



Camila Maria do Nascimento Monteiro

**Modelo para previsão de curto prazo de
velocidade de vento usando Holt- Winters**

Dissertação de Mestrado

Dissertação apresentada ao Programa de Pós-Graduação
em Engenharia Elétrica da PUC-Rio como requisito parcial
para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Reinaldo Castro Souza

Rio de Janeiro
Setembro de 2013



Camila Maria do Nascimento Monteiro

**Modelo para Previsão de Curto Prazo de
Velocidade de Vento Usando Holt-Winters**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica do Centro Técnico Científico da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

Prof. Reinaldo Castro Souza
Orientador

Departamento de Engenharia Elétrica – PUC-Rio

Prof. José Francisco Moreira Pessanha
UERJ

Prof. Plutarcho Maravilha Lourenço
CEPEL

Prof. José Eugenio Leal
Coordenador Setorial do Centro
Técnico Científico

Rio de Janeiro, 10 de setembro de 2013

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, da autora e do orientador.

Camila Maria do Nascimento Monteiro

Graduou-se como Bacharel em Estatística pela UERJ (Universidade do Estado do Rio de Janeiro) em 2010. Afastou-se da atividade profissional, para efetuar seus estudos de mestrado na área de Métodos de Apoio a Decisão da Engenharia Elétrica no ano 2010. Na qual durante o mestrado, trabalhou com modelagem e previsão com aplicação no mercado brasileiro de energia elétrica.

Ficha Catalográfica

Monteiro, Camila Maria do Nascimento

Modelo para previsão de curto prazo de velocidade de vento usando Holt-Winters / Camila Maria do Nascimento Monteiro; orientador: Reinaldo Castro Souza. – Rio de Janeiro: PUC-Rio, Departamento de Engenharia Elétrica, 2013.

95 f.; 30 cm

Dissertação (mestrado) – Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica, 2013.

Inclui referências bibliográficas

1. Engenharia Elétrica - Tese. 2. Energia Eólica. 3. Velocidade de Vento. 4. Curto Prazo. 5. Séries Temporais. 6. Método de Holt-Winters. 7. Previsão. I. Souza, Reinaldo Castro. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. III. Título.

CDD: 621.3

“ O que a mente do homem pode conceber e acreditar, pode ser realizado”.

Napoleon Hill

Agradecimentos

A Deus, por ter caminhado comigo em todos os momentos,

Ao meu orientador Prof. Reinaldo Souza Castro, pela oportunidade de estar aqui e pela aprendizagem enriquecedora,

A banca examinadora que tenho uma honra enorme de tê-los.

Dedico esta dissertação aos meus pais Idílio e Rosi, meu padrinho Cesar e a minha avó Aurora que apesar de não estar mais presente na Terra, estará sempre presente em pensamento e no meu coração.

Ao meu amor, por estar sempre ao meu lado, Thiago.

Aos amigos que fiz na PUC-Rio, dos quais jamais me esquecerei.

À CAPES e a PUC-Rio, pelo apoio financeiro.

Resumo

Monteiro, Camila Maria do Nascimento; Souza, Reinaldo Castro (Orientador). **Modelo para previsão de curto prazo de velocidade usando Holt-Winters**. Rio de Janeiro, 2013. 95p. Dissertação de Mestrado – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Após o choque de racionamento de energia elétrica, decorrente do desequilíbrio entre oferta e demanda, os vários setores da sociedade brasileira constatarem a real e iminente necessidade de diversificação das fontes de geração de energia elétrica e de seu uso racional. Busca-se hoje novas fontes, entre as quais a energia eólica, uma alternativa nova e promissora. A energia eólica está aumentando no mundo todo e o Brasil tem um enorme potencial devido a sua localização geográfica e o governo tem investido neste tipo de energia. O principal objetivo desta dissertação é estudar e desenvolver modelos de previsão de velocidade de vento, de curto prazo da velocidade do vento. Os métodos de amortecimento exponencial, em particular o método de Holt-Winters e suas variações, são apropriados para este contexto devido à sua alta adaptabilidade e robustez. Para aplicação da metodologia considerou-se o município de São João do Cariri (Estado de Paraíba), onde está localizada uma das estações de referência do projeto SONDA (Sistema Nacional de Dados Ambientais para o setor de energia). Será utilizado o método de Holt-Winters, que será comparado com os modelos: de persistência, neuro-fuzzy (ANFIS) e estatísticos.

Palavras-chave

Energia Eólica; velocidade de vento; curto prazo; séries temporais; método de Holt-Winters; previsão.

Abstract

Monteiro, Camila Maria do Nascimento; Souza, Reinaldo Castro (Advisor). **Model for predicting short-term speed using Holt-Winters**. Rio de Janeiro, 2013. 95p. MSc. Dissertation – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

After the shock of electricity rationing, due to the imbalance between supply and demand, the various sectors of the Brazilian society found a real and imminent need to diversify sources of electricity generation and its rational use. New sources are searched today, including wind power, a promising new alternative. Wind energy has been increasing worldwide and Brazil has huge potential due to its geographical location and the government has invested in this type of energy. The main objective of this thesis is to study and develop forecasting models, of short-term wind speed. The methods of exponential smoothing, in particular the method Holt-Winters and its variations, are suitable in this context because of its high adaptability and robustness. The city of São João do Cariri (State of Paraíba), where it is located one of the reference stations of project SONDA (National Environmental Data for the energy sector) was chosen in order to apply the methodology. The method that will be used is Holt-Winters, who will be compared with the models: persistence, neuro-fuzzy (ANFIS) and statistics.

Keywords

Wind power; wind speed; short term; time series analysis; exponential smoothing methods; prediction.

Sumário

1. Introdução.....	13
1.1. Objetivo.....	15
1.2. Estrutura da Dissertação.....	16
2 Energia Eólica	18
2.1. Base de dados	18
2.2. Breve Histórico da Energia Eólica.....	20
2.3. Panorama da Energia Eólica no Mundo	22
2.4. Aerogeradores.....	28
2.5. Potência de Vento.....	32
3. Metodologia.....	34
3.1. Série Temporal e Processo Estocástico	34
3.2. Previsão de Séries Temporais.....	38
3.3. Método Ingênuo (Naíve)	39
3.4. Média Móvel.....	39
3.5. Métodos de Amortecimento Exponencial.....	41
3.6. Métodos de Amortecimento de Brown.....	42
3.7. Método de Amortecimento Direto.....	43
3.7.1. Holt-Winters Padrão.....	44
3.7.1.1. Holt-Winters Aditivo.....	45
3.7.1.2. Holt- Winters Multiplicativo.....	49
3.7.2. Holt-Winters com Múltiplos Ciclos.....	51
3.9.4. Métricas de Desempenho.....	53
4. Análise Exploratória.....	56
5. Modelagem.....	67
5.1. Aplicação do Modelo.....	67
5.2. Comparação dos Resultados.....	86
6. Considerações Finais.....	90
6.1. Conclusão.....	90
6.2. Sugestões para Trabalhos Futuros.....	91
7. Referências bibliográficas.....	92

Lista de Tabelas

Tabela 2.1: Estações do projeto SONDA.	19
Tabela 4.1: Estatísticas de resumo da série de São João do Cariri – PB	56
Tabela 4.2: Teste Augmented Dickey-Fuller.	57
Tabela 4.3: Teste de Normalidade.	65
Tabela 5.1: Resumo dos Resíduos.	70
Tabela 5.2: Métricas de comparação - Aditivo (1 passo à frente).	76
Tabela 5.3: Métricas de comparação - Multiplicativo (1 passo à frente).	76
Tabela 5.4: Métricas de comparação.	82
Tabela 5.5: Métricas de comparação.	82
Tabela 5.6: Métricas de comparação.	85
Tabela 5.7: Métricas de comparação.	85
Tabela 5.8: Métricas de comparação entre os modelos	89

Lista de Figuras

Figura 2.1: Mapa das estações do Projeto SONDA.	20
Figura 2.2: Moinho Eólico	21
Figura 2.3: Participação dos países na nova capacidade instalada de energia eólica em 2011 e no total acumulado.	25
Figura 2.4: Evolução da capacidade instalada de energia eólica no Mundo.	26
Figura 2.5: Mapa eólico com as regiões de maior potencial	27
Figura 2.6: Como se captura e transforma a energia eólica	30
Figura 2.7: Parque Eólico de Osório	30
Figura 2.8: Evolução dos Aerogeradores desde 1985 até 2005.	31
Figura 2.9: Curva típica de potência de turbinas eólicas	32
Figura 3.1: Processo Estocástico e Série Temporal.	37
Figura 3.2: Exemplo da componente tendência e sazonalidade	44
Figura 4.1: Rosa dos ventos a 50 m de altura.	58
Figura 4.2: Periodograma da série da velocidade do vento.	60
Figura 4.3: Histograma da série.	63
Figura 4.4: QQ-Plot da série.	63
Figura 4.5: Boxplot da série.	64
Figura 5.1: Histograma dos resíduos.	73
Figura 5.2: Q-Q Plot dos resíduos.	74
Figura 5.3: Valores observados e previsão 1 passo à frente (Modelo Aditivo).	75
Figura 5.4: Valores observados e previsão 1 passo à frente (Modelo Multiplicativo).	75
Figura 5.5: Valores observados e previsão 2 passos à frente.	77
Figura 5.6: Valores observados e previsão 3 passos à frente.	77
Figura 5.7: Valores observados e previsão 4 passos à frente.	78
Figura 5.8: Valores observados e previsão 5 passos à frente.	78
Figura 5.8.1: Valores observados e previsão 6 passos à frente.	79
Figura 5.8.2: Valores observados e previsão 2 passos à frente.	79
Figura 5.8.3: Valores observados e previsão 3 passos à frente.	80
Figura 5.8.4: Valores observados e previsão 4 passos à frente.	80
Figura 5.8.5: Valores observados e previsão 5 passos à frente.	81
Figura 5.8.6: Valores observados e previsão 6 passos à frente.	81
Figura 5.9: Evolução do MAPE para o Modelo HW Aditivo.	83
Figura 5.10: Evolução do MAPE para o Modelo HW Multiplicativo.	83
Figura 5.11: Valores observados e previsão 24 passos à frente.	84
Figura 5.12: Valores observados e previsão 24 passos à frente.	84
Figura 5.13: Valores observados e previsões 1, 6 e 24 passos à frente.	85
Figura 5.14: Valores observados e previsões 1, 6 e 24 passos à frente.	86
Figura 5.15: Comparação: Modelo Proposto e Modelo Persistência.	87
Figura 5.16: Comparação: Modelo Proposto e Modelo ARFIMA.	87
Figura 5.17: Comparação: Modelo Proposto e Modelo Harmônico.	88
Figura 5.18: Comparação: Modelo Proposto e Modelo Tempo Frequência.	88

Lista de Gráficos

Gráfico 4.1: Série horária de São João do Cariri	57
Gráfico 4.2: Médias horárias da velocidade do vento.	59
Gráfico 4.3: Médias mensais da velocidade do vento.	59
Gráfico 4.4: FAC da série da velocidade do vento.	51
Gráfico 4.5: FACP da série da velocidade do vento.	61
Gráfico 4.6: Sazonalidade da série horária	62
Gráfico 5.1: Série dos Resíduos.	71
Gráfico 5.2: Função de autocorrelação dos resíduos.	72
Gráfico 5.3: Função de autocorrelação parcial dos resíduos.	72

Lista de Abreviaturas

ANEEL - Agência Nacional de Energia Elétrica
BDMEP - Banco de Dados Meteorológicos para Ensino e Pesquisa
CONAMA - Conselho Nacional do Meio Ambiente.
DB - Decibéis
DEWI - Deutsches Windenergie - Institute
EERE - Energy Efficiency & Renewable Energy
EPE - Empresa de Pesquisa de Energia
EWEA - European Wind Energy Association
FAE - Fontes Alternativas de Energia Elétrica
FC - Fator de Capacidade
GTEE - Grupo de Trabalho de Energia Eólica
GWEC – Global Wind Energy Council
GW - Gigawatt
IEA - International Energy Agency
INMET - Instituto Nacional de Meteorologia
INPE - Instituto de Pesquisas Espaciais
KW - Quilowatt
JB – Estatística de teste Jarque-Bera
MME - Ministério de Minas e Energia
MPH – Milhas por hora
MW - Megawatt
NWP - Numerical Weather Prediction
ONS - Operadora Nacional do Sistema
PCH – Pequena Central Hidroelétrica.
PDEE - Plano Decenal de Energia Elétrica
PDP – Plano diário de produção
PEE - Previsão de energia eólica = wind power forecasting (WPF)
PMO - Programa Mensal da Operação Eletroenergética
PROINFA - Programa de Incentivos às Fontes Alternativas de Energia
SETAR - Self-Exciting Threshold Autoregressive
SIG - Sistema de Informação Geográfica
UFRJ - Universidade Federal do Rio de Janeiro
UFSC - Universidade Federal de Santa Catarina
WWEA - World Wind Energy Association

Introdução

A busca dos países por energia limpa intensificou os estudos na área de desenvolvimento das tecnologias para geração de energia eólica pois o consumo de energia esta aumentando e com isso vem sendo uma das grandes preocupações da sociedade que busca alternativas para o suprimento dessa demanda. Com objetivo de diminuir os custos e tornar mais acessível o uso em larga escala de energia renovável.

As fontes renováveis de energia representam uma das alternativas para atender o crescimento de demanda energética. Entre tais fontes, a energia eólica emerge como uma das mais promissoras, tendo experimentado um crescimento acelerado nos últimos anos. Suas vantagens decorrem principalmente do fato de ser de natureza barata, uma vez que o parque eólico é instalado, inesgotável e, sobretudo limpa.

A crescente demanda energética no mundo se dá em razão da melhoria dos padrões de vida nos países em desenvolvimento, de uma forma que traz a preocupação com alguns aspectos essenciais para a política e planejamento energético de todas as economias emergentes.

Sendo uma energia limpa, renovável e abundante, a energia eólica vem traçando horizontes de grandes perspectivas em alguns países, especialmente no Brasil, principalmente nas regiões Nordeste e Sul do país. E com isso o estudo desta dissertação é a previsão de velocidade de vento com a metodologia estatística que tem apresentado bons resultados. O modelo utilizado para este estudo será o Holt-Winters que será melhor apresentado no capítulo 3.

Em estudos realizados pela ANEEL, o Brasil tem condições favoráveis de vento, favorecendo a implantação de Parque Eólico. E em 2002 foi aprovado pelo Congresso Nacional o Programa de Incentivo a Fontes Renováveis o PROINFA estimula o investimento em fontes de energia alternativas, podemos ver que o país caminha em direção de melhorias no setor de energia. Nesta dissertação serão analisados os dados da estação de São João do Cariri que tem medições anemométricas e fornece uma estimativa mais precisa do potencial eólico.

De acordo com outros estudos e artigos já lidos como o (Silva,2010; Dantas,2011) esta estação de São João do Cariri fornece informações de qualidade para o desenvolvimento de análise estatística.

Como o potencial eólico esta em grande expansão e com um desenvolvimento acelerado, tem sido um tema importante em diversos artigos e dissertações segundo (Pessanha et al, 2012).

Com os fatos expostos acima, o Brasil e o mundo vem recebendo um grande incentivo de produção de energia limpa e com isso vem sendo discutidos os problemas ambientais tais como o efeito estufa (Martins et al, 2008).

Os combustíveis fósseis são os maiores responsáveis pela produção de gases causadores do efeito estufa, além de não possuírem reservas permanentes. A dependência em relação a estes combustíveis ameaça os ecossistemas do planeta e deixa a humanidade em situação desconfortável em relação à oferta de energia para o futuro. A energia nuclear elimina as emissões de gases na atmosfera. Porém há resíduos nucleares, que até hoje não tem uma solução encontrada e que representam uma terrível herança deixada através dos séculos às futuras gerações.

E com estes problemas ficou evidenciado a necessidade de substituição das energias convencionais, além dos grandes choques de petróleo que os preços aumentaram de uma tal forma que não havia controle no mercado, causando a maior queda do nível da atividade econômica. Com as crises, as fontes de energia renováveis tiveram um grande desenvolvimento, pois são obtidas de fontes naturais capazes de regenerar e são consideradas inesgotáveis. Para reduzir a dependência em fontes de energia convencionais, além de renovar as matrizes energéticas e preservar o meio ambiente. Com isso estimulando o crescimento de mercado e o desenvolvimento tecnológico, alavancando recursos a ponto de fixar a energia eólica no mercado mundial com tecnologia, qualidade e confiabilidade, fazendo desta uma opção imprescindível para o fornecimento de energia limpa em grandes potências.

1.1

Objetivo

Atualmente, diversas técnicas estão sendo desenvolvidas para prever a velocidade de vento no curto prazo. Algumas técnicas tem sido baseadas em modelos computacionais e estatísticos. Como por exemplo podemos citar: Alexiadis et al (1999) que utilizaram um modelo de rede neurais que considera a velocidade do vento e a correlação espacial para obter um melhor resultado nas suas previsões. Genton et al (2006) que propuseram modelos em diferentes estações meteorológicas e a direção do vento. Silva (2010) propôs a previsão de velocidade de vento, utilizou os modelos computacionais e estatísticos para melhor desenvolvimento. Beblo e Schmid (2010) tiveram bons resultados na estação anemométrica na previsão de velocidade de vento no leste da Alemanha. Dantas (2011) utilizou para a previsão de velocidade de vento o modelo ARFIMA.

Como já explicitado este trabalho tem como foco os métodos que utilizam séries temporais. Todo modelo de previsão tem por objetivo prever a componente sistemática e estimar a componente aleatória. Nos modelos que utilizam séries temporais é necessário levar em consideração o comportamento dos dados.

Segundo MAKRIDAKIS, WEELWRIGHT e HYNDMAN (1998), o método de Holt-Winters é uma evolução do modelo de suavização exponencial simples, que inicialmente Holt para trabalhar com dados que apresentavam tendência linear, foi incluída uma equação para utilizar o modelo com dados que apresentam característica de tendência.

Em 1960, Winters estendeu o modelo de Holt incluindo uma nova equação que acrescentasse às previsões o comportamento sazonal dos dados, o que resultou no método de Holt-Winters. Com isso o modelo de Holt-Winters é um procedimento popular para a previsão de séries temporais que tem ciclos sazonais. Podemos falar também que este método é um dos mais utilizados para fazer previsões de curto prazo devido a fatores como simplicidade, baixo custo de operação, boa precisão uma capacidade de ajustamento automático e rápido à mudanças na série. Taylor (2003a) desenvolveu um trabalho no qual previa dados de demanda elétrica no intervalo de trinta minutos.

Com isso o modelo proposto nesta dissertação foi o Holt- Winters que será utilizado em uma estação anemométrica e a escolhida foi a de São João de Cariri – PB, a mesma foi escolhida pelo motivo de apresentar dados completos e a existência de trabalhos prévios com a série temporal em questão e com isso permitindo a comparação dos resultados. O modelo proposto que será aplicado na série escolhida e considera todos os fatores observados na análise exploratória de dados.

O objetivo deste estudo é desenvolver os modelos de previsão de curto prazo de velocidade do vento, para geração de energia eólica. Foi desenvolvido o modelo de Holt-Winters com 1 ciclo no modelo aditivo e 1 ciclo no modelo multiplicativo. Este método foi escolhido por ser tratar de um procedimento popular e com boa precisão. E da existência desse modelo ser quase de 50 anos e ser ainda bem forte e utilizado em diversas dissertações e sendo um modelo robusto.

1.2

Estrutura da Dissertação

A dissertação está organizada em oito capítulos, sendo o primeiro uma breve introdução e objetivo da dissertação.

No Capítulo 2, será apresentada uma breve revisão bibliográfica sobre energia eólica no mundo e no Brasil, além de características técnicas, tais como: potencial eólico, previsão do vento e os componentes do aerogerador.

No Capítulo 3 é detalhada a metodologia utilizada para a elaboração dos modelos propostos e utilizados, bem como as métricas de comparação dos resultados.

No Capítulo 4, fará uma breve apresentação do banco de dados utilizado para o desenvolvimento dessa dissertação, bem como o motivo da escolha do período de tempo utilizado para elaboração desse trabalho.

O Capítulo 5 é dedicado à análise exploratória dos dados, de maneira a justificar a escolha dos modelos a serem utilizados na previsão. No Capítulo 6 será feita uma apresentação do modelo proposto como o Holt-Winters tradicional, com os seus conceitos teóricos e suas fórmulas matemáticas, e o Holt-Winters

Aditivo e Multiplicativo. E aplicação dos modelos à série temporal de velocidade de vento na estação anemométrica de São João do Cariri – PB. No Capítulo 7, serão apresentadas as conclusões sobre a análise do resultado e futura proposta de estudo.

2

Energia Eólica

2.1

Base de Dados

Os dados utilizados neste trabalho foram obtidos do projeto SONDA (Sistema de Organização Nacional de Dados Ambientais). A rede SONDA de dados nasceu de um projeto do Instituto Nacional de Pesquisas Espaciais (INPE) para implementação de infra-estrutura física e de recursos humanos destinada a levantar e melhorar a base de dados dos recursos de energia solar e eólica no Brasil (site do projeto sonda - <http://sonda.ccst.inpe.br/>).

Cada estação da rede SONDA possui uma configuração específica de sensores, medindo variáveis diferentes conforme sua classificação que são:

- Estação Anemométrica (A)
- Estação Solarimétrica (S)
- Estação Anemométrica e Solarimétrica (SA)

Cada estação anemométrica fornece os seguintes dados com periodicidade de 10 minutos:

- Velocidade do vento aos 25 metros de altura em metros por segundo
- Direção do vento aos 25 metros de altura em graus
- Temperatura aos 25 metros de altura em graus Celsius
- Velocidade do vento aos 50 metros de altura em metros por segundo
- Direção do vento aos 50 metros de altura em graus
- Temperatura aos 50 metros de altura em graus Celsius

Na Tabela 2.1 estão resumidas as informações de todas as estações do projeto SONDA:

Tabela 2.1: Estações do projeto SONDA.

<i>Estação (SIGLA)</i>	<i>Tipo</i>	<i>UF</i>	<i>ID</i>	<i>Latitude</i>	<i>Longitude</i>	<i>Alt.(m)</i>
<u>Belo Jardim (BJD)</u>	A	PE	22	08° 22' 03" S	36° 25' 46" O	718
<u>Brasília (BRB)</u>	SA	DF	10	15° 36' 03" S	47° 42' 47" O	1023
<u>Caicó (CAI)</u>	S	RN	20	06° 28' 01" S	37° 05' 05" O	176
<u>Campo Grande (CGR)</u>	S	MS	12	20° 26' 18" S	54° 32' 18" O	677
<u>Cuiabá (CBA)</u>	S	MT	21	15° 33' 19" S	56° 04' 12" O	185
<u>Ourinhos (ORN)</u>	SA	SP	28	22° 56' 55" S	49° 53' 39" O	446
<u>Palmas (PMA)</u>	S	TO	19	10° 10' 40" S	48° 21' 43" O	216
<u>Petrolina (PTR)</u>	SA	PE	11	09° 04' 08" S	40° 19' 11" O	387
<u>Rolim de Moura (RLM)</u>	S	RO	27	11° 34' 54" S	61° 46' 25" O	252
<u>São Luiz (SLZ)</u>	S	MA	16	02° 35' 36" S	44° 12' 44" O	40
<u>São João do Cariri (SCR)</u>	A	PB	25	07° 22' 54" S	36° 31' 38" O	486
<u>São Martinho da Serra (SMS)</u>	SA	RS	08	29° 26' 34" S	53° 49' 23" O	489
<u>Triunfo (TRI)</u>	A	PE	23	07° 49' 38" S	38° 07' 20" O	1123

Fonte: Site do projeto sonda.

E a Figura 2.1 mostra a sua localização no mapa:



Figura 2.1: Mapa das estações do Projeto SONDA.

Fonte: Projeto SONDA.

Em diversas estações anemométricas, existem observações incompletas por meses e com datas diferentes em cada estação, não seguia um padrão que a estimativa fosse possível com um certo nível de segurança.

A estação de São João do Cariri na Paraíba, apresenta dados de registros anemométricos e esta localidade abrange mais de um ano sem observações faltantes. O período utilizado para elaboração desse trabalho, refere-se ao ano de 2006. O período foi escolhido de maneira que fosse possível comparar os resultados com trabalhos anteriores na mesma estação anemométrica e no mesmo período, por esta razão foi escolhida esta série.

2.2

Breve Histórico da Energia Eólica

A energia eólica tem sido aproveitada desde a antiguidade para mover os barcos impulsionados por velas ou para fazer funcionar a engrenagem de moinhos, ao mover as suas pás. Nos moinhos de vento a energia eólica era

transformada em energia mecânica, utilizada na moagem de grãos ou para bombear água. Os moinhos foram usados para fabricação de farinhas e ainda para drenagem de canais, sobretudo nos Países Baixos. Estes cata-ventos foram chamados de eixo horizontal ou do tipo “holandês”.

Dizem que a energia eólica foi utilizada pela primeira vez na Pérsia, por volta do ano 200 A.C. na moagem dos grãos. E esse tipo de energia foi disseminado para a Inglaterra, França e Holanda e, logo depois, espalhado por toda a Europa. Na Figura 2.2 abaixo, segue a foto de um moinho típico da Holanda:



Figura 2.2: Moinho Eólico

Fonte: Site panorâmico

Dominar o vento é um dos métodos mais antigos de produção de energia. A humanidade utiliza, desde a antiguidade, os moinhos de vento para moer os cereais e para bombear água.

Com a crise do petróleo (1970 a 1980), o mundo se viu dependente dos combustíveis fósseis e com a possibilidade de esgotamento desta fonte. Com isto, diversos países, inclusive o Brasil, pensaram em alternativas para geração de energia elétrica. O surgimento da eletricidade no final do século XIX, os primeiros protótipos de turbinas eólicas modernas foram concebidos, utilizando tecnologia baseada no tradicional moinho de vento. Desde então, decorreu um processo moroso até que a energia eólica fosse aceita como um método de produção de energia economicamente viável.

Portanto começaram os investimentos em pesquisas para energias alternativas destacando-se países como: Alemanha, Dinamarca, EUA e Espanha. As turbinas eólicas construídas nessa época eram utilizadas essencialmente para

investigação e eram extremamente dispendiosas. Com a ajuda de programas de gestão e investigação internacional financiado pelo governo, bem como da criação de institutos de investigação, nos anos 80, continuaram a ser investigados, desenvolvidos e implementados novos métodos de produção de energias renováveis.

Porém, após a guerra, com a retomada do crescimento da economia mundial, a energia eólica foi deixada em segundo plano por não ser economicamente competitiva e não gerar impactos na cadeia produtiva se comparada com os combustíveis fósseis.

Mas alguns países como a Alemanha e a Dinamarca desenvolveram vários programas de investigação e cooperação internacionais no sector da energia eólica, contribuíram para os avanços industriais e tecnológicos dos pioneiros da energia eólica. Devido à estreita cooperação entre os institutos de investigação e os pioneiros da energia eólica, foram desenvolvidos e implementados padrões internacionais, uma regulamentação precisa e um design cada vez mais eficientes, tendo resultado em parques eólicos modernos e economicamente viáveis.

A energia eólica é, atualmente, uma das fontes energéticas menos dispendiosas, se forem tidos em conta todos os custos externos (por exemplo, os danos ambientais). Assim, através de pesquisas, surgiram vários aerogeradores eólicos de diferentes potências e formas.

Com o avanço da tecnologia e o aumento do consumo de energia, foi impulsionada a produção de novos aerogeradores, reduzindo gradativamente os custos da geração de energia elétrica proveniente dos ventos.

As estações modernas de energia eólica produzem uma parte cada vez maior da energia global. A indústria da energia eólica, com o crescente volume de exportações, tornou-se um importante mercado global e um fator econômico.

2.3

Panorama da Energia Eólica no Mundo

A energia eólica apresenta um panorama bastante diferente da energia solar, já possuindo maturidade tecnológica e escala de produção industrial. Isso foi resultado de significativos investimentos e uma política de criação de mercado

através de políticas de incentivos em vários países, especialmente na Alemanha, Dinamarca, EUA, e mais recentemente na Espanha. Hoje essa tecnologia está preste a ser tornar economicamente viável para competir com as fontes tradicionais de geração de eletricidade, além de um existir um grande potencial eólico a ser explorado em diversos países. Existem oportunidades de melhoramentos tecnológicos bem identificados internacionalmente que deverão levar ainda a reduções de custo e permitir estabelecer metas bastante ambiciosas para instalação de sistemas de geração nos próximos 30 anos.

A crise europeia e o medo de recessão não foram capazes de frear os investimentos em energia eólica, que apresentou em 2011 um crescimento de 21% na capacidade instalada mundial. Esta expansão resultou principalmente do interesse de novos mercados, principalmente da China, pelas renováveis.

Segundo o Conselho Global de Energia Eólica (GWEC), 80 países já possuem instalações eólicas e 22 delas são capazes de gerar pelo menos 1GW. Mais de 41GW foram somados à capacidade total instalada em 2011, que agora ultrapassa os 238GW. “Apesar do estado atual da economia global, a energia eólica continua a ser a tecnologia de geração renovável mais escolhida”, afirmou Steve Sawyer, secretário geral da GWEC.

Segundo a reportagem do Instituto Carbono Brasil, a China consolidou seu papel de liderança no mercado global, instalando 18GW em 2011 e com uma capacidade ultrapassando os 62GW. “O ano não foi fácil para a indústria de energia eólica chinesa. No entanto, o setor conseguiu sair-se bem, não só superando as dificuldades, mas tornando-se mais resiliente frente aos vários desafios. No ano de 2013, o setor irá adaptar-se as novas exigências do governo bem como às exigências do mercado. Esperamos que o setor torne-se mais forte e competitivo”, comentou Li Junfeng, Secretário Geral da Associação das Indústrias de Energia Renovável da China (CREIA).

Na América Latina, mais de 1,2GW foram instalados, sendo que o Brasil foi responsável por 587MW.

Na Índia, as instalações de 2011 elevaram a capacidade total do país para pouco mais de 16GW. “A Índia alcançou outro marco acrescentando mais de 3GW de energia eólica instalados. Esse número possivelmente chegará a 5GW por ano até 2015. As iniciativas contínuas do governo indiano no sentido de criar

novas políticas atrairão quantias significativas de investimentos privados para o setor”, disse D.V. Giri, Presidente da Associação de Fabricantes de Turbinas Eólicas da Índia.

Na União Europeia, 9.616 MW de capacidade de energia eólica foi instalada em 2011, totalizando 93.957 MW – suficiente para fornecer 6,3% da energia elétrica do bloco, de acordo com a Associação de Energia Eólica Europeia (EWEA). “Apesar da crise econômica que assola a Europa, o setor de energia eólica está instalando em níveis sólidos”, comentou Justin Wilkes, Diretor de Políticas da EWEA. E ainda complementa dizendo que “Mas para alcançar os objetivos de longo prazo precisamos ter um forte crescimento nos próximos anos. Um compromisso da União Europeia para estabelecer a meta de energia renovável para 2030 seria um sinal muito positivo para os potenciais investidores.”

Após um ano muito difícil em 2010, o setor de energia eólica norte-americano está novamente em ascensão, com instalações de mais de 6800MW.

“A base do setor de energia eólica norte-americana é sólida. Estamos bem encaminhados para oferecer 20% da energia elétrica dos EUA até 2030. Só com as instalações que fizemos em 2011 fornecemos energia elétrica suficiente para quase dois milhões de lares americanos”, afirmou Denise Bode, CEO da Associação Americana de Energia Eólica (AWEA).

“Vislumbramos a abertura de novos mercados na África, Ásia e América Latina e esperamos ver alguns países na América Latina, além do Brasil, aproximar-se da massa crítica. Mas, sinceramente, será difícil manter o potencial de crescimento do setor sem um preço unificado do carbono e outras medidas que justifiquem os custos reais da geração convencional de energia elétrica para a sociedade”, concluiu Sawyer.

A seguir, os gráficos (Figura 2.3) ilustram a capacidade de energia eólica de vários países em 2011:




Figura 2.3: Participação dos países na nova capacidade instalada de energia eólica em 2011 e no total acumulado.

Fonte: GWEC / Instituto Carbono Brasil.

Mesmo com a falta de recursos financeiros, os países possuem metas a seguir, ou seja, a crise financeira desestabilizou o setor de energia renovável, mas não o paralisou. Como podemos notar no Figura 2.4, abaixo de evolução de potência instalada no mundo até 2014. Já a Europa, em 2009, que adotou o *Renewable Energy Directiva*, que incluiu uma meta de 20% de energia renovável até 2020 em que 14% serão provenientes de energia eólica (EWEA, 2010).




Figura 2.4: Evolução da capacidade instalada de energia eólica no Mundo.

Fonte: Ministério de Minas de Energia

Os Programas Governamentais vêm incentivando a energia eólica, que esta é uma energia limpa - sem queima de combustível, renovável e cada vez mais barata. O preço do megawatt/hora da eólica já é quase igual ao das hidrelétricas, a fonte de energia mais barata do Brasil, e custa menos que o gás natural. Hoje já são 12 milhões de pessoas atendidas por essa fonte de energia.

Mas na década de 70, com a crise do abastecimento de petróleo, alguns países se viram obrigados a pesquisar fontes alternativas de energia. No Brasil, o primeiro aerogerador só foi instalado em 1992, em Fernando de Noronha, mas foi a partir de 2005 que o parque eólico brasileiro cresceu significativamente. Nos últimos sete anos, a capacidade instalada aumentou 54 vezes. Foi a que mais cresceu no mundo. Muito pelas características do vento no Brasil, um dos melhores do planeta. O desenvolvimento da energia eólica, no Brasil, tem ocorrido de forma gradual e consistente e está em consonância com a diretriz do Governo Federal de valorização das características e potencialidades regionais na formulação e implementação de políticas. Estudos realizados comprovam sua importância como fonte complementar à geração hidrelétrica, ressaltando o caráter estratégico para diversificação da Matriz Energética e para o aumento da segurança no abastecimento de energia elétrica.

O Brasil tem 71 parques com quase mil aerogeradores, alguns da altura de um prédio de 50 andares, em nove estados. Mas é o Nordeste o campeão nacional

de geração de energia do vento. O Ceará detém 40% da capacidade do país. São 17 parques e já existe até aerogerador residencial para o consumidor produzir a própria energia.

Em nenhum outro lugar do Brasil a energia eólica provocou mudanças tão importantes quanto no Rio Grande do Norte. Até dois anos atrás, o estado era obrigado a importar energia elétrica para atender a demanda. Mas os bons ventos da região atraíram os investidores. Dez parques eólicos foram construídos. Outros 30 estão em construção. Até 2014, o Rio Grande do Norte será o principal produtor de energia eólica do Brasil, de acordo com o Empresa de Pesquisa Energética (EPE).

Na Figura 2.5 abaixo, segue o mapa com as regiões com maior potencial para geração de energia eólica:

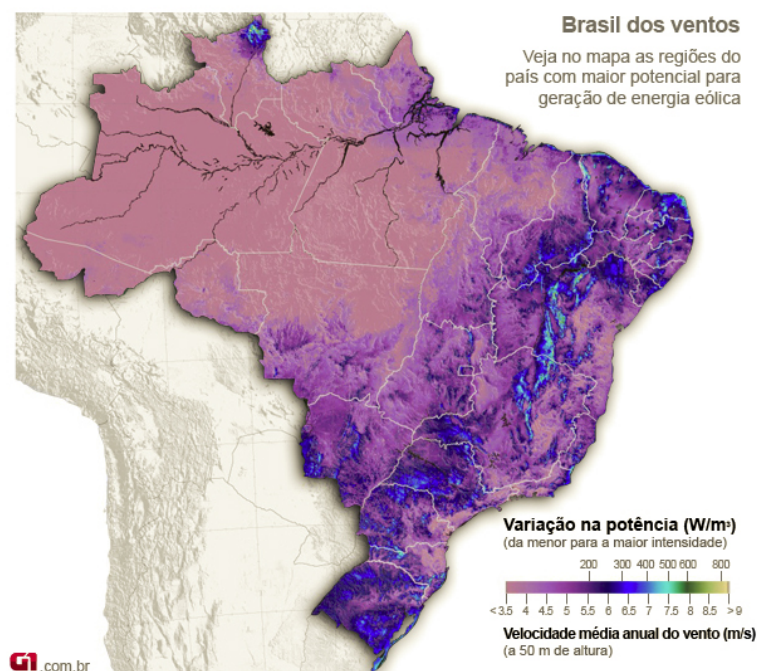


Figura 2.5: Mapa eólico com as regiões de maior potencial

Fonte: Atlas Eólico Brasileiro

“O Brasil ultrapassou a marca dos 1GW em 2011 e tem encaminhados mais 7000MW para serem instalados antes do fim de 2016. O setor eólico brasileiro está atraindo investimentos significantes, facilitados por políticas do

BNDES. Porém, uma nova estrutura legal com regras claras para o futuro será necessária para garantir o ritmo de crescimento”, afirmou Pedro Perrelli, diretor executivo da Associação Brasileira de Energia Eólica (Abeólica).

De acordo com dados do relatório Global Wind Report 2011, o Brasil vem se estabelecendo como grande mercado internacional, já dominando o latino-americano. Com uma forte base industrial, o país é considerado capaz de abastecer o Cone Sul, e será responsável, em vasta maioria, pelo crescimento regional até 2016. Segundo o presidente da Empresa de Pesquisa Energética (EPE), o ritmo intenso de crescimento do setor fará com que, até 2020, o Brasil tenha quase uma Belo Monte de capacidade de geração a partir dos ventos. As usinas eólicas deverão ter o maior crescimento proporcional dentre as diversas fontes, passando dos atuais 2 % para 8% da matriz energética nacional. Com isso, de acordo com a Agência Nacional de Energia Elétrica (Aneel), o país produz pouco mais de 2 GW de energia eólica, 1,7% do total produzido em território nacional.

De acordo com o Conselho Global de Energia Eólica, o crescimento no ano passado foi de 75,2%. O país agora tem 2,5 mil MW de energia eólica instaladas e ocupa a 21ª posição no ranking de produtores.

2.4

Aerogeradores

O aproveitamento da energia eólica para produção de eletricidade é feito por aerogeradores de grande dimensão, os quais podem ser implantados em terra ou no mar e estar agrupados em parques ou isolados. Os aerogeradores convertem a energia eólica em energia elétrica.

São constituídos por uma torre metálica com uma altura que pode oscilar entre 25 e 80 m e por turbinas com duas ou três pás, cujos diâmetros de rotação se situam em valores idênticos à altura dos postes. As turbinas de última geração têm uma capacidade de produção de energia de 1.6-2 MW, encontrando-se em fase de teste turbinas de 5 MW. A velocidade mínima do vento necessária para as turbinas entrarem em funcionamento situa-se entre 10 a 15Km/h e a velocidade de cruzeiro é de 50 a 60 m/s. Em caso de tempestade as pás e o rotor são

automaticamente travados quando a velocidade de vento for superior a 90 km/h. Uma vez travado, o aerogerador pode suportar velocidades de até 200 km/h sem sofrer danos.

Possuem ainda proteção contra raios e microprocessadores que permitem o ajuste continuado do ângulo das pás às condições de vento dominantes e a manutenção de um output de corrente elétrica uniforme, condição esta muito importante quando se encontram ligados à rede de distribuição elétrica. Os sistemas eólicos isolados, com gamas de potência entre 25W e 150W, são dos mais bem sucedidos comercialmente, sendo usados para carga de baterias (utilizados no Reino Unido pela Marinha e caravanas e na China pelas populações seminômades da região da Mongólia), bombeamento de água, aquecimento, etc., de acordo com o site energia eólica no mundo.

Os Aerogeradores podem ser classificados de acordo com a configuração do eixo rotor:

- ✓ Eixo Vertical
- ✓ Eixo Horizontal

Os Aerogeradores com eixo rotor vertical são capazes de gerar energia em condições de vento reduzido, não necessitam de mecanismo de direcionamento, são mais seguros e tem um custo menor.

São divididos com os diferentes rotores: Darrieus e Savonius. Mesmo sendo mais vantajoso que o eixo rotor horizontal, o eixo vertical perde em rentabilidade quando os ventos são altos.

Os Aerogeradores com eixo rotor horizontal são similares à estrutura de helicópteros. Ele possui um custo maior, mas liberam mais potência gerando maior eficiência e rendimento. Esse aerogerador pode ser dividido em múltiplas ou com uma ou duas pás, tipo hélice.

Na Figura 2.6 abaixo, é mostrado como se captura e se transforma a energia eólica:




Figura 2.6: Como se captura e transforma a energia eólica

Fonte: Site energia eólica no mundo

Normalmente, os aerogeradores são instalados em grupo, em uma mesma região e são chamados de parque eólicos ou usinas eólicas. A região escolhida deve ter vento forte e área física necessária para sua instalação e possibilidade de expansão. Um exemplo de parque eólico pode ser visto na Figura 2.7:



Figura 2.7: Parque Eólico de Osório

Fonte: Site do parque de Osório

Os aerogeradores devem ser escolhidos de acordo com a velocidade de vento disponível na região onde deseja-se instalar um parque eólico. Caso contrário, analisada corretamente a velocidade de vento do local, é possível que os

aerogeradores não sejam adequados, resultando em perda financeira do investimento realizado.

Com o passar dos anos os aerogeradores tiveram uma evolução, como ganharam novos formatos das pás, melhor controle e maior potência. A Figura 2.8, mostra a evolução dos aerogeradores desde 1985 até 2005.




Figura 2.8: Evolução dos Aerogeradores desde 1985 até 2005.

Fonte: Tutorial de Energia Eólica- Princípios e Tecnologias – CRESESB.

A redução da demanda por aerogeradores no mundo, esta fazendo com que os preços desses equipamentos busquem novos mercados, com preços inferiores e a valorização do real mediante o dólar, incentiva a entrada de produtos importados, como a presença de aerogeradores para a instalação de parques eólicos no Brasil.

No Brasil, os ventos possuem características constantes durante todo o ano, o que proporciona um melhor aproveitamento dos aerogeradores.

2.5

Potência do Vento

Segundo, (Pessanha et al, 2012) a potência elétrica P gerada por uma turbina eólica varia com o cubo da velocidade do vento v transversal à área A varrida pelas pás da turbina:

$$P_t = \frac{1}{2} \rho v^3 A \eta C_p \quad (2.1)$$

Onde:

P_t = potência da turbina eólica no instante t ;

ρ = massa específica do ar (Kg/m^3);

v = velocidade do vento que incide na turbina eólica (m/s);

A = área varrida pelo rotor da turbina eólica (m^2);

η = eficiência mecânica e elétrica do sistema;

C_p = coeficiente de potência.

A relação entre a potência elétrica gerada pela turbina e a velocidade do vento é normalmente apresentada na forma da curva de potência, ilustrada na Figura 2.9.




Figura 2.9: Curva típica de potência de turbinas eólicas

Fonte: Pessanha (2012) e Custódio (2010).

Segundo Custódio (2010), o coeficiente de potência de uma turbina eólica varia de acordo com a velocidade do vento. Essa variação é decorrente do fato de as pás do rotor da turbina eólica alterarem suas eficiências de acordo com a velocidade do vento. Portanto, conforme aumenta a velocidade do vento, cresce a potência da turbina eólica até alcançar a potência nominal máxima.

No entanto, os métodos de previsão de vento baseiam-se em dois tipos: os modelos físicos e modelos estatísticos. Os modelos físicos baseiam-se nas propriedades físicas do vento para fazer as previsões. Já os modelos estatísticos obtêm relações entre variáveis para obter as previsões.

3

Metodologia

Introdução

O modelo estatístico proposto, adotado na dissertação é baseado no modelo Holt-Winters. No entanto, será apresentado alguns conceitos de séries temporais e de outros modelos estatísticos de previsão.

3.1

Série Temporal e Processo Estocástico

Uma série temporal pode ser caracterizada como uma coleção de observação de uma variável aleatória, dispostas de maneira sequencial e ordenada em uma determinada unidade de tempo (semana, mês, ano, etc.). Tais observações, geralmente, estão em intervalos temporais de mesmo tamanho.

Tome-se, por exemplo, X_t a representação de uma variável aleatória X no instante de tempo t , a série temporal pode ser escrita por X_1, X_2, \dots, X_N , sendo N é o número de observações registradas pela série, o qual referido também como o tamanho da série (Souza e Camargo, 1996). As séries temporais podem ser classificadas como discretas, contínuas, determinísticas, estocásticas, multivariadas e multidimensionais.

Existem duas formas de se analisar uma série temporal: a análise no domínio do tempo, e a análise no domínio da frequência.

Na análise no domínio do tempo, considera-se a evolução temporal do processo que está sendo estudado, o objetivo desta análise é determinar a magnitude de cada evento nos diversos instantes da série. A análise é baseada, em geral, por modelos paramétricos que utilizam as funções de auto covariância e autocorrelação.

A auto covariância é a covariância da série com ela mesma, porém em um intervalo defasado em intervalos de tempo (k), podendo ser escrito da seguinte forma: covariância de X_t com X_{t+k} :

$$\gamma_k = \text{cov} [X_t, X_{t+k}] = E \{ [X_t - \mu][X_{t+k} - \mu] \} \quad (3.1)$$

onde:

μ = média do processo

Pode-se padronizar a função de autocovariância, resultando na função de autocorrelação. A mesma mede a intensidade da qual o valor tomado no tempo t depende daquele tomado no tempo $t-k$. Logo, tem-se como função de autocorrelação:

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{\text{Cov}[X_t, X_{t+k}]}{\sqrt{\text{Var}(X_t)\text{Var}(X_{t+k})}} \quad (3.2)$$

onde:

$\text{Var}(X_t) = \text{Var}(X_{t+k}) = \gamma_0$ = variância do processo

$\rho_0 = 1$

$\rho_k = \rho_{-k}$ (função de autocorrelação é simétrica em relação à origem $k=0$)

Há também a autocorrelação parcial, estendida se for medida a correlação entre duas observações seriais X_t e X_{t+k} , não considerando as observações intermediárias. Desta forma a autocorrelação parcial é representada por:

$$\text{Corr} (X_t, X_{t+k} \mid X_{t+1}, \dots, X_{t+k-1}) \quad (3.3)$$

Processo Estocástico

Os modelos utilizados para descrever séries temporais são processos estocásticos, isto é, processos controlados por leis probabilísticas.

Seja T um conjunto arbitrário. Um processo estocástico é uma família $Z = \{Z(t), t \in T\}$, tal que, para cada $t \in T$, $Z(t)$ é uma variável aleatória. Nestas condições, um processo estocástico é uma família de variáveis aleatórias, que supomos definidas num mesmo espaço de probabilidades (Morettin e Toloi, 2006).

Uma série temporal pode ser interpretada como uma realização de um processo estocástico sendo assim, uma amostra finita de observações em uma linha de tempo. O processo somente poder ser estatisticamente determinado quando todas as suas funções de distribuição de probabilidade são conhecidas até a T -ésima ordem (Barros, 2004).

Com isso, temos o fato de o não conhecimento do processo até a T -ésima ordem e portanto, assume somente uma realização do processo estocástico, já que o mecanismo gerador de dados do processo não é conhecido. Para contornar estes problemas, assumimos duas condições: Ergodicidade e Estacionariedade.

No processo estocástico estacionário algumas características permanecem constantes ao longo do tempo. Podemos analisar a estacionariedade sendo do tipo forte (estrita) ou fraca (segunda ordem). O conceito de processo não estacionário homogêneo se dá, quando se consegue um processo estacionário através de diferenças sucessivas de um determinado processo não estacionário.

Segundo PAPOULIS (1965), um processo estacionário pode ser classificado em:

- **Estritamente estacionário (ou estacionariedade forte):** quando suas estatísticas não são afetadas por variações devido à escolha da origem dos tempos, ou seja, quando as séries X_t e X_{t+k} estão distribuídas de forma idêntica, independente de “ k ”.

- **Estritamente estacionário de ordem finita:** um processo é estritamente estacionário de ordem “ i ” se a estacionariedade do item anterior não for válida

para todo t_j com j pertencente ao conjunto dos números naturais, mas somente para $j \leq i$.

- **Estacionário de segunda ordem (ou fracamente estacionário):** um processo será denominado estacionário de segunda ordem quando sua função valor médio for constante e sua função de covariância depender somente da diferença, em valor absoluto, $t_s - t_j$.

A ergodicidade acontece quando uma única realização de um processo estocástico é suficiente para obter todas as suas estatísticas. Com isso podemos verificar que todo o processo ergódico é estacionário também, visto que se for não estacionário, não conterá todas as informações necessárias para a especificação do processo.

A Figura 3.1 ilustra a sequencia e o objetivo do estudo de uma série temporal.

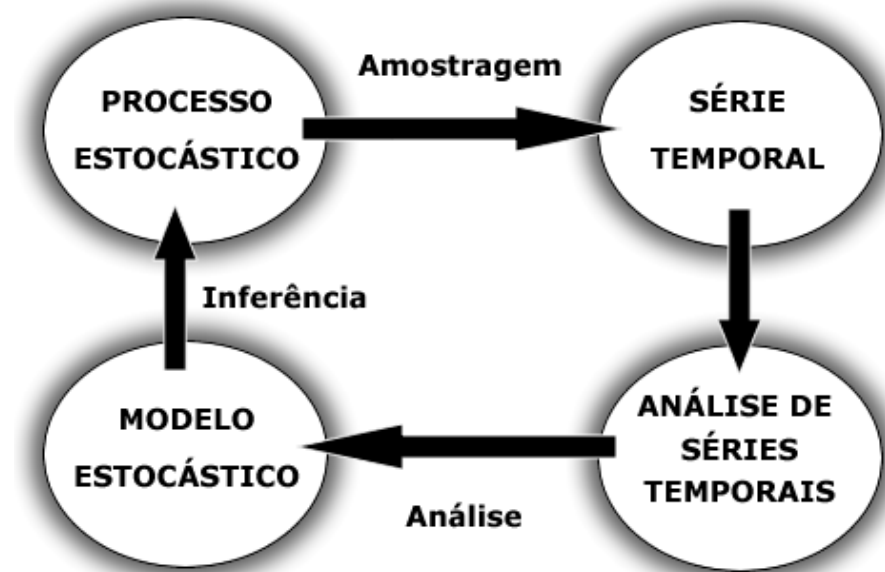


Figura 3.1: Processo Estocástico e Série Temporal.

Fonte: Livro de Séries Temporais (Souza e Camargo, 1996).

Dada uma realidade (processo estocástico) retira-se uma amostra finita de observações equiespaçadas no tempo (série temporal) e através do estudo desta amostra (análise de séries temporais) identifica-se um modelo cujo objetivo é

inferir sobre o comportamento da realidade (processo estocástico) (Souza & Camargo, 1996).

3.2

Previsão de Séries Temporais

A previsão de uma série temporal (Dielbold, 1999; Montgomery, 1990), tem como objetivo estabelecer os valores futuros da série. Uma previsão é uma estimativa quantitativa (ou conjunto de estimativas) acerca de eventos futuros, baseados na informação atual e passada da série em estudo. O horizonte de previsão é o comprimento de tempo, contado a partir de uma origem predeterminada (origem da previsão).

Podemos denotar por $\hat{Z}_t(k)$ como sendo a esperança condicional de Z_{t+k} dados os valores passados:

$$\hat{Z}_T(k) = E(Z_{T+k} | Z_T, Z_{T-1}, \dots) \quad (3.4)$$

Sendo Z_{t+k} os valores a serem previstos para $k=1,2,\dots$

Para estabelecer valores futuros para a série em estudo, é necessário que possa captar e formular um modelo matemático capaz de representar o comportamento e as características da série temporal que se deseja prever. Existe alguns modelos de previsão são classificados desta forma:

Modelos Univariados utilizam os valores passados da própria série para explicar os valores futuros. Exemplo, são os dados de energia eólica. E alguns métodos são: método de amortecimento exponencial, método de decomposição e os modelos de Box & Jenkins. Nesta dissertação foi utilizado um modelo univariado que é o modelo de Holt-Winters.

Modelos Causais ou Modelo Função de Transferência, utilizam os valores passados da própria série a ser prevista e também de outras séries que possuem

relação com a série que se vai prever. Exemplo, prever os dados de um aerogerador eólico usando uma série de temperatura.

Modelos Multivariados, são aqueles em que é possível realizar previsões de várias séries ao mesmo tempo. Exemplo, prever a carga de energia de várias concessionárias simultaneamente.

3.3

Método Ingênuo (NAÍVE)

Este método, também é conhecido como modelo Persistence e como “random walk” (passeio aleatório), e é obtido com esforço e manipulação mínimos, pois é baseado somente na informação mais recente disponível. O método consiste em repetir, para o instante futuro, o valor real do instante atual, seguindo a premissa básica de que a melhor estimativa para a previsão do valor em $t + 1$ é o valor no instante t . Podemos escrever o modelo da seguinte forma:

$$Z_{t+1} = Z_t + \epsilon_t \quad (3.5)$$

E a previsão k passos à frente $\hat{Z}_t(k)$ podemos escrever da seguinte forma:

$$\hat{Z}_t(k) = E[(Z_{t-1+k}|Z_t)] = E(Z_{t-1+k}) \quad (3.6)$$

Este método é considerado o método de previsão mais simples e por este motivo é usado como critério de comparação (benchmark), isto é, o modelo a ser testado tem que ser sempre melhor do que este.

3.4

Média Móvel

O método de previsão de demanda média móvel é de fácil entendimento e pode ser utilizado para uma enorme gama de situações, cada ponto de uma média

móvel numa série de tempo é a média aritmética ou ponderada de um número de pontos consecutivos das séries, na qual o número de pontos de dados é escolhidos de forma a eliminar os efeitos da sazonalidade ou irregularidade (MOREIRA, 2006) :

$$Z_t = \frac{1}{n}(Z_{t-1} + Z_{t-2} + \dots + Z_{t-n}) \quad (3.8)$$

Sendo n o tamanho da janela que é o parâmetro a ser ajustado. Pelo método, a cada nova observação que chega, a mais antiga é retirada. Porém o tamanho da Média Móvel permaneça fixo, o conjunto esta se movendo, daí o motivo da palavra “móvel”.

E segundo Novaes et al. (2009), o método consiste em se contemplar um conjunto de “ n ” amostras, ou observações, do sinal original e se verificar o deslocamento do filtro sobre o sinal original com passo de uma amostra.

No processo de filtragem se desconsidera a amostra mais antiga e, simultaneamente, se considera a amostra mais recente, mantendo o número de dados utilizados na ordem do filtro (“ n ”). De acordo com Chopra e Meindl (2003), isso significa que para calcular a nova média móvel adicionamos a mais recente observação e descartamos a mais antiga.

Um modelo de média móvel simples, a sua série é caracterizada localmente por seu nível. Na média móvel dupla, a série possui tendência aditiva e média móvel tripla é usada em séries de tendência quadrática, segundo Vidigal, 2007.

O modelo de média móvel simples é :

$$Z_t = a + \varepsilon_t \quad (3.9)$$

O estimador do parâmetro “ a ” no instante T é :

$$\hat{a}(T) = M_T = \frac{Z_T + Z_{T-1} + \dots + Z_{T-N+1}}{N} \quad (4.0)$$

O modelo de média móvel dupla é :

$$Z_t = a_1 + a_2 t + \varepsilon_t \quad (4.1)$$

Os estimadores no instante T são:

$$\begin{aligned} \hat{a}_1(T) &= 2M_T - M_T^{[2]} - \hat{a}_2(T)T \\ \hat{a}_2(T) &= \frac{2}{N-1} [M_T - M_T^{[2]}] \end{aligned} \quad (4.2)$$

O modelo de média móvel tripla é :

$$Z_t = a_1 + a_2 t + a_3 t^2 + \varepsilon_t \quad (4.3)$$

O modelo de previsão para os dados com sazonalidade utilizando médias móveis é :

$$\hat{Z}_T(\tau) = \frac{1}{n} E(Z_{T+\tau-S} + Z_{T+\tau-2S} + \dots + Z_{T+\tau-nS}) \quad (4.4)$$

3.5

Métodos de Amortecimento Exponencial

Os métodos de amortecimento exponencial são classificados como sendo modelos automáticos e de validade local. Somente terá um resumo dos modelos de amortecimento exponencial, simples, duplo e triplo.

Existem duas formas de se obter as equações do modelo de amortecimento: de forma heurística, e por um procedimento de mínimos quadrados, sugerido por Brown (1984).

As mudanças ocorridas numa série nesse formato são bastante lentas. No amortecimento exponencial duplo, a série possui uma tendência aditiva. Diferente daquele, no amortecimento simples, a média não é constante ao longo do tempo, ocorre, sim, uma mudança linear.

Mesmo a base é uma referência simples, esses métodos geralmente, obtém bons resultados. É normalmente usada para desenvolvimento de modelos de previsão. Além disso, a robustez e acuracidade desses métodos têm aumentado suas formas de aplicação e utilização.

3.6

Métodos de Amortecimento de Brown

Nesse método os modelos automáticos para séries não sazonais, sendo simples, duplo e triplo. Segundo Vidigal, 2007, a diferença desses modelos para os de médias móveis é a estimação das constantes de amortecimento. Com isso, será mostrado como as constantes são estimadas.

Simple:

$$\hat{a}(T) = \alpha Z_T + (1 - \alpha)Z_{T-1} = \alpha Z_T + (1 - \alpha)\hat{a}(T-1) \quad (4.5)$$

Duplo:

$$\begin{aligned} \hat{a}_1(T) &= 2S_T - S_T^{[2]} \\ \hat{a}_2(T) &= \frac{\alpha}{1 - \alpha} (S_T - S_T^{[2]}) \\ S_T &= \alpha Z_T + (1 - \alpha)S_{T-1} \\ S_T^{[2]} &= \alpha S_T + (1 - \alpha)S_{T-1}^{[2]} \end{aligned} \quad (4.6)$$

Triplo:

$$\begin{aligned}
 \hat{a}_1(T) &= 3S_T - 3S_T^{[2]} + S_T^{[3]} \\
 \hat{a}_2(T) &= \left(\frac{\alpha}{1-\alpha} \right)^2 [S_T - 2S_T^{[2]} + S_T^{[3]}] \\
 \hat{a}_3(T) &= \frac{\alpha}{2(1-\alpha)^2} [(6-5\alpha)S_T - 2(5-4\alpha)S_T^{[2]} + (4-3\alpha)S_T^{[3]}] \\
 S_T &= \alpha Z_T + (1-\alpha)S_{T-1} \\
 S_T^{[2]} &= \alpha S_T + (1-\alpha)S_{T-1}^{[2]} \\
 S_T^{[3]} &= \alpha S_T^{[2]} + (1-\alpha)S_{T-1}^{[3]}
 \end{aligned}$$

(4.7)

3.7

Método de Amortecimento Direto

O método de amortecimento direto, pode modelar funções matemáticas, pois ele tem a capacidade de corrigir os seus parâmetros de forma automática. O seu procedimento funciona da seguinte forma : ele suaviza as antigas estimativas dos parâmetros do modelo para o período corrente com o objetivo de obter estimativas revisadas, segundo Esteves,2003.

O método faz uso dos mínimos quadrados ponderados para estimar os parâmetros, (Souza, 1983).

Exemplo dessa técnica está em Quadrelli (1998), que a utilizou na previsão de carga elétrica horária e diária, com dados de uma concessionária do Brasil. Um outro exemplo do uso dessa metodologia pode ser encontrado em Esteves (2003), este modelo e o de Holt-Winters com múltiplos ciclos para fazer previsão horária, 24 passos à frente, da carga elétrica de uma concessionária do Brasil.

As estimativas iniciais dos parâmetros do modelo podem ser encontradas usando um modelo de regressão linear múltipla (detalhes ver Montgomery, 1976).

3.7.1

Holt-Winters Padrão

O modelo Holt-Winters padrão é bastante utilizado para a previsão de séries temporais que contém sazonalidade. Porém esta modelagem é capaz de comportar somente um padrão sazonal. Quando os dados de séries temporais não apresentam tendência ou sazonalidade, os métodos exponenciais simples ou por médias móveis podem ser utilizados em previsão. Na presença de tendência, o método de Holt-Winters é o mais indicado. Entretanto, a presença de sazonalidade no comportamento da série temporal, inviabiliza a utilização dos métodos mais simples, com isso utilizaremos o método de Holt-Winters também.

O método de Holt-Winters é baseado em três equações alisadoras. Uma para o nível, outra para tendência e outra para sazonalidade. Sendo que a sazonalidade pode ter efeito aditivo ou multiplicativo. O modelo aditivo, é recomendada para séries homocedásticas onde a variância não cresce ao decorrer do tempo e o modelo multiplicativo é recomendada para séries heterocedásticas que a variância é crescente. Na Figura 3.2, exemplos dessas componentes:




Figura 3.2: Exemplo da componente tendência e sazonalidade

Fonte: Livro de Séries Temporais (Souza e Camargo, 1996)

3.7.1.1

Holt-Winters Aditivo

O Holt-Winters aditivo é utilizado quando a amplitude da variação sazonal mantém-se constante, ou seja, a diferença entre o maior e o menor ponto de demanda nos ciclos permanece constante com o passar do tempo. Com isso sendo a série, Z_t , com tendência e com apenas um padrão sazonal. Podemos escrever o modelo da seguinte maneira:

$$Z_t = a_1 + a_2 t + c_t + \varepsilon_t \quad (4.8)$$

Sendo, a primeira componente de nível, a segunda de tendência linear, a terceira o fator sazonal e a última componente é aleatório.

Considerando que o ciclo sazonal tem comprimento (L), e os fatores sazonais somam o seguinte tamanho.

$$\sum_{i=1}^L c_i(t) = 0 \quad (4.9)$$

Denotando, as estimativas dos fatores sazonais e das componentes de nível e de tendência do modelo aditivo, no instante T, por $\hat{a}_1(T), \hat{a}_2(T), \hat{c}_i(T)$, tem-se que para este instante :

$$\textbf{Nível:} \quad \hat{a}_1(T) = \alpha [Z_T - \hat{c}_{m(T)}(T-1)] + (1-\alpha) [\hat{a}_1(T-1) + \hat{a}_2(T-1)] \quad (5.0)$$

$$\textbf{Tendência:} \quad \hat{a}_2(T) = \beta [\hat{a}_1(T) - \hat{a}_1(T-1)] + (1-\beta) \hat{a}_2(T-1) \quad (5.1)$$

$$\textbf{Sazonalidade:} \quad \hat{c}_{m(T)}(T) = \gamma [Z_T - \hat{a}_1(T)] + (1-\gamma) \hat{c}_{m(T)}(T-1) \quad (5.2)$$

Sendo α , β e γ as constantes de amortecimento.

O modelo aditivo é importante para séries que possuem um efeito sazonal aditivo e um efeito de tendência aditivo. Caso a componente de tendência seja desnecessária, pode ser retirada da modelagem. A subtração da componente de sazonalidade de Z_t , na equação 5.0, é feita para que a variável seja desazonalizada. O objetivo dessa desazonalização é deixar que o processo de atualização da componente de nível seja apenas baseado na estimativa prévia dela mesma e da tendência.

Já na componente de tendência, a forma de calcular é igual que na modelagem pelo método multiplicativo. Assim, a equação de previsão usa o fator sazonal estimado no último instante, para τ períodos à frente, feita no instante T , pode ser escrita por:

$$\hat{Z}_T(\tau) = \hat{a}_1(T) + \hat{a}_2(T)\tau + \hat{c}_{m(T+\tau)}(T) \quad (5.3)$$

Com isso, se desejar fazer previsões para períodos mais distantes que 1 passo a frente, poderão ser feitas usando o fator sazonal apropriado. Sendo assim, o fator sazonal correspondente ao período que se deseja prever.

O uso do modelo Holt-Winters não necessita que os dados possuam distribuição normal e/ou sejam estacionários, o que pode apresentar-se como uma vantagem. No entanto, pode limitar a aplicabilidade em situações em que é impossível aumentar o tamanho da amostra considerada, pois se o modelo apresentar discrepâncias consideradas inaceitáveis.

Segundo Esteves (2003), para utilizar este modelo aditivo, é preciso que os parâmetros iniciais $\hat{a}_1(0), \hat{a}_2(0), \hat{c}_i(0), i=1, \dots, L$, sejam determinados. A estimativa de mínimos quadrados desses parâmetros iniciais pode ser obtida através da análise dos dados históricos e para melhor detalhamento na obtenção dos valores iniciais, ver em Montgomery (1990). Para a inicialização dos parâmetros, Taylor (2003a) utilizou o mesmo procedimento utilizado em Williams & Miller (1999).

Para facilitar a explicação, segundo Vidigal (2007), a série temporal será trabalhada na forma matricial, sendo que nas linhas estarão os dias a serem utilizados na definição dos parâmetros iniciais e nas colunas estará o número de

Segundo Esteves (2003), assumo que a série temporal, X_T , possa ser escrita em uma forma matricial, onde as linhas representam o ciclo menor (dia, L) e as colunas as horas sequenciais, como abaixo :

(5.4)

(5.5)

Passo 2: Fatores dos Ciclos Diários Grosseiros

$$\begin{array}{c}
 c_{1,1,1}^* \ c_{1,1,2}^* \ \dots \ c_{1,1,L_1}^* \\
 c_{1,2,1}^* \ c_{1,2,2}^* \ \dots \ c_{1,2,L_1}^* \\
 \dots \dots \dots \\
 c_{1,I,1}^* \ c_{1,I,2}^* \ \dots \ c_{1,I,L_1}^*
 \end{array}
 \quad (5.6)$$

onde:

$$c_{1,i,j}^* = \frac{x_{ij}}{\bar{x}_i} \quad \text{para } j = 1, \dots, L_1 \quad \text{e } i = 1, \dots, I
 \quad (5.7)$$

Passo 3: Fatores dos Ciclos Diários

$$c_{1,j}^* = \frac{\sum_{i=1}^I c_{1,i,j}^*}{I} \quad \text{para } j = 1, \dots, L_1
 \quad (5.8)$$

Passo 4: Fatores dos Ciclos Diários Normalizados

$$c_{1,j} = \left(\frac{c_{1,j}^*}{\sum_{j=1}^{L_1} c_{1,j}^*} \right) \times L_1 \quad \text{para } j = 1, \dots, L_1
 \quad (5.9)$$

Passo 5: Estimativas Iniciais para Parâmetros do Modelo

$$\hat{b}_1(0) \cong \bar{x}_1$$

$$\hat{b}_2(0) \cong (\bar{x}_2 - \bar{x}_1)/L_2$$

$$\hat{c}_{1,j}(0) \cong c_{1,j} \quad \text{para } j = 1, \dots, L_1$$

$$\hat{c}_{2,j}(0) \cong c_{2,j} \quad \text{para } j = 1, \dots, L_2 \quad (6.0)$$

3.7.1.2

Holt-Winters Multiplicativo

O modelo de Holt-Winters pode ter o caso multiplicativo. É utilizado quando a amplitude da variação sazonal aumenta com o tempo, ou seja, a diferença entre o maior e o menor ponto de demanda nos ciclos cresce com o passar do tempo. Com isto, a componente de tendência continua tendo uma formulação aditiva. Logo, ele é capaz de incorporar tanto a tendência linear quanto o efeito sazonal multiplicativo.

Segundo Esteves (2003), a sazonalidade é chamada multiplicativa pois o nível da série temporal é multiplicado pelo índice sazonal. É preciso lembrar, que o modelo Holt-Winters Multiplicativo não é um subgrupo dos modelos ARIMA, como o modelo aditivo.

Este modelo pode ser escrito da seguinte maneira:

$$Z_t = (a_1 + a_2 t)c_t + \varepsilon_t \quad (6.1)$$

Sendo, a primeira componente é de nível, a segunda de tendência linear, a terceira o fator sazonal e a última componente é aleatório.

Considerando que o ciclo sazonal tem comprimento (L), a soma fatores sazonais é igual ao tamanho da sazonalidade:

$$\sum_{i=1}^L c_i(t) = L \quad (6.2)$$

Então, denotando por $\hat{a}_2(T), \hat{c}_i(T)$, para $i=1, \dots, L$, sendo a componente de tendência e a componente sazonal, no final de qualquer período e a componente de nível é denotada por $\hat{a}_1(T)$, estimados em T. A atualização da estimativa e da previsão é feita de forma simples. A partir da equação de previsão todos os fatores sazonais são estimados mas somente aquele correspondente à informação recebida é atualizado. No final do período T, efetua-se os seguintes cálculos, admitindo o conhecimento de seus resultados em T-1, sendo:

$$\textbf{Nível:} \quad \hat{a}_1(T) = \alpha \left(\frac{Z_T}{\hat{c}_{m(T)}(T-1)} \right) + (1-\alpha)(\hat{a}_1(T-1) + \hat{a}_2(T-1)) \quad (6.3)$$

$$\textbf{Tendência:} \quad \hat{a}_2(T) = \beta(\hat{a}_1(T) - \hat{a}_1(T-1)) + (1-\beta)\hat{a}_2(T-1) \quad (6.4)$$

$$\textbf{Sazonalidade:} \quad \hat{c}_{m(T)}(T) = \gamma \left(\frac{Z_T}{\hat{a}_1(T)} \right) + (1-\gamma)\hat{c}_{m(T)}(T-1) \quad (6.5)$$

Sendo α , β e γ são constantes de amortecimento.

Os demais fatores sazonais:

$$\hat{c}_j(T) = \hat{c}_j(T-1); \quad j = 1, 2, \dots, L; \quad j \neq m(T) \quad (6.6)$$

O procedimento de determinação dos parâmetros iniciais do método de Holt-Winters multiplicativo com um único padrão sazonal, descrito anteriormente, é facilmente adaptável, para o método Holt-Winters com múltiplos ciclos.

A normalização dos fatores sazonais, ou seja, faz com que a soma dos novos fatores em T seja igual a L, segundo Souza (1983).

$$c_j(T) = \left[\frac{\hat{c}_j^*(T)}{\sum_{j=1}^L \hat{c}_j^*(T)} \right] \cdot L \quad (6.7)$$

Onde $\hat{c}_j^*(T)$ são os fatores não normalizados estimados, na equação de sazonalidade (6.5).

Visto em Esteves (2003), o desenvolvimento do sistema de previsão no método de Winters requer que os valores iniciais dos parâmetros. As informações históricas, quando disponíveis, podem ser usadas com o propósito de fornecer algumas ou todas as estimativas iniciais necessárias. A definição para achar a inicialização para o caso multiplicativo será o mesmo procedimento usado no caso aditivo que pode ser visto na seção 3.7.1.1, que o passo a passo será o mesmo. O procedimento formal de obtenção destes valores iniciais pode ser visto em detalhes em Montgomery, (1976).

3.7.2

Holt-Winters com Múltiplos Ciclos

Apesar do modelo Holt-Winters padrão ser amplamente utilizado para a previsão de séries temporais com comportamentos sazonais, o método somente comporta um padrão sazonal correspondente a mudança de comportamento de uma dada série decorrente da mudança das estações do ano. Para resolver esse problema, Taylor (2002) propôs uma extensão do modelo Holt-Winters, extensão esta

onde existiria a possibilidade da incorporação de múltiplos ciclos a modelagem. Esse método é adequado quando existem dois ou mais ciclos diferentes na série em estudo.

Temos exemplos de modelagem com múltiplos ciclos nas dissertações da Esteves (2003) e Vidigal (2007), que a série é de consumo de carga e por este motivo faz necessário o uso de dois ciclos ou mais.

No caso da série, em questão utilizada de velocidade de vento só poderá ter 1 ciclo. Por este motivo não foi utilizado este método de Múltiplos Ciclos.

A formulação é composta por índices de ciclos distintos, C_1 e C_2 com períodos, L_1 e L_2 , respectivamente.

Com relação às equações de atualização dos parâmetros de um instante genérico $T-1$ para o instante seguinte T , o procedimento iterativo é como mostrado abaixo :

De acordo com Esteves (2003), seja o instante $T-1$, onde conhecemos : o nível, $\hat{b}_1(T-1)$, a tendência, $\hat{b}_2(T-1)$, os fatores do ciclo 1, $\hat{c}_{1j}(T-1)$ para $j=1, \dots, L_1$, e os fatores do ciclo 2, $\hat{c}_{2j}(T-1)$ para $j=1, \dots, L_2$. Observando X_T no instante T , as equações de atualização dos parâmetros para o instante T s serão:

$$\text{Nível: } \hat{b}_1(T) = \alpha \left(x_T / \hat{c}_{1b_1(T)}(T-1) \hat{c}_{2b_2(T)}(T-1) \right) + (1 - \alpha) \left(\hat{b}_1(T-1) + \hat{b}_2(T-1) \right) \quad (6.8)$$

$$\text{Tendência: } \hat{b}_2(T) = \beta \left(\hat{b}_1(T) - \hat{b}_1(T-1) \right) + (1 - \beta) \hat{b}_2(T-1) \quad (6.9)$$

$$\text{Ciclo 1: } \hat{c}_{1b_1(T)}(T) = \gamma \left(x_T / \hat{b}_1(T) \hat{c}_{2b_2(T)}(T-1) \right) + (1 - \gamma) \hat{c}_{1b_1(T)}(T-1) \quad (7.0)$$

$$\text{Ciclo 2: } \hat{c}_{2b_2(T)}(T) = \delta \left(x_T / \hat{b}_1(T) \hat{c}_{1b_1(T)}(T-1) \right) + (1 - \delta) \hat{c}_{2b_2(T)}(T-1) \quad (7.1)$$

onde $h_1(T)$ é a “hora” correspondente ao instante T (assumindo valores de 1 a L_1) enquanto $h_2(T)$ é a “hora” correspondente ao instante T (assumindo valores de 1 a L_2). Assim, como no caso do Holt-Winters convencional, temos que somente os fatores dos ciclos 1 e 2 correspondentes ao instante T, isto é, $\hat{c}_{1h_1(T)}(T)$ e $\hat{c}_{2h_2(T)}(T)$, são atualizadas em T, de acordo com as equações (7.0) e (7.1). Para demais fatores temos :

$$\begin{aligned}\hat{c}_{1j}(T) &= \hat{c}_{1j}(T-1); & j &= 1, 2, \dots, L_1; & j &\neq h_1(T) \\ \hat{c}_{2j}(T) &= \hat{c}_{2j}(T-1); & j &= 1, 2, \dots, L_2; & j &\neq h_2(T)\end{aligned}\quad (7.2)$$

Os fatores devem ser normalizados a cada atualização para garantir que suas respectivas somas sejam L_1 e L_2 respectivamente, sendo assim:

$$\sum_{j=1}^{L_1} \hat{c}_{1j}(\cdot) = L_1 \quad \text{e} \quad \sum_{j=1}^{L_2} \hat{c}_{2j}(\cdot) = L_2 \quad (7.3)$$

A equação de previsões τ -passos à frente feita na origem T é :

$$\hat{x}_T(\tau) = (\hat{b}_1(T) + \hat{b}_2(T)\tau) \hat{c}_{1h_1(T+\tau)}(T) \cdot \hat{c}_{2h_2(T+\tau)}(T) \quad (7.4)$$

3.7.3

Métricas de Desempenho

Serão utilizadas algumas métricas de comparação para avaliar o desempenho dos modelos. Avaliando através de medidas estatísticas, comparando os valores do histórico ajustado versus os valores reais e verificando o erro na previsão um passo à frente. Existem muitos critérios possíveis de utilização para avaliação dos modelos, mas neste trabalho serão utilizados os seguintes: RMSE,

MAE, MAPE.

$$\text{Raiz do erro quadrático médio (RMSE)} = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2} = \sqrt{\frac{1}{N} \sum_{t=1}^N e_t^2} \quad (7.5)$$

$$\text{Erro absoluto médio (MAE)} = \frac{1}{N} \sum_{t=1}^N |e_t| \quad (7.6)$$

$$\text{Erro percentual absoluto médio (MAPE)} = \frac{100}{N} \sum_{t=1}^N \frac{|e_t|}{y_t} \quad (7.7)$$

RMSE é a raiz da variância do erro como se fosse o desvio-padrão. O MAE é o erro médio, ou seja, as diferenças dos valores reais e ajustados ponderadas em média. O MAPE é o percentual de erro que o modelo comete na previsão, considerado melhor quanto mais próximo de zero.

Além das métricas acima, será utilizada uma métrica que leva em consideração o método naíve é o coeficiente U de Theil. Ele avalia a previsão levando em consideração o erro apresentado pelo modelo naíve e o modelo proposto. Sendo assim, podemos escrever da seguinte forma:

$$U = \frac{\sqrt{\sum_{i=1}^N (z_t - \hat{z}_t)^2}}{\sqrt{\sum_{i=1}^N (z_t - z_{t-1})^2}} \quad (7.8)$$

A interpretação do coeficiente pode ser da seguinte maneira:

- Se o coeficiente $U = 1$, o método naïve é tão eficiente quanto o método em avaliação.
- Se o coeficiente $U < 1$, o método naïve é menos eficiente que o método em avaliação.
- Se o coeficiente $U > 1$, o método naïve é mais eficiente que o método em avaliação.
- Se o coeficiente $U = 0$, o método em avaliação é perfeito.

Lembrando que em geral esperamos que o modelo avaliado apresente um coeficiente U de Theil menor que 1 e sendo assim erro menor que o da previsão apresentado por um modelo ingênuo (naïve).

4

Análise Exploratória

Neste capítulo serão descritas as análises exploratórias para verificar as principais características da série temporal. A série será analisada através de gráficos e testes estatísticos para melhor compreender as componentes da série como: a sazonalidade, componente cíclica e tendência.

A série estudada do Projeto SONDA contém observações da velocidade do vento e direção a cada 10 minutos no ano de 2006. Com isso a série tem velocidade média de vento de 5,31m/s, o que será apresentado na Tabela 4.1 de estatísticas de resumo da série temporal de São João do Cariri – PB.

Tabela 4.1: Estatísticas de resumo da série de São João do Cariri - PB

Estatísticas de Resumo	
Primeiro Quartil (m/s)	3,6367
Terceiro Quartil (m/s)	6,8567
Média (m/s)	5,3101
Mediana (m/s)	5,2200
Variância (m/s)	4,6171
Desvio Padrão (m/s)	2,1492
Mínimo (m/s)	0,2317
Máximo(m/s)	11,5083
Número de Observações	8760

Fonte: Elaboração própria.

Com os dados foi construída a série de médias horárias da velocidade do vento, no Gráfico 4.1. Além disso, apresenta indícios da presença de sazonalidade e é visualmente estacionária na média.




Gráfico 4.1: Série horária de São João do Cariri

Fonte: Elaboração própria.

Pelo teste da raiz unitária é verificado se a série não varia em relação ao tempo. Foi utilizado para tal o Teste ADF (Augmented Dickey – Fuller), no qual a hipótese nula é de que a série possui raiz unitária, ou seja, não é estacionária. A hipótese alternativa é a estacionariedade da série.

Além disso que está evidenciado no gráfico da série que é estacionária, podemos observar na Tabela 4.2 que rejeita a hipótese nula e portanto o processo é estacionário.

Tabela 4.2: Teste Augmented Dickey-Fuller.

Teste Dickey - Fuller aumentado	
Estatísticas de teste	-9,0472
P-valor	< 0,01
Ordem do lag	20

Fonte: Elaboração própria.

Na Figura 4.1, mostra que os ventos em São João do Cariri são predominantemente da região sul (Chou et al, 2006), com isso, os dados de direção do vento tem efeito reduzido na previsão, visto que sopram na mesma direção.




Figura 4.1: Rosa dos ventos a 50 m de altura.
Fonte: Pessanha, Silva e Souza – SPOLM (2010).

No Gráfico 4.2, podemos observar a velocidade do vento ao longo do dia, no período da noite a partir das 21 horas os ventos sofrem um aumento, indo ao máximo de velocidade às 23 horas. E o horário de menor intensidade do vento é em torno das 9 horas da manhã.

No Gráfico 4.3, mostra a velocidade média do vento ao longo do ano e com isso observamos que os ventos apresentam intensidades diferentes. Sendo assim o maior potencial de vento no período de agosto a janeiro e o menor pico de intensidade em abril.




Gráfico 4.2: Médias horárias da velocidade do vento.

Fonte: Elaboração própria.




Gráfico 4.3: Médias mensais da velocidade do vento.

Fonte: Elaboração própria.

O periodograma é útil para apresentar a análise espectral da série, onde podemos verificar a existências dos picos observados pela representação gráfica e na determinação das freqüências significativas. Na Figura 4.2, foram identificados três picos significativos que são de 1 ano, 24 horas e 12 horas.




Figura 4.2: Periodograma da série da velocidade do vento.

Fonte: Elaboração própria.

Nos Gráficos 4.4 e 4.5 podemos analisar a função de autocorrelação e função de autocorrelação parcial da série. Na FAC (função de autocorrelação), nota a existência de picos nos lags múltiplos de 12 e 24, com a presença de uma forte correlação entre os dados. No Gráfico 4.6 podemos observar a presença de sazonalidade na série, neste gráfico tirei a tendência e foi observada a série com várias curvas assim predominando a sazonalidade, como visto também na FAC e FACP.




Gráfico 4.4: FAC da série da velocidade do vento.

Fonte: Elaboração própria.




Gráfico 4.5: FACP da série da velocidade do vento.

Fonte: Elaboração própria.




Gráfico 4.6: Sazonalidade da série horária

Fonte: Elaboração própria.

O histograma da distribuição de frequências da velocidade do vento demonstra as caudas mais pesadas que de uma distribuição normal e revela uma distribuição levemente assimétrica, ver Figura 4.3. Já o QQ-Plot revela que as observações se afastam um pouco da bissetriz imaginária, com isso tem um desvio em seguir a distribuição normal, ver Figura 4.4. Adicionalmente, temos o boxplot que podemos observar que a média não se afasta da mediana e que as observações não apresentam outliers relevantes, ver Figura 4.5.




Figura 4.3: Histograma da série.
Fonte: Elaboração própria.




Figura 4.4: QQ-Plot da série.
Fonte: Elaboração própria.




Figura 4.5: Boxplot da série.

Fonte: Elaboração própria.

Ainda existem vários testes que tem o objetivo de comprovar estatisticamente que esta série não segue a distribuição normal, são eles: O teste de Jarque Bera e o não paramétrico de Kolmogorov Smirnov.

O Teste de Jarque Bera se baseia nos resíduos do método dos mínimos quadrados. Que necessita da diferença entre os coeficientes da assimetria e da curtose, com isso serve para testar a hipótese nula de que a amostra foi extraída de uma distribuição normal e a hipótese alternativa que não segue uma normal. E o Teste de Kolmogorov Smirnov rejeitamos a hipótese nula de que as observações da velocidade do vento tenham distribuição normal. Portanto podemos observar na Tabela 5.3 que a série não segue uma distribuição normal.

Tabela 4.3: Teste de Normalidade.

Teste de Normalidade	P-valor
Jarque Bera	< 0,01
Kolmogorov Smirnov	< 0,01

Fonte: Elaboração própria.

As distribuições de Weibull ou de Rayleigh são os modelos probabilísticos que melhor descrevem a distribuição de frequência da velocidade do vento (CUSTÓDIO, 2009). A função densidade de probabilidade da distribuição de Weibull é:

$$f(v) = \frac{k}{c} \left(\frac{v}{c}\right)^{k-1} e^{-\left(\frac{v}{c}\right)^k} \quad (7.9)$$

Onde:

v = a variável aleatória velocidade do vento em m/s ($v \geq 0$);

c = fator de escala (m/s e $c > 1$);

K = o fator de forma (adimensional e $k > 0$).

Segundo Pessanha et al (2012), a distribuição de Rayleigh é a distribuição de Weibull com parâmetro de forma (k) igual a 2. Como a distribuição de Rayleigh é um caso particular da distribuição de Weibull. O fator de escala c tem relação direta com a velocidade média e o k é um indicador da constância do vento, quanto maior o valor de k menor a dispersão em torno da velocidade média, tipicamente assume valores entre 2 e 3.

Em regiões de ventos alísios, como no Nordeste brasileiro, o parâmetro k pode atingir valores superiores a 6 (AMARANTE et al, 2001).

A distribuição Rayleigh é usada quando o regime dos ventos possui velocidade moderada. Com isso, é preciso conhecer apenas a velocidade média dos ventos para determinar a frequência da distribuição. A distribuição Rayleigh é dada da seguinte equação:

$$f(v) = \frac{\pi}{2} \frac{v}{V^2} e^{-\left(\frac{\pi}{4}\right)\left(\frac{v}{V}\right)^2} \quad (8.0)$$

Onde:

v = velocidade do vento (m/s);

V = velocidade média do vento (m/s).

5

Modelagem

5.1

Aplicação do Modelo

Com base nas análises gráficas feitas para a série em questão, no capítulo 4 na análise exploratória, foi notada a existência de comportamento cíclico diário e como os dados são de velocidade do vento só teremos 1 ciclo de 24 horas, por esta razão, iremos então, utilizar o modelo de Holt-Winters Padrão Aditivo e Multiplicativo.

Segundo Esteves (2003) e Vidigal (2007), utilizaram uma série de consumo de carga e esta série tem comportamentos cíclicos diários, semanais e mensais, por este motivo foi utilizado Holt- Winters com Múltiplos Ciclos. Conforme dito antes, a minha série em questão só apresenta 1 ciclo, sendo ele diário e como sendo algo inédito, não visto em outros trabalhos com dados de velocidade do vento, isto me motivou a utilizar o Modelo de Holt-Winters.

Na aplicação para a série de velocidade de vento da estação de São João de Cariri, iremos determinar somente 1 ciclo, o diário, sendo especificado como L_1 . Com isso, L_1 terá 24 fatores de amortecimento, cada um correspondendo a cada uma das 24 horas do dia. O modelo proposto, exceto a parte residual, é estimado via mínimos quadrados. Essa estimação permite que sejam coletados os resíduos, que é a diferença entre o estimado e o observado.

A seguinte etapa do processo é a estimação dos parâmetros iniciais que serão calculados seguindo os procedimentos descritos no item 3.9, do capítulo 3. Para tal, segundo Dantas (2011) foram considerados 50 dias de dados. O motivo da escolha de se utilizar 50 dias advém do fato de Gneiting et al (2006) terem advertido que períodos entre 30 e 60 dias de treino apresentam melhores previsões. A modelagem é feita utilizando fatores sazonais. Com os parâmetros estimados, iremos fazer as previsões. Os valores previstos são incorporados aos componentes diários previstos no modelo via mínimos quadrados, com isso dando

na previsão final. Os fatores sazonais podem ser incorporados ao modelo de forma aditiva ou multiplicativa. Nesta dissertação foi utilizado o software “R”.

Abaixo seguem os parâmetros iniciais do modelo aditivo e do multiplicativo encontrados e a sazonalidade:

Modelo Holt- Winters Aditivo:

Nível Inicial:

$$\hat{a}_1(0) = 4.0748$$

Tendência Inicial:

$$\hat{a}_2(0) = 0.009$$

Fatores Sazonais (C_i):

C1 = 2.4212; C2 = 2.9982; C3 = 2.9997; C4 = 2.0946; C5 = 0.7139;
 C6 = -0.03; C7 = -0.5041; C8 = -0.4465; C9 = -0.3904; C10 = -0.326;
 C11 = -0.1416; C12 = 0.1435; C13 = 0.2729; C14 = -0.1597;
 C15 = -1.4671; C16 = -2.4337; C17 = -2.263; C18 = -2.0794;
 C19 = -1.6813; C20 = -1.2895; C21 = -0.6861;
 C22 = -0.1363; C23 = 0.7152; C24 = 1.6757

Modelo Holt- Winters Multiplicativo:

Nível Inicial:

$$\hat{a}_1(0) = 3.8392$$

Tendência Inicial:

$$\hat{a}_2(0) = 0.0077$$

Fatores Sazonais (Ci):

$$\begin{aligned} C1 &= 1.433; C2 = 1.5114; C3 = 1.5098; C4 = 1.342; C5 = 1.1071; \\ C6 &= 0.9792; C7 = 0.8982; C8 = 0.893; C9 = 0.9073; C10 = 0.9269; \\ C11 &= 0.965; C12 = 1.003; C13 = 1.0285; C14 = 0.969; C15 = 0.7655; \\ C16 &= 0.6052; C17 = 0.6263; C18 = 0.6631; C19 = 0.719; \\ C20 &= 0.7967; C21 = 0.8928; C22 = 0.9976; C23 = 1.1525; \\ C24 &= 1.3078 \end{aligned}$$

As constantes de amortecimento, α , β e γ foram definidas através da minimização da média dos erros ao quadrado (*mean square error* – MSE) seguindo um procedimento de otimização. Na previsão um passo à frente. As constantes de amortecimento estimadas foram as seguintes, para o Modelo Holt-Winters Aditivo: 0.9802 para a constante de nível, 1e-04 para a constante de tendência e 1e-04 para a constante de ciclo diário.

E para o Modelo Holt-Winters Multiplicativo: 0.9995 para a constante de nível, 1e-04 para a constante de tendência e 1e-04 para a constante de ciclo diário.

Com as informações acima, podemos escrever as equações dos parâmetros do modelo e a equação de previsão.

Para o Modelo Holt-Winters Aditivo:Nível:

$$\hat{a}_1(T) = 0.98[Z_t - \hat{c}_m(T)(T-1)] + (1-0.98)[\hat{a}_1(T-1) + \hat{a}_2(T-1)] \quad (8.1)$$

Tendência:

$$\hat{a}_2(T) = 1e-04 [\hat{a}_1(T) - \hat{a}_1(T-1)] + (1-1e-04)\hat{a}_2(T-1) \quad (8.2)$$

Sazonalidade:

$$\hat{c}_{m(T)}(T) = 1e-04 [Z_t - \hat{a}_1(T)] + (1-1e-04)\hat{c}_{m(T)}(T-1) \quad (8.3)$$

Para o Modelo Holt-Winters Multiplicativo:Nível:

$$\hat{a}_1(T) = 0.99\{Z_t / [\hat{c}_{m(T)}(T-1)]\} + (1-0.99)[\hat{a}_1(T-1) + \hat{a}_2(T-1)] \quad (8.4)$$

Tendência:

$$\hat{a}_2(T) = 1e-04 [\hat{a}_1(T) - \hat{a}_1(T-1)] + (1-1e-04)\hat{a}_2(T-1) \quad (8.5)$$

Sazonalidade:

$$\hat{c}_{m(T)}(T) = 1e-04 [Z_t / \hat{a}_1(T)] + (1-1e-04) \hat{c}_{m(T)}(T-1) \quad (8.6)$$

Uma das vantagens do modelo Holt-Winters é que não exige a normalidade dos erros, nem que a série seja um processo estacionário (ruído branco). A seguir iremos analisar os resíduos do modelo Holt-Winters Aditivo pois o modelo aditivo é mais apropriado pelo fato da série não ser econômica. A Tabela 5.1 abaixo apresenta as estatísticas de resumo da série de resíduos gerado pelo modelo Holt-Winters Aditivo e o Gráfico 5.1 apresenta o gráfico da série dos resíduos.

Tabela 5.1: Resumo dos Resíduos.

Medidas de Resumo	
Mínimo	-3,1680
Máximo	4,9920
Primeiro Quartil	-0,5392
Terceiro Quartil	0,4612
Média	-0,0048
Mediana	-0,0762

Fonte: Elaboração própria.




Gráfico 5.1: Série dos Resíduos.

Fonte: Elaboração própria.

Os gráficos da função de autocorrelação e autocorrelação parcial dos resíduos mostram presença de correlação, ver Gráficos 5.2 e 5.3. Sendo assim, a função de autocorrelação descreve a correlação entre duas observações adjacentes da mesma série temporal, ocorridas em diferentes períodos, enquanto a função de autocorrelação parcial mede o grau de associação entre as observações de uma série temporal quando o efeito de defasagem é retirado.

E o teste de Ljung-Box rejeitou a hipótese H_0 (pvalor = 0,8545) de que os dados são independentes.




Gráfico 5.2: Função de autocorrelação dos resíduos.
Fonte: Elaboração própria.




Gráfico 5.3: Função de autocorrelação parcial dos resíduos.
Fonte: Elaboração própria.

Os gráficos do histograma e do QQ-Plot, mostram que os dados se afastam da distribuição normal, ver Figuras 5.1 e 5.2 No gráfico QQ-Plot podemos observar que os dados se afastam um pouco da reta bissetriz imaginária. E além da inspeção visual, podemos observar o teste de Jarque Bera que o P-valor $< 2.2e-16$, logo a hipótese de normalidade deve ser rejeitada.




Figura 5.1: Histograma dos resíduos.

Fonte: Elaboração própria.




Figura 5.2: Q-Q Plot dos resíduos.

Fonte: Elaboração própria.

O modelo de Holt-Winters foi reestimado a cada nova informação trazida ao modelo. A previsão final é obtida com a incorporação da previsão, no modelo de Holt-Winters, no horizonte de previsão de interesse.

Considerando a previsão um passo à frente, no Figura 5.3 do modelo de Holt-Winters Aditivo e no Figura 5.4 do modelo de Holt-Winters Multiplicativo apresenta os resultados para o modelo final, onde as observações previstas são as 168 horas da primeira semana do ano de 2007:




Figura 5.3: Valores observados e previsão 1 passo à frente (Modelo Aditivo).

Fonte: Elaboração própria.




Figura 5.4: Valores observados e previsão 1 passo à frente (Modelo Multiplicativo).

Fonte: Elaboração própria.

Podemos observar nos gráficos acima, da previsão criada pelo modelo e dos valores observados no período, demonstra que os valores previstos estão bem próximos dos valores reais. Com isso, comprovando que a primeira semana do ano 2007 o modelo teve um bom desempenho utilizando previsões um passo à frente. E o U de Theil do modelo avaliado foi menor que 1.

E na Tabela 5.2 mostra os valores previstos do modelo Holt-Winters Aditivo e na Tabela 5.3, os valores previstos do modelo Holt-Winters Multiplicativo, em ambos não apresentam grandes desvios dos valores reais.

Tabela 5.2: Métricas de comparação - Aditivo (1 passo à frente).

Modelo HW Aditivo	
Métricas	Resultados
RMSE	0,894
MAPE	12,93%

Fonte: Elaboração própria.

Tabela 5.3: Métricas de comparação - Multiplicativo (1 passo à frente).

Modelo HW Multiplicativo	
Métricas	Resultados
RMSE	0,935
MAPE	13,03%

Fonte: Elaboração própria.

Ainda foi testado as previsões utilizando dois, três, quatro, cinco e seis passos (horas) à frente, também na primeira semana do ano de 2007. Nas Figuras 5.5, 5.6, 5.7, 5.8, 5.8.1, os resultados do modelo Holt-Winters Aditivo e nas Figuras 5.8.2, 5.8.3, 5.8.4, 5.8.5, 5.8.6, os resultados do modelo Holt-Winters Multiplicativo.

Para o Modelo Holt-Winters Aditivo




Figura 5.5: Valores observados e previsão 2 passos à frente.

Fonte: Elaboração própria.




Figura 5.6: Valores observados e previsão 3 passos à frente.

Fonte: Elaboração própria.




Figura 5.7: Valores observados e previsão 4 passos à frente.

Fonte: Elaboração própria.




Figura 5.8: Valores observados e previsão 5 passos à frente.

Fonte: Elaboração própria.




Figura 5.8.1: Valores observados e previsão 6 passos à frente.

Fonte: Elaboração própria.

Para o Modelo Holt-Winters Multiplicativo




Figura 5.8.2: Valores observados e previsão 2 passos à frente.

Fonte: Elaboração própria.




Figura 5.8.3: Valores observados e previsão 3 passos à frente.

Fonte: Elaboração própria.




Figura 5.8.4: Valores observados e previsão 4 passos à frente.

Fonte: Elaboração própria.




Figura 5.8.5: Valores observados e previsão 5 passos à frente.

Fonte: Elaboração própria.




Figura 5.8.6: Valores observados e previsão 6 passos à frente.

Fonte: Elaboração própria.

Os modelos de Holt-Winters Aditivo e Multiplicativo, seus resultados de maneira geral, consegue acompanhar os valores reais, pode ser visto nos gráficos acima. Aliás, os modelos propostos apresentam melhores resultados que o modelo naïve. Ficando evidente que acontece uma piora na previsão do modelo com o aumento do horizonte de previsão. A Tabela 5.4, são os resultados das métricas de

comparação do modelo Holt-Winters Aditivo e na Tabela 5.5 são os resultados do modelo Holt-Winters Multiplicativo.

Tabela 5.4: Métricas de comparação.

Modelo HW Aditivo	RMSE	RMSE (Naíve)	MAPE	MAPE (Naíve)
1 passo à frente	0,8943 m/s	0,9333 m/s	12,93%	13,74%
2 passos à frente	1,1495 m/s	1,4629 m/s	16,20%	21,80%
3 passos à frente	1,2400 m/s	1,9299 m/s	17,51%	30,76%
4 passos à frente	1,5154 m/s	2,2930 m/s	20,75%	38,11%
5 passos à frente	1,5540 m/s	2,6214 m/s	21,27%	44,79%
6 passos à frente	2,0365 m/s	2,8849 m/s	26,94%	49,54%

Fonte: Elaboração própria.

Tabela 5.5: Métricas de comparação.

Modelo HW Multiplicativo	RMSE	RMSE (Naíve)	MAPE	MAPE (Naíve)
1 passo à frente	0,9354 m/s	0,9373 m/s	13,03%	13,74%
2 passos à frente	1,2472 m/s	1,4629 m/s	16,25%	21,80%
3 passos à frente	1,4440 m/s	1,9299 m/s	19,50%	30,76%
4 passos à frente	1,6669 m/s	2,2930 m/s	21,56%	38,11%
5 passos à frente	1,8149 m/s	2,6214 m/s	22,17%	44,79%
6 passos à frente	2,6197 m/s	2,8849 m/s	31,99%	49,54%

Fonte: Elaboração própria.

Nas Figuras 5.9 (para o Modelo Holt-Winters Aditivo) e 5.10 (para o Modelo Holt-Winters Multiplicativo) a seguir, apresentaremos a evolução da métrica MAPE com isso podemos observar que o MAPE piora a habilidade de previsão do modelo com o aumento do horizonte de previsão na primeira semana de 2007.




Figura 5.9: Evolução do MAPE para o Modelo HW Aditivo.

Fonte: Elaboração própria.




Figura 5.10: Evolução do MAPE para o Modelo HW Multiplicativo.

Fonte: Elaboração própria.

Sendo assim, ainda foi observado previsões 24 passos à frente utilizando o modelo de Holt-Winters para a primeira semana de 2007. As Figuras 5.11 e 5.12 mostram os resultados modelo de Holt-Winters Aditivo e do Multiplicativo, respectivamente.




Figura 5.11: Valores observados e previsão 24 passos à frente.

Fonte: Elaboração própria.




Figura 5.12: Valores observados e previsão 24 passos à frente.

Fonte: Elaboração própria.

Como já se previa, na previsão ocorre uma piora na sua habilidade preditiva, na previsão com 24 passos à frente. Contudo, os modelos propostos conseguem acompanhar o comportamento da série. A Tabela 5.6, são os resultados das métricas de comparação do modelo Holt-Winters Aditivo e na Tabela 5.7 são os resultados do modelo Holt-Winters Multiplicativo, ambos para 24 passos à frente.

Tabela 5.6: Métricas de comparação.

Modelo HW Aditivo	
Métricas	Resultados
RMSE	1,882
MAPE	29,33%

Fonte: Elaboração própria.

Tabela 5.7: Métricas de comparação.

Modelo HW Multiplicativo	
Métricas	Resultados
RMSE	1,770
MAPE	28,11%

Fonte: Elaboração própria.

Nas Figuras 5.13 e 5.14, são os resultados de 1 passo, 6 passos e 24 passos à frente de forma conjunta para os modelos de Holt-Winters Aditivo e Multiplicativo, respectivamente.




Figura 5.13: Valores observados e previsões 1, 6 e 24 passos à frente.

Fonte: Elaboração própria.




Figura 5.14: Valores observados e previsões 1, 6 e 24 passos à frente.

Fonte: Elaboração própria.

Podemos observar que o modelo de Holt-Winters Aditivo obteve um melhor resultado em todas as previsões e resultados que o modelo de Holt-Winters Multiplicativo e por este motivo ele que será comparado com os outros modelos. E para as previsões foi usado o programa R.

5.2

Comparação dos resultados

Na modelagem acima, apresentei os dois modelos, que foram o Modelo de Holt-Winters Aditivo e Multiplicativo, como podemos ver nos resultados da seção 5.1 o modelo de melhor desempenho foi o Holt-Winters Aditivo por este motivo este modelo que foi comparado com os outros modelos.

O Modelo Holt-Winters Aditivo será comparado com outros tipos de modelos dentro da semana de teste. As previsões foram comparadas com os modelos Persistence (ou naïve), ARFIMA, Harmônico, Modelo Tempo-Frequência (que foi proposto na dissertação do Dantas e Souza- 2011 na mesma semana de teste) e Híbrido Neuro-Fuzzy (este modelo não foi estimado nessa dissertação. A comparação veio através dos resultados para a mesma semana de teste no artigo Previsão de Velocidade de Vento com Sistema de Inferência Neuro-Fuzzy Adaptativo. Pessanha, Silva e Souza – 2010).

Nas Figuras 5.15, 5.16, 5.17, 5.18, abaixo apresenta os resultados para os modelos Persistence, ARFIMA, Harmônico e Tempo-Frequência para previsões um passo à frente. Os resultados mostram de maneira geral que o modelo proposto teve um bom desempenho na semana analisada.




Figura 5.15: Comparação: Modelo Proposto e Modelo Persistência.

Fonte: Elaboração própria.




Figura 5.16: Comparação: Modelo Proposto e Modelo ARFIMA.

Fonte: Elaboração própria.




Figura 5.17: Comparação: Modelo Proposto e Modelo Harmônico.

Fonte: Elaboração própria.




Figura 5.18: Comparação: Modelo Proposto e Modelo Tempo Freqüência.

Fonte: Elaboração própria.

Podemos ver, na Tabela 5.8 os resultados das métricas de comparação RMSE e MAPE para o modelo proposto e para os modelos ARFIMA, Persistence, Tempo-Freqüência e Neuro-Fuzzy, considerando um passo a frente.

Tabela 5.8: Métricas de comparação entre os modelos

Modelos	RMSE	MAPE
Modelo Proposto	0,8943 m/s	12,93%
Persistence	0,9373 m/s	13,74%
Modelo Tempo Frequência	0,8066 m/s	12,05%
Modelo Neuro- Fuzzy	1,1449 m/s	16,63%
Modelo Arfima	1,2079 m/s	18,04%

Fonte: Elaboração própria.

O coeficiente U de Theil apresentou valor menor que 1 (0,956), e observado na tabela acima, que o modelo proposto é melhor que o modelo persistence (ingênuo). De maneira geral, o modelo persistence apresenta uma competitividade em um passo à frente.

Podemos observar, no que foi analisado no problema estudado que para previsões em que o horizonte é aumentado, por exemplo 24 horas, utilizando essa modelagem, apresenta uma queda de desempenho de previsão. Porém o modelo proposto apresentou vantagem na qualidade da previsão para a série em estudo de velocidade de vento, e sendo uma modelagem inédita para a série em questão.

6

Considerações Finais

6.1

Conclusão

Com a evolução da fonte de energia eólica, países se interessam por esse tipo de energia por ser uma fonte renovável de baixo impacto ambiental e com custos cada vez menores. A energia eólica é um recurso natural limpo e inesgotável, e com seu aproveitamento na produção é uma das alternativas promissoras na redução de gases do efeito estufa.

O Brasil e o mundo demonstram a cada dia mais interesse na inserção de fontes de energia renovável na matriz energética. Portanto a expectativa é que a geração de energia eólica na matriz elétrica brasileira e no mundo continue a crescer nos próximos anos.

Portanto o desenvolvimento de modelos de previsão é fundamental para sistemas de parques eólicos e para desenvolver modelos de previsão de curto-prazo. Na dissertação, apresentou o modelo de Holt-Winters na forma Aditiva e Multiplicativa para fazer previsões horárias sobre a velocidade de vento na estação Anemométrica de São João do Cariri – PB, obtida do projeto SONDA. A estação estudada dispõe de uma boa série de dados, que permitiu uma avaliação da capacidade preditiva. Foi utilizado 1 ciclo diário, pelo motivo da série ser de velocidade de vento e com isso apresentar somente 1 ciclo.

Este estudo com modelo de Holt-Winters para a série de velocidade de vento é algo inédito e não visto em outros trabalhos, com isso a motivação de utilizar este modelo.

O modelo de Holt-Winters Aditivo apresentou melhor resultado que o Holt-Winters Multiplicativo e por este motivo foi comparado com outros modelos já estudados em outras dissertações, na mesma série e período. Considerando a métrica MAPE, para previsão 1 passo à frente, o modelo de Holt-Winters Aditivo apresentou, dentro da amostra o MAPE de 11,34% e o MAPE fora da amostra foi de 12,93%, comparado com os resultados dos modelos Persistence (Naíve),

Neuro-Fuzzy e com o ARFIMA puro, o modelo proposto obteve melhor resultado. Apesar de o modelo proposto obter um bom desempenho, não obteve um desempenho superior ao se comparar com o modelo Tempo-Frequência, sendo uma pequena diferença no MAPE.

Com isso, os resultados apresentados pelo modelo proposto foram satisfatórios e animadores, já que obtiveram ganhos sobre os modelos testados (Persistence, Neuro-Fuzzy, ARFIMA puro) na mesma série e período. E por se tratar de algo inovador utilizando o modelo de Holt-Winters na série de velocidade de vento, a modelagem apresenta baixo custo computacional e de fácil interpretação, facilmente implementada em vários softwares como por exemplo o R (utilizado nessa dissertação).

6.2

Sugestões para Trabalhos Futuros

Assim, para trabalhos futuros podemos incluir outras variáveis explicativas para obter uma melhora na previsão. Tais como, a variável de temperatura e direção do vento podendo gerar melhores resultados, conforme a tese da Vidigal (2007).

Em relação a localidade, não tem nenhuma restrição. Com isso, pode ser usado em outras estações anemométricas para previsão de curto prazo. Sendo analisadas correlações com outras estações eólicas, que sejam usadas as variáveis explicativas.

Utilizar outros modelos para a estação analisada, como por exemplo modelos de correlação espacial, regressão dinâmica e Hierarchical Profiling Approach (HPA).

Referências bibliográficas

ALEXIADIS, M.C.; DOKOPOULOS, P.S. & SAHSAMANOGLU, H.S. (1999). **Wind speed and power forecasting based on spatial correlation models.** *IEEE Transactions on Energy Conversion*, 14(3), 836-842.

AMARANTE, O.A.C.; BROWER, M.; ZACK, J. & DE S_A, A. L. (2001). **Atlas do Potencial Eólico Brasileiro.** Ministério de Minas e Energia/Eletronbras/CEPEL/Cresesb.

AMMONIT – **Histórico da Energia Eólica**, Junho (2012). Disponível em: <<http://www.ammonit.com/pt/energia-eolica/energia-eolica>>, Acessado em Junho de 2013.

ANEEL (2001). **Atlas de Energia Elétrica do Brasil**, 3ed. Capítulo 3: 3. Energia Hidráulica. Disponível em: <<http://www.ANEEL.gov.br>>. Acesso em Agosto de 2011.

ANEEL (2001). **Atlas de Energia Elétrica do Brasil**, 3ed. Capítulo 3: 3. Energia Hidráulica. Disponível em: <<http://www.ANEEL.gov.br>>. Acessado em Janeiro de 2013.

BARROS, M. (2004). **Processos Estocásticos**. Papel Virtual. Rio de Janeiro.

BEBLO, G. & SCHMID, W.(2010). **Reading the Message of the High Frequency Wind Data. A Short-Term Wind Speed Forecast With Periodic**

Components and Long Range Dependence. METMAV 2010.

BOX, G.E.P. and JENKINS, G.M. (1976). **Time series analysis: forecasting and control.** *Rev. Ed. Holde - Day*. (1976).

BROWN, B.G.; KATZ, R.W. and MURPHY & A.H. (1984). **Time Series Models to Simulate and Forecast Wind Speed and Wind Power.** *Journal of Climate and Applied Meteorology*.

CHOU, S.C.; CHAGAS, D.J.; PAIVA NETO, A.C.; VENTURA, G.M.; LYRA, A. & PEREIRA, E.B. **Regime eólico de quatro estações no Nordeste**, XIV Congresso Brasileiro de Meteorologia, Florianópolis, 2006.

CIPRA, T.; TRUJILLO, J. & RUBIO, A. (1995). **Holt-Winters Meted with Missing Observations.** *Management Science*, 41 (1), 174-178.

CRESESB (2008). **Tutorial de Energia Eólica.** Disponível em: <<http://www.cresesb.cepel.br>>. Acessado em Agosto de 2011.

CUSTÓDIO, R.S. (2010). **Energia Eólica para a produção de Energia Elétrica**, 1ª Edição, Eletronbras.

CUSTÓDIO, R.S. (2010). **Energia Eólica para a produção de Energia Elétrica**, 1ª Edição, Eletrobrás.

DANTAS, T.M. 2011. **Modelo Tempo-Frequência para Previsão de Curto Prazo de Velocidade de Vento**. Dissertação de mestrado, PUC-Rio, Departamento de Engenharia Elétrica, Rio de Janeiro.

DUTRA, R.M. (2007). **Propostas de Políticas específicas para Energia Eólica no Brasil após a primeira fase do PROINFA**. Tese de Doutorado, COPPE/UFRJ, Rio de Janeiro, Brasil.

ESTEVES, G.R.T. **Modelos de Previsão de Carga de Curto Prazo**, Dissertação de Mestrado, DEE, PUC-Rio, abril 2003.

EWEA – **European Wind Energy Association**. March (2010). Disponível em: <<http://www.ewea.org>>. Acessado em Março de 2013.

GENTON, M.G. & HERING, A.S (2009). **Powering Up With Space-Time Wind Forecasting**. *Journal of American Statistical Society*.

GIEBEL, G.; KARINIOTAKIS, G. & BROWNSWORD, K. (2003). **The State of the Art in Short-term Prediction of Wind Power**. *Technical report*, Deliverable report of the EU project Anemos, available at: <http://anemos.cma.fr>

GNEITING, T.; LARSON, K.; WESTRICK, K.; GENTON, M.G. & ALDRICH, E. (2006). **Calibrated Probabilistic Forecasting at Stateline Wind Energy Center: The Regime Switching Space-Time Method**. *Journal of American Statistical Society*.

GOLDEMBERG, J. & VILLANUEVA, L.D. **Energia, Meio Ambiente e Desenvolvimento**. São Paulo: Edusp, 2. ed, 2003.

GWEC – **Global Wind Energy Council**. March (2006). Disponível em: <<http://www.gwec.net/>>. Acessado em Março de 2013.

HAMILTON, J.D. (1994). **Time Series Analysis**. Princeton University Press.

HYNDMAN, R.J. & KHANDAKAR, Y. (2008). **Automatic time series forecasting: The forecast package for R**. *Journal of Statistical Software*, 26(3).

ISA (Instituto Socioambiental). **Fontes Alternativas de Energia e Eficiência Energética – Opção para uma política energética sustentável no Brasil**. Brasília DF, 2002. Disponível em: <http://www.socioambiental.org/esp/bm/boell.html>. Acessado em Março 2013.

LEITE, A.P.; BORGES, C.L.T.; FALCÃO, D.M. (2006). **Modelagem de Usinas Eólicas para Estudos de Confiabilidade**. *Revista Controle & Automação*, Vol. 17, n. 2, p. 178-188.

MACHADO, R.R. (2008). **Estudo do Potencial Eólico do Pontal de Abreu – Município de Viamão-RS**. Dissertação de Mestrado. Universidade Federal do Rio Grande – RS. Engenharia Oceânica.

MARTINS, F.R.; GUARNIERI, R.A.; CHAGAS, R.C.; NETO, S.L.M.; PEREIRA, E.B.; ANDRADE, E. & THOMAZ, C. **Projeto Sonda – Rede Nacional de Estações para coleta de dados meteorológicos aplicados ao setor de energia**, I Congresso Brasileiro de Energia Solar, (2007).

MARTINS F.R.; GUARNIERI R.A. & PERREIRA E.B. **O Aproveitamento da Energia Eólica**, Instituto Nacional de Pesquisa Espacial. (2008).

MAKRIDAKIS, S.G.; WHEELWRIGHT, S.C. and HYNDMAN, R.J. **Forecasting: Methods and Applications**. 3 ed. New York: John Wiley & Sons, 1998.

MEDEIROS, M.C. **Técnicas de Pesquisa em Economia**, Notas de Aula, 2005.

MONTGOMERY, D.C. and JOHNSON, L.A. **Forecasting and Time Series Analysis**, New York, McGraw-Hill Book Co., 2 ed., 1990.

MONTGOMERY, D.C. and JOHNSON, L.A. **Forecasting and Time Series Analysis**, New York, McGraw-Hill Book Co., 1976.

MORETTIN P.A. & TOLOI M C. **Análise de Séries temporais**, 2. Ed. São Paulo: Egard Blucher, 2006. 135 p.

PANORAMIO – **Fotos de moinhos e energia eólica**, Julho (2011). Disponível em: <<http://www.panoramio.com/photo/13149827>>, Acessado em Junho de 2013.

PESSANHA, J.F.; SILVA, I.V.G. & SOUZA, R.C. (2010). **Previsão de Velocidade de Vento com Sistema de Inferência Neuro-Fuzzy Adaptativo**. SPOLM 2010.

PESSANHA, J.F.; SOUZA, R.C.; MENEZES, M.L.; CASSIANO, K.M., and JUNIOR, L.A. (2012). **Artificial Neural Networks integrated with Singular spectrum analysis and wavelet theory in the short-term Wind speed forecasting**. EEMSW 2012.

SILVA, N.F. da (2006). **Fontes de energias renováveis complementares na expansão do setor elétrico brasileiro: O caso da energia eólica**. Tese de Doutorado, COPPE/UFRJ, Rio de Janeiro, Brasil.

SILVA, P.C. da (1999). **Sistema para Tratamento, Armazenamento e Disseminação de Dados de Vento**. Dissertação de Mestrado, COPPE/UFRJ, Rio de Janeiro, Brasil.

SILVA, N.F. da (2006). **Fontes de energias renováveis complementares na expansão do setor elétrico brasileiro: O caso da energia eólica**. Tese de Doutorado, COPPE/UFRJ, Rio de Janeiro, Brasil.

SOUZA, R.C. & CAMARGO, M. E. (2004). **Análise e previsão de séries temporais: os modelos ARIMA**. SEDIGRAF, Ijuí.

TAYLOR, J.W. (2003). **Short-term electricity demand forecasting using double seasonal exponential smoothing**. *Journal of Operational Research Society*, 54, 799-805.

TAYLOR, J.W. & BUIZZA, R. (2003). **Using Weather Ensemble Predictions in Electricity Demand Forecasting**. *International Journal of Forecasting*, 19, 57-70.

TAYLOR, J.W.; MCSHARRY, P.E. & BUIZZA, R. (2009). **Wind Power Density Forecasting Using Wind Ensemble Predictions and Time Series Models**. *IEEE Transactions on Energy Conversion*, 24, 775-782.

VIDIGAL, C. & SOUZA, R.C. (2007). **Previsão de dados de alta frequência para carga elétrica usando Holt-Winters com dois ciclos**. Dissertação de Mestrado, DEE, PUC-Rio.

WILLIAMS, D.W. and MILLER, D. (1999). **Level-adjusted exponential smoothing for modeling planned discontinuities**. *International Journal of Forecasting*, 15, 273-289.