMA, verifica-se que as previsões são menos eficientes em relação ao Modelo Híbrido desenvolvido para o período de 1 a 24 de janeiro-2012.

Figura 3- Curvas do resultado 1 com o MAPE de 3,7479 %.




Fonte: Elaborado pelo próprio autor.

Figura 4- Curvas do resultado 2 com o MAPE de 4,5240 %.



Fonte: Elaborado pelo próprio autor.

Figura 5- Curvas do resultado 3 com o MAPE de 5,9161%.



Fonte: Elaborado pelo próprio autor.

Na tabela 6 apresenta-se uma comparação entre os resultados de previsão da série de velocidade dos ventos. O confronto entre o modelo ARIMA, o de RNA, e o Modelo Híbrido pode ser avaliada através do MAPE. No modelo de RNA o MAPE variou entre 7,0535 % a 16,7174 %, sendo sua acurácia mostrada nos resultados das figuras 2 e 3 superior ao modelo ARIMA, apenas sendo inferior no resultado mostrado pela figura 4. Já o MAPE do ARIMA foi de 10,8414 %. Por sua vez o Modelo Híbrido apresentou um MAPE entre 3,7479 % a 5,9161 % obtendo assim, os melhores resultados.

Quadro 6- O MAPE do modelo ARIMA, RNA e do modelo Híbrido.

	MAPE %		
	ARIMA	RNA	Híbrido
Figura 1	10,8014	7,0535	3,7479
Figura 2	10,8014	6,2773	4,5240
Figura 3	10,8014	16,7174	5,9161

Fonte: Elaborado pelo próprio autor.

5.2 TESTE 2 – DADOS PROJETO SONDA (SISTEMA DE ORGANIZAÇÃO NACIONAL DE DADOS AMBIENTAIS)

Baseando-se nos resultados obtidos e visando outros horizontes, em alturas ideais para geração de energia eólica, buscou-se prever a série de velocidade dos ventos a altura de 25 a 50 metros. Para a realização da previsão foi utilizada as bases de dados disponibilizados pelo Projeto Sistema de Organização Nacional de Dados Ambientais (SONDA), projeto oriundo do Instituto Nacional de Pesquisas Espaciais (INPE). No intuito de implementar uma infraestrutura física e de recursos humanos, o Projeto SONDA, tem o objetivo de levantar e melhorar a base de dados anemométricos e solarimétricos no Brasil possuindo bases em várias regiões. O acesso a esta base de dados pode ser realizado no portal:

www.sonda.ccst.inpe.br/clima.

Com esse objetivo, foram pesquisadas várias metodologias para o tratamento dos dados até chegar à fase de implementação.

Em um primeiro teste, a base de dados da Estação de São Martinho da Serra – RS, para os meses de Janeiro e Fevereiro de 2011, foi utilizada. A velocidade disponibilizada pelo Projeto é dada de 10 em 10 minutos e em duas alturas ideais, a 25 metros e a 50 metros. Nesta pesquisa, utilizou-se a mais elevada. O intervalo de dados empregados foram os referentes aos meses de Janeiro e Fevereiro. Percebeu-se, no decorrer da implementação da rede MLP, que os dados provenientes do intervalo de 10 em 10 min, a velocidade oscilava muito em baixa amplitude e, assim, a rede não se estabilizava e acabava não convergindo.

Partiu-se, então, para outro tipo de tratamento dos dados, usando-se somente as horas cheias, ou seja, de hora em hora. O mesmo período foi selecionado para os testes, totalizando 1.421 dados, culminando com a previsão para o dia 1-março-2011, igual a 24 horas à frente. Notou-se o mesmo fenômeno, mas, diferentemente, uma oscilação em alta amplitude e, assim, a rede não estabilizava e fornecia uma previsão não confiável.

Com a finalidade de diminuir a oscilação dos dados, utilizou-se a média horaria e submeteu-se uma nova base de dados oriunda da cidade de São João do Cariri, no estado da Paraíba. O período utilizado foi do dia 21-Dezembro-2007 a 19-Março-2008, correspondente ao verão de 2008. Para o período de testes foi escolhida uma das estações do ano, pois se verifica que há uma mudança significativa na velocidade dos ventos em cada estação, que são compostas geralmente de 90 dias cada uma, gerando uma sazonalidade igual a 90, para

melhorar os parâmetros da previsão do modelo estatístico ARIMA. A previsão foi realizada para o dia 20-Março-2008.

5.2.1 RESULTADOS: TESTE 2

Para os resultados encontrados com os dados do Teste 2 foi realizada a mesma metodologia que no Teste 1. Para o ARIMA o melhor modelo identificado foi o descrito abaixo:

$$\text{ARIMA } (2, 1, 1)(2, 0, 0)_{[90]}$$

Quadro 7- Modelo ARIMA encontrado mais adequado para a previsão.

AR 1	AR 2	MA 1	SAR 1	SAR 2
0,0268	0,088	-0,9402	-0,0076	0,0556

Fonte: Elaborado pelo próprio autor.

Consequentemente, os parâmetros encontrados são:

$$\phi_1 = 0,0268, \quad \phi_2 = 0,088;$$

$$\theta_1 = -0,9402;$$

$$\Phi_1 = -0,0076, \quad \Phi_1 = 0,0556.$$

Assim, ajustando o modelo tem-se a equação (51) descrita abaixo:

$$(B)\Phi(B^{90})\Delta_{90}^0\Delta^1Z_t = \theta(B)\Theta(B^{90})a_t, \quad (51)$$


Na tabela 8 são mostrados alguns parâmetros da topologia utilizada para a implementação da rede MLP, com o algoritmo de aprendizagem retropropagação (BP) para a base de dados de São João do Cariri-PB.

Quadro 8- Topologia utilizada na rede MLP nos resultados encontrados.

Resultados	Número de camadas	Número de neurônios por camada			Número de iterações	Treinamento
		entrada	intermediária	saída		
1	4	4	8	8	1	<i>Traingda</i>
2	4	4	5	5	1	<i>Traingda</i>
3	4	4	8	8	1	<i>Traingda</i>
4	4	4	10	10	1	<i>Traingda</i>


Fonte: Elaborado pelo próprio autor.

Nos gráficos ilustrados nas Figura 6 a 9, é possível observar as curvas da série real, das séries das velocidades dos ventos da RNA, do ARIMA e do Modelo Híbrido. Comparando-se as curvas da série real com as demais, constatou-se que as curvas da RNA e do ARIMA se mostraram menos eficientes que o Modelo Híbrido para previsão da velocidade dos ventos para o dia 20 de março de 2011 (1º dia do Outono).

Figura 6- Curvas do resultado 1 com o MAPE de 22,4838 %.


Fonte: Elaborado pelo próprio autor.

Figura 7- Curvas do resultado 2 com o MAPE de 26,9939 %.




Fonte: Elaborado pelo próprio autor.

Figura 8- Curvas do resultado 3 com o MAPE de 29,1994 %.



Fonte: Elaborado pelo próprio autor.

Figura 9- Curvas do resultado 4 com o MAPE de 30,4435 %.

Fonte: Elaborado pelo próprio autor.

Os resultados da previsão da série de velocidade dos ventos podem ser comparados na Tabela 9. A verificação dos resultados entre o ARIMA, a RNA e Modelo Híbrido, pode ser avaliada pelo MAPE. Para a RNA, o MAPE variou entre 57,6545 % a 65,6143 %, sendo o menos preciso para a série de dados submetidos. O ARIMA, por sua vez, apresentou MAPE de 35,1708 %, com precisão superior a RNA. Já o Modelo Híbrido, representado por MAPE entre 22,4838 % e 30,4435 %, foi o que obteve melhor desempenho.

Quadro 9- MAPE da previsão da velocidade dos ventos, para o modelo ARIMA, RNA e Modelo Híbrido, para o Teste 2: Projeto SONDA.

	MAPE %		
	ARIMA	RNA	Híbrido
Figura 1	35,1708	57,6545	22,4838
Figura 2	35,1708	62,1647	26,9939
Figura 3	35,1708	64,3702	29,1994
Figura 4	35,1708	65,6143	30,4435

Fonte: Elaborado pelo próprio autor.

Embasado em outros trabalhos será realizado o comparativo dos resultados alcançados até o momento para o Teste 2- Dados Projeto SONDA.

No trabalho de Cao, Ewing e Thompson (2012) foi realizada uma análise comparativa da precisão de previsão de velocidade do vento a diversas alturas entre os modelos lineares uni e multivariáveis ARIMA e os modelos não-lineares uni e multivariáveis das redes neurais. Dentre as alturas utilizadas pelos autores (8, 13, 33, 70 e 160 pés) para as comparações, a que mais se aproxima da pesquisa em questão é a de 160 pés equivalentemente a 48,77 m. Os autores propõem amostras das velocidades de 30 minutos para uma previsão de 15 minutos a frente usaram amostras rolantes de 30 períodos. No trabalho em questão os modelos são ambos univariáveis. No trabalho de Cao, Ewing e Thompson (2012) os resultados indicam um MAPE de 35,7% no modelo estatístico ARIMA, contra 33,1 % no modelo redes neurais *feedforward* multicamadas. Concluíram que os modelos de RNA superou o estatístico ARIMA. Em um comparativo com este trabalho em que foi proposto um horizonte de previsão de 24 horas à frente e não minutos, obteve-se um MAPE de 35,1708 % no modelo linear estatístico ARIMA e um MAPE por volta de 62,455% no modelo não-linear das RNA. No entanto, o Modelo Híbrido proposto atingiu um MAPE de 22,4838 % no Teste 1, o que mostra resultados compatíveis com os da literatura.

Diferentes métodos de previsão da velocidade do vento foram realizados no trabalho de Chen (2011), sendo as margens de previsão 1, 2, 3 e 4 horas à frente nos meses de Maio a Outubro de 2005. Os dados foram extraídos de um parque eólico em Da Wu, China, sendo que para todos os métodos utilizou-se a medição dos valores da velocidade média horária, destacando que os anemômetros estavam localizados a 10 metros de altura. O comparativo de precisão das previsões foi realizado pelo modelo ARIMA e pelo de Redes Neurais Artificiais. A rede neural utilizada foi *feedforward* multicamadas com o algoritmo de treinamento *backpropagation*. A série da velocidade dos ventos utilizada na pesquisa foi o verão de 2008. Os autores apresentaram as comparações de desempenho mês a mês. Como a estação climática utilizada é a série da velocidade de ventos do verão, optou-se para comparação a previsão do mês de Maio que é o mês que a velocidade dos ventos mais se aproxima. O horizonte de previsão da pesquisa em questão é de 24 horas à frente. No trabalho de Chen e Lai, o maior horizonte é de 4 horas à frente, que corresponde a $\frac{1}{6}$ do horizonte previsto nesta pesquisa. No trabalho de Chen e Lai (2011) com 4 horas à frente de previsão resultou no modelo ARIMA obtendo um MAPE de 29,18%, no Modelo de RNA o MAPE foi de 25,87%. Já o Modelo Híbrido proposto nesta pesquisa o MAPE médio foi de 27,275 %. Conclui-se, então, que foram obtidos resultados compatíveis com os da literatura.

6 CONCLUSÕES

E, por fim, no Capítulo 7, as principais conclusões e sugestões para trabalhos futuros para complementar a metodologia desenvolvida nesta pesquisa.

6.1 PRINCIPAIS CONCLUSÕES

A previsão de séries temporais de velocidade dos ventos é uma área que se encontra em evolutivo aprimoramento, por causa da necessidade de desenvolver modelos confiáveis. Por ser uma fonte de energia alternativa, diversas metodologias estão sendo desenvolvidas e elaboradas para a melhoria da previsão. Diversos estudos sugerem a combinação de modelos a fim de se obter resultados mais satisfatórios.

No trabalho em questão, a metodologia híbrida foi desenvolvida com o intuito das redes neurais e sua capacidade de modelagem não-linear e o modelo matemático ARIMA combinados realizassem previsões adequadas.

Observa-se que as redes neurais artificiais, em especial com o treinamento por backpropagation utilizado nesta proposta de maneira isolada, não são adequadas para a série temporal de ventos, uma vez que não conseguem generalizar. Entretanto, ao serem usadas na metodologia híbrida, melhoram significativamente os resultados obtidos.

Inicialmente, considerando-se a base de Dados Agrometereológicos (Teste 1), pode-se destacar os resultados satisfatórios, com um MAPE muito sugestivo em todos os testes realizados em torno de 4,77%.

Os Dados do Projeto SONDA (Teste 2) proporcionaram um horizonte de possibilidades de metodologias que poderiam ter sido adotadas para a implementação do Modelo Híbrido desenvolvido. Com os dados das bases do Projeto SONDA sendo disponibilizados, em alturas viáveis, a obtenção de previsão de séries de velocidade dos ventos, almejando a geração de energia eólica, pode-se ter uma ideia real do alcance do método desenvolvido.

Os resultados do Teste 2 mostram um MAPE satisfatório em relação ao Modelo Híbrido, se comparados com os trabalhos desenvolvidos por (CAO; EWING; THOMPSON, 2012; CHEN; LAI, 2011).

Por fim, o intuito de promover a junção da Rede neural MLP e do modelo matemático ARIMA, para desenvolver um modelo híbrido capaz de prever adequadamente e prover bons comparativos para as séries temporais de velocidade dos ventos, obteve resultados satisfatórios que podem ser melhorados e complementados, sugerindo assim trabalhos futuros.

6.2 SUGESTÕES TRABALHOS FUTUROS

A metodologia desenvolvida obteve resultados satisfatórios, no entanto, pode ser complementada. Como foi observado que não existem muitos trabalhos no Brasil provenientes de Modelos Híbridos, sugere-se:

- a) Realizar as previsões com vários horizontes de previsão a curto prazo.
- b) Fazer os testes em todas as estações climáticas do ano e comparar com outros resultados.
- c) As previsões podem ser realizadas em testes mês a mês.
- d) Realizar previsões com informações complementares de outras estações de captura de dados.
- e) Introduzir outros parâmetros como entrada na rede (por exemplo, direção do vento, umidade e outros).

REFERÊNCIAS

AHLSTROM, M.; JONES, L.; ZAVADIL, L.; GRANT, W. The future of wind forecasting and utility operations. **IEEE Power and Energy Magazine**, New York, v. 3, n. 6, p. 57-64, 2005.

BARBOUNIS, T.G; THEOCHARIS, J.B. Locally recurrent neural networks for long-term wind speed and power prediction. **Neurocomputing**, Amsterdam, v. 69, n. 4-6, p. 466-496, 2006.

BEALE, M. H.; HAGAN, M. T.; DEMUTH, H. B. **Neural network toolbox™ 7: user's guide**. Natick: The Math Works, 1996. p.435.

BECCALI, M.; CIRRINCIONE, G.; MARVUGLIA, A.; SERPORTA, C. Estimation of wind velocity over a complex terrain using the Generalized Mapping Regressor. **Applied Energy**, London, v. 87, n. 3, p. 884-893, 2010.

BESSA, R.; MIRANDA, V.; GAMA, J. Improvement in wind power forecasting based on information entropy - related concepts. **IEEE Power and Energy Magazine**, New York, v.2, n1, p. 1-6, 2008.

BILGILI, M.; SAHIN, B.; YASAR, A. Application of artificial neural networks for the wind speed prediction of target station using reference stations data. **Renewable Energy**, Oxford, v. 32, n. 14, p. 2350-2360, 2007.

BLONBOU, R. Very short-term wind power forecasting with neural networks and adaptive Bayesian learning. **Renewable Energy**, Oxford, v. 36, n. 3, p. 1118-1124, 2011.

BOX, G. E.; JENKINS, G. M. **Time series analysis: forecasting and control**. San Francisco: Holden-Day, 1976. 575 p.

BRASIL. Instituto Nacional de Pesquisas Espaciais - INPE. **Rede SONDA**. sistema nacional de organização de dados ambientais. Brasília [s.n.], 2012. Disponível em: <<http://sonda.ccst.inpe.br/>> Acesso em: 10 jan. 2012.

CADENAS, E.; RIVERA, W. Wind speed forecasting in the South Coast of Oaxaca, Mexico. **Renewable Energy**, Oxford, v. 32, n.12, p. 2116-2128, 2007.

CADENAS, E; RIVERA, W. Short term wind speed forecasting in La Venta, Oaxaca, Mexico, using artificial neural networks. **Renewable Energy**, Oxford, v. 34, n. 1, p. 274-78, 2009.

CADENAS, E.; RIVERA, W. Wind speed forecasting in three different regions of Mexico, using a hybrid ARIMA e ANN model. **Renewable Energy**, Oxford, v. 35, n. 12, p. 2732-2738, 2010.

CAO, Q; EWING, B.T.; THOMPSON, M. A. Forecasting wind speed with recurrent neural networks. **European Journal of Operational Research**, Amsterdam, v. 221, n. 1, p. 148-154, 2012.

CASTRO, R. M. G. **Energias renováveis e produção descentralizada: introdução à energia eólica**. Lisboa: Universidade Técnica de Lisboa, 2008. Disponível em: <<http://www.troquedeenergia.com/Produtos/LogosDocumentos/IntroducaoAEnergiaEolica.pdf>>. Acesso em: 8 abr. 2012.

CATALÃO, J. P. S.; POUSINHO, H. M. I.; MENDES, V. M. F. An artificial neural network approach for short - term wind power forecasting in Portugal. **Engineering Intelligent Systems**, Leicester, v. 17, n. 1, p. 1-5, 2009.

CHEN, L.; LAI, X. Comparison between ARIMA and ANN models used in short-term wind speed forecasting. **IEEE Power and Energy Magazine**, New York, v 5, n.1, p. 25-28, 2011.

DALMAZ, A; PASSOS, J. C.; COLLE, S. Energia eólica para geração de eletricidade e a importância da previsão. **Revista ABCM – Engenharia**, Rio de Janeiro, v. 13, n. 1, p. 27-32, 2008.

EL-FOULY, T. H. M.; EL-SAADANY, E. F.; SALAMA, M. M. A. Improved grey predictor rolling models for wind power prediction. **IET Generation, Transmission Distribution**, Waterloo, v. 1, n. 6, p. 928-937, 2007.

ERNST, B.; OAKLEAF, B.; AHLSTROM, M. L.; LANGE, M.; MOEHRLEN, C.; LANGE, B.; FOCKEN, U.; ROHRIG, K. Predicting the wind. **IEEE Power & Energy Magazine**, New York, v. 5, n. 6, p. 78-89, 2007.

FARUK, D. O. A hybrid neural network and ARIMA model for water quality time series prediction. **Engineering Applications of Artificial Intelligence**, Oxford, v. 23, n. 4, p. 586-594, 2009.

FLORES, P.; TAPIA, A., TAPIA, G. Application of a control algorithm for wind speed prediction and active power generation. **Renewable Energy**, Oxford, v. 30, n. 4, p. 523-536, 2005.

GRASSI, G.; VECCHIO, P. Wind energy prediction using a two-hidden layer neural network. **Communications in Nonlinear Science and Numerical Simulation**. Amsterdam, v. 15, n. 9, p. 2262-2266, 2010.

HAYKIN, S. **Neural networks: a comprehensive foundation**. 2. ed. New Jersey: Prentice Hall, 1999. 842 p.

JURSA, R.; ROHRIG, K. Short-term wind power forecasting using evolutionary algorithms for the automated specification of artificial intelligence models. **International Journal of Forecast**, Amsterdam, v. 24, n.4, p. 694-709, 2008.

KANI, S. A. P.; ARDEHALI, M. M. Very short-term wind speed prediction: a new artificial neural network-Markov chain model. **Expert Systems with Applications**, New York, v. 52, n.1, p. 738-745, 2011.

KARTALOPOULOS, S. V. **Understanding neural networks and fuzzy logic: basic concepts and applications**. New York: Wiley, 1996. 205 p.

KHASHEI, M.; BIJARI, M. An artificial neural network (p, d, q) model for time series forecasting. **Expert Systems with Applications**, New York, v. 37, n. 1, p. 479-489, 2010.

KOHONEN, T. An adaptive associative memory principle. **IEEE Transmission on Computers**, New York, v. C-23, n. 4, p. 444-445, 1974.

KROSE, B.; SMAGT, P. V. **An introduction to neural networks**. 8. ed. Amsterdam: University of Amsterdam, 1996. 135 p.

LI, G.; SHI, J. On comparing three artificial neural networks for wind speed forecasting. **Applied Energy**, London, v. 87, n. 7, p. 2313-2320, 2010.

LI, G.; SHI, J.; ZHOU, J. Bayesian adaptive combination of short-term wind speed forecasts from neural network models. **Renewable Energy**, Oxford, v. 36, p. 352-359, 2011.

LÓPEZ, P.; VELO, R.; MASEDA, F. Effect of direction on wind speed estimation in complex terrain using neural networks. **Renewable Energy**, Oxford, v. 33, n. 10, p. 2266-2272, 2008.

LOPES, M. L. M. **Desenvolvimento de redes neurais para previsão de carga elétricas em sistemas de energia elétrica**. 2005. 169 f. Tese (Doutorado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2005.

MA, L.; SHIYAN, L.; CHUANWEN, J.; HONGLING, L.; YAN, Z. A review on the forecasting of wind speed and generated power. **Renewable Energy**, Oxford, v. 13, n. 4, p. 915-920, 2009.

MCCULLOCH, W.; PITTS, W. A. A logical calculus of the ideas imminent innervous activity. **Bulletin of Mathematical Biophysics**, New York, v. 5, n. 4, p. 115-133, 1943.

MINSKY, M.; PAPERT, S. **Perceptrons: an introduction to computational geometry** Cambridge: MIT Press, 1969. 308 p.

MOHANDES, M.; HALAWANI, T.; REHMAN, S.; HUSSAIN, A. support vector machines for wind speed prediction. **Renewable Energy**, Oxford, v. 29, n. 6, p. 939-947, 2004.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. 2. ed. São Paulo: Edgard Blücher, 2006. 538 p.

PALOMARES-SALAS, J. C.; LA ROSA, J. J. G.; RAMIRO, J. G.; MELGAR, J.; AGÜERA, A.; MORENO, A. ARIMA vs. neural networks for wind speed forecasting. **IEEE Power and Energy Magazine**, Hong Kong, p. 129-133, 2009.

POTTER, C.W.; NEGNEVITSKY, W. Very short-term wind forecasting for Tasmanian power generation. **IEEE Transactions Power Systems**, Montreal, v. 21, n. 2, p. 965-972, 2006.

RAMIREZ-ROSADO, I. J.; FERNANDEZ-JIMENEZ, L. A.; MONTEIRO, C.; SOUSA, J.; BESSA, R. Comparison of two new short- term wind power forecasting systems. **Renewable Energy**, Oxford, n. 7, v. 34, p. 1848-1854, 2009.

ROMERO, T. **Ventos ignorados**. São Paulo: FAPESP, 2008. Disponível em: <<http://agencia.fapesp.br/9886>>. Acesso em: 23 fev. 2012.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, Washington, v. 65, n. 6, p. 386-408, 1958.

SAWYER, S.; RAVE, K. The global status of wind power in 2009. **Global Wind Report: annual market update 2009**, Bruxelas, v. 1, n. 6, p. 1-68, 2010.

SAWYER, S.; RAVE, K. The global status of wind power in 2011. **Global Wind Report: annual market update 2011**, Bruxelas, v. 1, n. 6, p. 1-66, 2012.

SIDERATOS, G.; HATZIARGYRIOU, N.D. An advanced statistical method for wind power forecasting. **IEEE Transactions on Power Systems**, New York, v. 22, n. 1, p. 258-265, 2007.

VALENZUELA, O.; ROJAS, I.; ROJAS, F.; POMARES, H.; HERRERA, L. J.; GUILLEN, A.; MARQUEZ, L.; PASADAS, M. Hybridization of intelligent techniques and ARIMA models for time series prediction. **Fuzzy Sets and Systems**, Amsterdam, v. 159, n. 7, p. 821-845, 2008.

VENABLES, W. N.; SMITH, D. M. R. **Development core team**: an introduction to R. [S. l.]: John Mark Ockerbloom, 2008. Disponível em: <<http://onlinebooks.library.upenn.edu/webbin/book/lookupname?key=R%20Development%20Core%20Team>>. Acesso em: 15 out. 2011.

VILLALBA, S. A.; BEL, C. A. Hybrid demand model for load estimation and short term load forecasting in distribution electric systems. **IEEE Transactions on Power Delivery**, New York, v. 15, n. 2, p. 764-769, 2000.

WASSERMAN, P. D. **Neural computing**: theory and practice. New York: Van Nostrand Reinhold, 1989. 230 p.

WERBOS, P. J. **Beyond regression**: new tools for prediction and analysis in the behavioral sciences. 1975. 906 f. Thesis (Doctor) - Harvard University, Boston, 1974.

WIDROW, B.; LEHR, M. A. 30 years of adaptive neural networks: perceptron, madaline, and backpropagation. **Proceedings of the IEEE**, New York, v. 78, n. 9, p. 1415-1442, 1990.

ZHANG, G. P. Time series forecasting using a hybrid ARIMA and neural network model. **Neurocomputing**, Amsterdam, v. 50, n.1, p. 159-175, 2003.

APÊNDICE A - TRABALHO PUBLICADO EM ANAIS DE CONGRESSO

ROSSI, Daniela Jardim; LOTUFO, Anna Diva Plasencia; LOPES, Mara Lúcia Martins. Previsão de Velocidade dos Ventos por Redes Neurais Artificiais e ARIMA de Box & Jenkins. In: CONGRESSO DE MATEMÁTICA APLICADA E COMPUTACIONAL – SUDESTE, 2., 2013, Bauru. *Congresso...*. Bauru:[s.n], 2013. p. 1-5.

APÊNDICE B – EMBASAMENTO TEÓRICO

No Apêndice A.1, é apresentada, brevemente, a importância da energia eólica no Brasil e no Mundo. No Apêndice A.2, são apresentados os conceitos teóricos da rede neural que é utilizada juntamente a seu algoritmo de treinamento.

B.1 ENERGIA EÓLICA

A energia provida dos ventos vem sendo utilizada para trabalho a milhares de anos, como, por exemplo, com a utilização dos moinhos de vento para moagem de grãos, movimentar embarcações, para bombear água, fazer serrarias se movimentar e outros usos afins. Mas foi no final do século XIX que começou a utilização do vento para geração de energia elétrica com a criação da primeira turbina eólica, inventada no ano de 1888 por Charles F. Brush (1849-1929) (DALMAZ; PASSOS; COLLE, 2008). Na figura 9 a seguir temos um moinho de vento estilo Holandês:

Figura 10- Moinho de vento em Holambra-SP.



Fonte: Elaborado pelo próprio autor.

No período da Segunda Guerra Mundial, os esforços foram voltados para a evolução dos aerogeradores com o intuito de poupar combustíveis fósseis, mas passada a guerra caíra no esquecimento. No entanto, nas próximas décadas o interesse volta a tomar conta de vários países como Estados Unidos, Alemanha, Dinamarca, França, Inglaterra entre outros e, conseqüentemente, de maneira muito feroz, o crescimento por essa inovadora tecnologia vem se dando em todo o mundo (DALMAZ; PASSOS; COLLE, 2008). Segundo Castro (2008), destaca-se, também o avanço da potência das turbinas eólicas, que por volta da década de 80 possuíam um potencial que variava de 100 a 500 kW. Em meados de 1990 ficava na faixa de 1000 kW. Hoje em dia, a potência média varia em torno de 2 MW por turbina geradora. Atualmente, existem dois tipos de turbinas eólicas: eixo vertical e eixo horizontal.

B.1.1.1 O RECURSO EÓLICO

Atualmente, a energia eólica é uma alternativa importantíssima para complementar o potencial das usinas hidrelétricas, tendo em que a água é um recurso cada vez mais escasso e que requer a utilização de seu uso de forma consciente. Assim, acaba tornando-se vital o investimento em outras tecnologias. Dentre as várias vantagens, pode-se destacar o desenvolvimento em regiões menos favorecidas e remotas, pois o lugar onde se monta um parque eólico pode ser utilizado para outras atividades como, por exemplo, agricultura e pecuária. Além disso, os aerogeradores não necessitam de nenhum abastecimento. Apenas requerem uma manutenção, que por sinal, é bem relevante em termos de tempo, isto porque é realizada em geral semestralmente. Mas ainda não é muito viável financeiramente, pois esta implantação e manutenção efetivamente requer um alto custo (CASTRO, 2008).

Cada vez mais a energia “verde”, assim apelidada, está vinculada aos sistemas de serviço público, gerando, fornecendo e distribuindo eletricidade, tornando-se essencial compreender e gerir o impacto da geração dos ventos nos sistemas de operações. Por causa do crescimento industrial e comercial desordenado tem-se o aumento de gases poluentes, o que acaba ocasionando também problemas enormes para o meio ambiente. Assim, para que se torne viável e seguro o fornecimento de energia, o seu potencial deve ser previsto o suficiente para suprir a demanda (DALMAZ; PASSOS; COLLE, 2008).

Como a superfície da Terra não é aquecida uniformemente, diferenças de pressão ocorrem na atmosfera e o fluxo de ar tenta equilibrá-los, fazendo o movimento de uma importante massa de ar, o vento. A natureza do fornecimento de combustível distingue geração de energia eólica de meios mais tradicionais de produção de energia elétrica. A saída

de eletricidade de uma turbina eólica depende da velocidade do vento passando sobre as pás das turbinas eólicas. Essa corrente de ar, em movimento, varia em uma ampla gama de tempo, de escalas de segundos a horas, dias e estações do ano. Padrões climáticos locais e regionais, variações sazonais. O terreno e outras turbinas nas proximidades são apenas alguns dos fatores que podem influenciar a variabilidade da saída de energia elétrica de uma turbina eólica. Sua operação pode ocorrer com diferentes velocidades dos ventos, podendo, assim, ocorrer de 4 até 25 metros por segundo (m/s) (ROMERO, 2012).

Deste modo, um dos mais importantes na produção de energia eólica está relacionado ao fato de que as séries das velocidades de ventos não são fáceis de prever. Estudos e simulações recentes estão cada vez mais proporcionando uma melhor compreensão desses impactos e assim o processo de conhecimento esta sendo feito para desenvolver ferramentas e métodos para minimizar custos e operar de forma confiável com níveis mais elevados o montante de energia eólica (AHLSTROM; JONES; ZAVADIL; GRANT, 2005).

B.2 NO BRASIL E NO MUNDO

Dentre os países que mais geram energia eólica, tem-se em primeiro lugar os Estados Unidos (35 GW), sendo a vice-liderança da China (25,8 GW) que viu seu potencial ser dobrado em 2009. No entanto, com um aumento significativo da produção da Índia seguido pelo Japão, Coreia do Sul e Taiwan a Ásia torna-se o continente com maior mercado eólico mundial em ascensão. Na América Latina o Brasil e o México são os líderes desse segmento (SAWYER; RAVE, 2010).

O setor eólico brasileiro instalou 583 MW em 2011, trazendo a capacidade total instalada para 1.509 MW, o que significa um aumento de 63% da capacidade instalada, e um acréscimo de 56% em termos de crescimento do mercado anual. O Brasil atingiu o marco de 1 GW em junho de 2011 e tem mais de 7.000 MW em desenvolvimento para ser concluído até 2016 (SAWYER; RAVE, 2012).

Pesquisas detectaram que 71 mil quilômetros quadrados do potencial eólico brasileiro, no qual este total está quase todo localizado no Nordeste, possuem velocidade dos ventos que ultrapassam 7 metros por segundo (m/s), o que proporcionam um potencial que supera dois terços do potencial de energia elétrica utilizado no país, que é cerca de 270 TWh/ano. Mas são

utilizados apenas expressivamente 1% desse potencial. A exploração torna-se baixíssima em relação aos países líderes em geração de energia eólica (ROMERO, 2012).

Assim, torna-se inevitável e imprescindível desenvolver pesquisas para o avanço significativo das formas de previsão da velocidade dos ventos para que os investimentos nessa inovadora forma de geração de energia, tão sustentável e necessária, ocupem o lugar de destaque, já que a energia elétrica do Brasil é uma das mais caras do mundo.

APÊNDICE C – REDES NEURAIS ARTIFICIAIS

C.1 INTRODUÇÃO

Alguns novos métodos capazes de realizar previsões de séries temporais estão a recuperar a atenção dos pesquisadores, isto é, métodos baseados em Inteligência Artificial como a Redes Neurais Artificiais (RNAs). Possuem a vantagem de conseguir aproximar funções não-lineares com boa precisão. A coleta de dados para esses métodos é uma tarefa muito interessante, já que existem algumas comparações entre redes neurais, lógica *fuzzy* e *neuro-fuzzy*, algoritmos evolucionários e alguns modelos híbridos, cujos resultados encontrados na previsão destas séries mostram que os modelos artificiais superam vários outros em resultados a curto prazo (BESSA et al., 2008; EL-FOULY et al., 2007; JURSA; ROHRIG, 2008; MA et al., 2009; POTTER; NEGNEVITSKY, 2006; RAMIREZ-ROSADO et al., 2009; SIDERATOS; HATZIARGYRIOU, 2007).

As RNAs são consideradas ferramentas poderosas e flexíveis para modelos de previsão de séries temporais, desde que existam informações relacionadas suficientes para a formação do banco de dados. É primordial uma seleção definida dos dados que serão utilizados como entrada e como saída da rede, assim como recursos computacionais disponíveis suficientemente para a implementação do programa (HAYKIN, 1999).

Pesquisas vêm sendo desenvolvidas com o objetivo de aplicar as RNAs em diversas áreas como matemática, engenharia, medicina, psicologia, neurologia, meteorologia, economia, na previsão de locais de minerais, previsões de carga elétrica e térmica, no controle adaptativo e robótica e em vários outros assuntos (MOHANDES et al., 2004).

Para realizar previsão de séries temporais, utilizando as RNAs, é necessário escolher corretamente qual estrutura de rede neural será utilizada, qual o treinamento mais viável para o problema em questão e, ainda, possuir dados suficientes para serem utilizados na rede neural (HAYKIN, 1999).

C.2 REFLEXÃO HISTÓRIA

Em razão do fascínio que o ser humano possui em desvendar o cérebro humano, desde o último século, tem-se muita curiosidade em revelar esses mistérios e, assim, trazer a tona uma nova ciência.

McCulloch e Pitts, 1943, já se interessavam pelo problema de representação das funções matemáticas lógicas juntamente com os estudos neurobiológicos, na qual foram propostas arquiteturas para os operadores lógicos “AND” e “OR”. No final dos anos 40, foi evidenciado pela publicação do livro *The Organization of Behavior*, escrito em 1949, por Donald Hebb, o introdutor dos conceitos básicos da aprendizagem Hebbiana (MC CULLOCH; PITTS, 1943).

Em estudos, Rosenblatt (1958) propôs o conceito e o algoritmo de aprendizagem de uma rede neural simples *perceptron*. São redes possuindo a característica de aprendizado de vários tipos de funções. Já em 1969, o livro de Minsky e Papert ocasionou uma reviravolta, pois relatava que a rede *perceptron* era incapaz de resolver problemas elementares como o problema do OR-exclusivo o que ocasionou um desinteresse neste assunto.

Somente na década seguinte foi reaberto esse interesse pelas redes neurais artificiais por Kohonen. Foi em 1974 que as primeiras concepções de um novo algoritmo de aprendizagem o retropropagação (*backpropagation*) foram apresentadas, sendo capaz de realizar tarefas mais complexas o que impulsionou novamente o campo das RNAs para novas pesquisas de maior eficiência, na resolução de problemas reais e descobertas de novas redes neurais (WERBOS, 1974; LOPES, 2005).

C.2.1 NEURÔNIO BIOLÓGICO


Atualmente, sabe-se que não se pode realizar nenhuma tarefa sem a ajuda do cérebro. Até os mais remotos micro-organismos possuem estímulos nervosos. O ser humano possui no cérebro em torno de 86 bilhões de neurônios que desenvolvem papel essencial para funcionamento, comportamento e raciocínio do corpo humano.

Os neurônios são constituídos de três partes, segundo Kartalopoulos, 1996:

- **Corpo celular:** onde se localiza o núcleo do neurônio. É responsável pelas reações bioquímicas.
- **Dendritos:** são finas extensões em forma de tubo, que contém ramificações ao redor de todo corpo celular onde agem como receptores para os sinais que lhe são enviados.
- **Axônios:** fibra nervosa que possui a finalidade de locomover os sinais emitidos pelos neurônios, sendo mais longo que os dendritos. São eles que se ramificam com outros neurônios.

Os neurônios conectados uns aos outros formam o sistema nervoso obtendo assim um arranjo espacial complexo. No cérebro humano, os dendritos captam sinais entre si e enviam atividades elétricas pelos axônios como se pode observar na figura 11:

Figura 11- Neurônios Biológicos.



Fonte: Wasserman (1989).

As conexões realizadas entre os neurônios são as chamadas sinapses que possuem papel fundamental para a comunicação entre as células nervosas. Pode-se dizer que o neurônio, quando é ativado, recebe um sinal eletroquímico que é conduzido ao longo dos axônios, através das sinapses para os neurônios subsequentes (WASSERMAN, 1989).

Portanto, o sinal eletroquímico do neurônio depende da eficácia das sinapses. É disparado somente se o sinal total que vem dos dendritos ultrapassar certo nível (*threshold*). As sinapses possuem uma abertura como um neurotransmissor químico para transmitir um sinal, o chamado estímulo nervoso (KARTALOPOULOS, 1996).


C.2.3 MODELO NEURÔNIO ARTIFICIAL

Ao longo dos tempos surgiram muitas ideias de como representar o funcionamento do cérebro humano. Foi através destas representações que deu origem o sistema artificial, constituindo assim a rede de neurônios multicamadas, composta por neurônios e organizadas em camadas sucessivas que são interconectadas. Dessa maneira, pode-se ressaltar que:

- Através do processo de aprendizagem é que o conhecimento é adquirido pela rede (WASSERMAN, 1989).
- Para se armazenar o conhecimento são utilizados os pesos sinápticos que é a força das conexões entre os neurônios (WASSERMAN, 1989).

Os componentes de um neurônio artificial sugerido por McCulloch & Pitts podem ser visto na Figura 12 (MC CULLOCH; PITTS, 1943).

Figura 12- Modelo do neurônio de McCulloch and Pitts.



Fonte: McCulloch and Pitts (1943).

O processo de treinamento do neurônio artificial pode ser desenvolvido de maneira simples, como a seguir (WASSERMAN, 1989):

1. É aplicado ao neurônio artificial um conjunto X de entradas $x_1, x_2, \dots, x_n$. Os sinais dentro das sinapses de um neurônio biológico devem ser interpretados como sendo as entradas.
2. Cada sinal (entrada) é multiplicado por um conjunto W de pesos $w_1, w_2, \dots, w_n$. No qual está relacionado com a resistência de uma única relação sináptica biológica.

3. Aplica-se tudo a um somatório $\sum$ que nada mais é que a soma dos valores das entradas pelos pesos.

Assim tem-se que a saída intermediária do neurônio é dada pela equação (52):


$$S_i = \sum_{j=1}^n w_{ij}x_j, \text{ para } i = 1, \dots, n. \quad (52)$$

No qual,

S_i = é a i-ésima saída do neurônio.

A função de ativação $f(\cdot)$ do neurônio é geralmente linear. Observa-se na figura 13 abaixo alguns exemplos de funções de ativação:

Figura 13- (a) Função Relé, (b) Função Lógica Thershold, (c) Função Sigmoidal.



Fonte: Elaborado pelo próprio autor.

C.2.4 ESTRUTURA REDE NEURAL ARTIFICIAL

A estrutura de uma rede neural consiste de elementos de processamento, isto é, de neurônios que podem possuir várias entradas e saídas. Sendo possível utilizar essas saídas para servirem de entrada de vários outros neurônios, produzindo as ramificações. Toda

conexão entre neurônios possui um peso que acaba determinando cada decisão de disparo e assim os estímulos controlados (HAYKIN, 1999; KARTAPOULOS, 1996).


A rede neural é diferenciada em dois tipos quanto a sua estrutura: redes neurais recorrentes (*feedforward*) ou não-recorrentes.

a) Redes neurais recorrentes: possui laços de realimentação, isto é, existem conexões das saídas de uma determinada camada para camadas anteriores ou da mesma camada.

b) Redes neurais não-recorrentes: estas ao contrário das redes recorrentes, não possuem laços de realimentação. A estruturação da rede é feita em camadas, porém neste tipo de rede as camadas em questão recebem sinais somente das camadas anteriores.

A estrutura de uma rede neural artificial pode ser descrita como na figura 14:

Figura 14- Estrutura de uma rede neural artificial.



Fonte: Haykin (1999).

C.2.5 TIPOS DE TREINAMENTO DAS REDES NEURAIS ARTIFICIAIS

Dentre as principais propriedades das redes neurais artificiais, a mais importante é a habilidade que elas possuem em aprender, através do treinamento e com isso melhorar seu desempenho. O treinamento está completo quando se aplica um conjunto de entradas, em sequência e, em acordo com o procedimento predeterminado, os pesos das redes vão sendo ajustados. (WASSERMAN, 1989). Classificam-se os tipos de treinamento em dois grupos distintos:

Treinamento supervisionado: treina-se a rede através da combinação dos padrões de entrada e saída. Na fase de aprendizado que é a fase que avalia e informa a rede sobre o seu desempenho, faz-se necessária a presença de um agente externo (professor). Podem-se citar algumas importantes redes que possuem esse treinamento entre elas: MADALINE no qual seu algoritmo de treinamento é o retropropagação (*backpropagation*), a rede ARTMAP, existe também rede ARTMAP FUZZY, e várias outras (KROSE; SMAGT, 1996; WASSERMAN, 1989).

Treinamento não-supervisionado: ao contrário do treinamento supervisionado, esse treinamento não necessita de um agente externo, ou seja, é um treinamento auto-organizável. Para se obter os ajustes dos pesos, leva-se em conta somente o conjunto de padrões de entrada. Podem-se citar algumas redes que obedecem a esse treinamento, são elas: Kohonen, Hopfield, e a ART (convencional e a *fuzzy*) (KROSE; SMAGT, 1996; WASSERMAN, 1989).

No trabalho em questão foi utilizado algoritmo de treinamento supervisionado retropropagação do erro (*backpropagation*).

C.2.6 ALGORITMO RETROPAGAÇÃO

O algoritmo retropropagação (BP) é um dos mais populares entre as redes neurais artificiais (HAYKIN, 1999; KARTAPOULOS, 1996).

Baseado no gradiente que busca minimizar o erro de previsão da rede neural. Descreve-se, a seguir, o algoritmo de treinamento retropropagação (VILLALBA; BEL, 2000):

Passo 1: Primeiramente, apresenta-se o vetor de entrada a rede, a partir dos dados de treinamento, na qual se propaga para obter a saída desejada;

Passo 2: Depois, calcula-se o sinal do erro, através da comparação da saída real para a saída desejada, como na equação (53):

$$E(\text{erro}) = \sum_{i=1}^{ns} |o_n - y_n|^2, \quad (53)$$

em que o_n é a saída desejada do n -ésimo peso da camada de saída, y_n é a saída real e ns é o número de neurônios da última camada da rede.

Passo 3: Consiste em propagar o sinal do erro no sentido contrário (retropropagação do erro) através da rede, associado a derivada parcial do erro quadrático de cada elemento relacionado aos pesos. O gradiente do erro quadrático pode ser definido por (KROSE; SMAGT, 1996):

$$\nabla_i(h) = \frac{\partial \varepsilon_i^2}{\partial V_i(h)} = 2\varepsilon_i \frac{\partial \varepsilon_i}{\partial V_i(h)}. \quad (54)$$

No qual se tem,

$$\varepsilon_i = o_n - y_n. \quad (55)$$

A função de ativação é denotada por (VILLALBA; BEL, 2000):

$$y_i = \left(\frac{2}{1 + e^{(-\lambda s_i)}} \right) - 1 \quad (56)$$

ou,

$$y_i = \frac{1}{1 + e^{(-\lambda s_i)}} \quad (57)$$

O parâmetro λ é a constante que determina a inclinação da curva y_i e s_i é a saída intermediária do neurônio.

Fazendo a diferenciação da equação (55), em relação ao vetor V_i , tem-se:

$$\frac{\partial \varepsilon_i}{\partial V_i} = -\frac{\partial y_i}{\partial V_i} = -\left(\frac{\partial y_i}{\partial s_i} \frac{\partial s_i}{\partial V_i} \right) \quad (58)$$

sendo:

$$\frac{\partial y_i}{\partial s_i} = \text{sgm}'(s_i), \quad (59)$$

$$\frac{\partial s_i}{\partial V_i} = X_i. \quad (60)$$

No qual,

$$X_i = [x_{0i} x_{1i} x_{2i} \dots x_{ni}]^T.$$

Realizando a substituição das equações (59) e (60) na equação (55), tem-se:

$$\frac{\partial \varepsilon_i}{\partial V_i} = -\text{sgm}'(s_i)X_i. \quad (61)$$

Substituindo a equação (61) na equação (54), obtém-se:

$$\nabla_i(h) = -2\varepsilon_i \text{sgms}'(s_i)X_i. \quad (62)$$

Passo 4: Em seguida faz-se o ajuste dos pesos para minimizar o erro. O ajuste dos pesos pode ser descrito como:

$$V_i(h+1) = V_i(h) + \theta_i(h), \quad (63)$$

desde que se considere o neurônio de índice i da rede, e fazendo a utilização do gradiente descendente.

No qual:

$$\theta_i(h) = -\gamma[\nabla_i(h)];$$

γ = taxa de treinamento;

h = iterações;

$\nabla_i(h)$ = gradiente do erro quadrático em relação aos pesos em relação a h ;

V_i = vetor que contém os pesos do neurônio i .

Substituindo o gradiente estimado através da equação (62), do método do gradiente descendente, na equação (63), tem-se:

$$V_i(h+1) = V_i(h) + 2\gamma\beta_i X_i \quad (64)$$

Se ocorrer do elemento i estar na última camada, tem-se:

$$\beta_i = \text{sgm}'(s_i)\varepsilon_i \quad (65)$$

Senão:

$$\beta_i = \text{sgm}'(s_i) \sum_{k \in R(j)} w_{ik} \beta_k \quad (66)$$

No qual:

$\text{sgm}'(s_i)$ = pelas equações (67) ou (68), é a derivada da função sigmoide em relação a s_i ;

$R(j)$ = conjunto dos índices dos elementos que se encontram na fileira seguinte a do elemento i , e que estão ligados a ele.

Dada a equação (59), pode-se obter a derivada parcial da função sigmoide, denotada assim por:

$$\frac{\partial y_i}{\partial s_i} = \frac{\partial}{\partial s_i} \left\{ \left(\frac{2}{1+e^{(-\lambda s_i)}} \right) - 1 \right\} = \frac{1}{2} \lambda (1 - y_i^2) \quad (67)$$

Dada a equação (60), a derivada parcial da função sigmoide, pode ser expressa da seguinte forma:

$$\frac{\partial y_i}{\partial s_i} = \frac{\partial}{\partial s_i} \left\{ \frac{1}{1+e^{(-\lambda s_i)}} \right\} \lambda y_i (1 - y_i) \quad (68)$$

Com o intuito de deixar o algoritmo retropropagação do erro mais rápido computacionalmente faz-se o uso de várias abordagens. Uma delas é o algoritmo retropropagação com momento (WIDROW; LEHR, 1990), que tem por finalidade atuar como um estabilizador (HAYKIN, 1999).

Pode-se formular a adaptação dos pesos da seguinte maneira (HAYKIN, 1999):

$$v_{ij}(h+1) = v_{ij}(h) + \Delta v_{ij}(h) \quad (69)$$

No qual, tem-se:

$$\Delta v_{ij}(h) = 2\gamma(1 - \eta)\beta_j x_i + \eta \Delta v_{ij}(h-1) \quad (70)$$

sendo:

v_{ij} = peso que corresponde a ligação entre o i-ésimo e o j-ésimo neurônio;

γ = taxa de treinamento;

η = constante “momento” na qual sua variação fica entre $0 \leq \eta \leq 1$;

Se ocorrer de o elemento j estar na última camada, tem-se:

$$\beta_j = \sigma_j \varepsilon_j \quad (71)$$

em que,

σ_j = derivada da função sigmoide, em relação a s_j , nas equação (67) ou (68):

$$= \frac{1}{2} \lambda (1 - y_i^2) \quad (72)$$

$$= \lambda y_i (1 - y_i) \quad (73)$$

Já se ocorrer do elemento j estiver nas demais camadas, então:

$$\beta_j = \sigma_j \sum_{k \in R(j)} w_{jk} \beta_k \quad (74)$$

No qual,

R_j = conjunto dos índices dos elementos que estão na fila seguinte a fila do elemento j e que encontram interligados a ele.

Passo 5: Apresenta-se um novo padrão a rede;

Passo 6: Repete-se os passos de 2 a 6 como próximo vetor de entrada até que o erro seja mínimo ($|\text{erro}| < \text{tolerância preestabelecida}$), ou um número máximo de interações preestabelecidas for alcançado.