



Glaucia Estefânia de Sousa Ferreira

**Modelo STAR-TREE de Transição Suave
Estruturado em Árvore para Previsão de Energia
Eólica**

Dissertação de Mestrado

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

Orientador: Prof. Álvaro Lima Veiga

Rio de Janeiro
Outubro de 2012



Glaucia Estefânia de Sousa Ferreira

**Modelo STAR-TREE de Transição Suave Estruturado
em Árvore para Previsão de Energia Eólica**

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. Álvaro de Lima Veiga Filho
Orientador

Departamento de Engenharia Elétrica – PUC-Rio

Prof. Reinaldo Castro Souza

Departamento de Engenharia Elétrica – PUC-Rio

Prof. Alexandre Street de Aguiar

Departamento de Engenharia Elétrica – PUC-Rio

Prof. José Eugenio Leal

Coordenador Setorial do Centro
Técnico Científico

Rio de Janeiro, 16 de outubro de 2012

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

Glaucia Estefânia de Sousa Ferreira

Graduou-se em Estatística pela Escola Nacional de Ciências Estatísticas, no Rio de Janeiro – RJ (2006). Experiência profissional de oito anos em análise estatística de dados, em especial na área de pesquisa de mercado. Durante o mestrado, trabalhou com modelagem e previsão com aplicação no mercado brasileiro de energia elétrica. Atualmente, na área econômica com análise de dados em painel e previsão dos dados.

Ficha Catalográfica

Ferreira, Glaucia Estefânia de Sousa

Modelo STAR-TREE de transição suave estruturado em árvore para previsão de energia eólica / Glaucia Estefânia de Sousa Ferreira ; orientador: Álvaro Lima Veiga. – 2012.

87 f. : il. (color.) ; 30 cm

Dissertação (mestrado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica, 2012.

Inclui bibliografia

1. Engenharia elétrica – Teses. 2. Modelos não lineares. 3. STAR-TREE. 4. Energia eólica. 5. Árvores de regressão. 6. Previsão. I. Veiga, Álvaro Lima. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. III. Título.

CDD: 621.3

Agradecimentos

Agradeço a Deus pelo dom da vida, por tudo que me deste até hoje e pela oportunidade de concluir mais uma etapa do meu caminho com muita fé e alegria.

Em segundo, a minha família por todo incentivo, carinho e apoio em todos os momentos da minha vida. Principalmente nesta reta final, onde foram compreensivos com minhas ausências. Em especial, a minha avó Nancy Mariz pela revisão ortográfica, minha mãe e padrasto por todo auxílio nos momentos de dedicação intensiva a este trabalho.

Ao meu noivo Gilson por toda ajuda, compreensão e amor.

A todos os meus amigos que torceram por mim de perto ou de longe.

Ao meu orientador o prof. Álvaro Lima Veiga e a co-orientadora Camila Rosa Epprech pelos conhecimentos repassados, pelos conselhos oferecidos, pelo apoio moral, confiança e incentivo em todas as etapas.

Agradeço aos professores Reinaldo Castro Souza e Alexandre Street por terem aceitado participar da banca e por todo esforço em trazer contribuições valiosas a este trabalho.

À Flávia por ter me ajudado com diversas conversas nos momentos de desespero e auxiliando na revisão do texto. Ao Guilherme Armando pelos estudos no tema.

Aos amigos queridos da PUC, que sem os grupos de estudo, as trocas de idéia e os auxílios profissionais, não teria sido possível meu ingresso no mestrado e nem a conclusão desta dissertação: Paulo Roberto Maia, Rafael Moraes, Rodrigo Farinazzo, Érika Victoriana, João Antunes, Thiago Dantas, Camila Monteiro e Pedro Ferreira.

Aos meus colegas do IPEA, Carolina Marques e Patrick Franco, por todo suporte, ajuda e folgas que me permitiram a conclusão deste trabalho.

Aos funcionários da ONS, Paulo Cunha e José Dantas, pelo atendimento e esclarecimentos das dúvidas.

Aos professores e a todos os funcionários da PUC-Rio, pelo conhecimento, apoio e infraestrutura proporcionados.

À CAPES e à PUC-Rio, pelo suporte financeiro durante o curso.

A todos que não foram citados, mas que contribuíram de forma direta ou indireta para este trabalho.

Resumo

Ferreira, Glaucia Estefânia de Sousa; Veiga, Álvaro Lima (Orientador). **Modelo STAR-TREE de transição suave estruturado em árvore para previsão de energia eólica.** Rio de Janeiro, 2012. 87p. Dissertação de Mestrado – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

O principal objetivo desta dissertação é estudar modelos de previsão da geração eólica utilizando os dados de cinco parques eólicos, mais precisamente comparar o desempenho dos modelos lineares e não lineares. Utilizando a metodologia do modelo não-linear STAR-TREE (Smooth Transition AutoRegression Tree) e comparando com o modelo linear Box&Jenkins através de medidas estatísticas. Basicamente, o modelo STAR-TREE é uma combinação dos modelos STAR (Smooth Transition AutoRegression) e CART (Classification and Regression Tree), realizando assim uma modelagem em árvore onde a transição entre os regimes é feita de forma suave através da função logística e nos nós terminais são ajustados modelos preditivos. Neste estudo será ajustado nos nós terminais um modelo simples constante e também modelos autorregressivos.

Palavras-chave

Modelos não lineares; STAR_TREE; Energia Eólica; Árvore de Regressão; Previsão.

Abstract

Ferreira, Glaucia Estefânia de Sousa; Veiga, Álvaro Lima (Advisor). **Tree structured smooth transition model STAR-TREE for wind power forecasting**. Rio de Janeiro, 2012. 87p. MSc. Dissertation – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

The main objective of this dissertation is to study wind generation forecasting models using data from five wind farms, more accurately compare the performance of linear and nonlinear models. Using the methodology of the nonlinear model STAR-TREE (Smooth Transition Autoregression Tree) and compare with the linear model Box&Jenkins through statistical measures. Basically the model STAR-TREE is a combination of models STAR (Smooth Transition Autoregression) and CART (Classification and Regression Tree), thus creating a modeling tree where the transition between regimes is done smoothly through the logistics function and in the terminal nodes are adjusted predictive models. In this study will fit in the terminal nodes, a simple model of constant and a autoregressive models.

Keywords

Nonlinear models; STAR-TREE; Wind Power; Regression trees; Prediction.

Sumário

1	Introdução	14
1.1	Estrutura Da Dissertação	15
2	Energia Eólica	16
2.1	Historia Da Energia Eólica	16
2.2	Características Técnicas Da Geração Eólica	18
2.2.1	O Vento	18
2.2.2	Principais Componentes De Um Aerogerador	20
2.2.3	Potencial Eólico	22
2.3	Vantagens E Desvantagens Da Energia Eólica	24
2.4	Energia Eólica No Mundo	25
2.5	Energia Eólica No Brasil	26
3	Modelagem Eólica De Previsão	29
3.1	Previsão Da Energia Eólica Abordagem Estatística	30
4	Metodologia	31
4.1	Modelos Comparativos	31
4.1.1	Box & Jenkins	31
4.2	Modelagem Star-Tree	33
4.2.1	Modelo Star	33
4.2.2	Modelo Cart	39
4.2.3	Modelo Star-Tree	43
4.2.3.1	Estimador De Mínimos Quadrados Não Lineares (MQNL)	48
4.2.3.2	Teste Multiplicador De Lagrange – Divisão Dos Nós	49
4.2.3.3	Ciclo De Modelagem – Sequência De Testes	54
4.2.3.4	Previsão	54
4.3	Métricas Para Comparação Dos Modelos	55

5	Estudo De Caso	57
6	Aplicação Aos Dados Reais	59
6.1	Análise Inicial Da Série	59
6.2	Resultados dos Modelos De Previsão Da Geração Eólica	60
7	Conclusão	71
8	Referencial Bibliográfico	72
9	Anexo	75
9.1	Teste De Normalidade Jarque-Bera	75
9.2	Boxcox	76
9.3	Anexo Análise Exploratória	77
9.3.1	Rio Do Fogo	77
9.3.2	Indios	79
9.3.3	Sangradouro	80
9.3.4	Canoa Quebrada	82
9.3.5	Enacel	84

Lista de Tabelas

Tabela 2.1. Níveis de poluição sonora em decibéis	24
Tabela 2.2. Capacidade instalada em 2011 (MW)	26
Tabela 5.1. Usinas eólicas participantes do PDP	57
Tabela 5.2. Características gerais dos parques eólicos em estudo	58
Tabela 6.1. Análise descritiva em MW médio dos parques em estudo	59
Tabela 6.2. Teste de normalidade e estatísticas para o cálculo	59
Tabela 6.3. Análise sob a estacionariedade da série	60
Tabela 6.4. Análise dos componentes não observáveis	60
Tabela 6.5. Análise comparativa dentro da amostra da EOL Rio do Fogo	61
Tabela 6.6. Análise comparativa fora da amostra da EOL Rio do Fogo	62
Tabela 6.7. Análise descritiva dos resíduos padronizados EOL Rio do Fogo dentro e fora da amostra dos modelos escolhidos nas estatísticas de comparação	63
Tabela 6.8. Análise comparativa dentro da amostra da EOL Índios	63
Tabela 6.9. Análise comparativa fora da amostra da EOL Índios	63
Tabela 6.10. Análise descritiva dos resíduos padronizados EOL Índios dentro e fora da amostra dos modelos escolhidos nas estatísticas de comparação	64
Tabela 6.11. Análise comparativa dentro da amostra da EOL Sangradouro	65
Tabela 6.12. Análise comparativa fora da amostra da EOL Sangradouro	66
Tabela 6.13. Análise descritiva dos resíduos padronizados EOL Sangradouro dentro e fora da amostra dos modelos escolhidos nas estatísticas de comparação	66
Tabela 6.14. Análise comparativa dentro da amostra da EOL Canoa Quebrada	67
Tabela 6.15. Análise comparativa fora da amostra da EOL Canoa Quebrada	68
Tabela 6.16. Análise descritiva dos resíduos padronizados EOL Canoa Quebrada dentro e fora da amostra dos modelos escolhidos nas estatísticas de comparação	68
Tabela 6.17. Análise comparativa dentro da amostra da EOL Enacel	68
Tabela 6.18. Análise comparativa fora da amostra da EOL Enacel	69
Tabela 6.19. Análise descritiva dos resíduos padronizados EOL Enacel dentro e fora da amostra dos modelos escolhidos nas estatísticas de comparação	70

Lista de Figuras

Figura 2.1. Moinho eólico medieval	16
Figura 2.2. Moinho com rotor de 17m e 144 pás de madeira	17
Figura 2.3. Turbina eólica	21
Figura 2.4. Componentes do aerogerador	22
Figura 2.5. Parque ou fazenda eólica	22
Figura 4.1. Exemplo enumeração de árvore para regressão com ausência de alguns nós	40
Figura 4.2. Árvore de decisão do STAR-TREE com os parâmetros associados	43
Figura 4.3. Árvore de decisão do STAR-TREE com primeira divisão	49
Figura 4.4. Árvore de decisão do STAR-TREE com os parâmetros associados	52

Lista de Gráficos

Gráfico 2.1. Capacidade instalada	25
Gráfico 2.2. Vazão do Rio São Francisco e vento típico do litoral e do interior da Região Nordeste	27
Gráfico 4.1. Função logística com $c=0$, $\gamma = (1, 2.5, 5, 25 \text{ e } 1200)$	37
Gráfico 6.1. Gráfico dos dados reais da geração da EOL FOGO versus a previsão de cada modelo	61
Gráfico 6.2. Gráfico dos dados previstos da geração da EOL FOGO	62
Gráfico 6.3. Gráfico dos dados reais da geração da EOL ÍNDIOS versus a previsão de cada modelo	64
Gráfico 6.4. Gráfico dos dados reais da geração da EOL SANGRADOURO versus a previsão de cada modelo	65
Gráfico 6.5. Gráfico dos dados reais da geração da EOL CANOA QUEBRADA versus a previsão de cada modelo	67
Gráfico 6.6. Gráfico dos dados real da geração da EOL ENACEL versus a previsão de cada modelo	69
Gráfico 6.7. Gráfico dos dados previstos da geração da EOL ENACEL	70

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
INESC - Instituto de Engenharia de Sistemas e Computadores do Porto
INMET - Instituto Nacional de Meteorologia
INPE - Instituto de Pesquisas Espaciais
KW - Quilowatt
JB – Estatística de teste Jarque-Bera
LI - Licença Ambiental de Instalação
LP - Licença Prévia Ambiental
ML- Multiplicadores de Lagrange
MME - Ministério de Minas e Energia
MPH – Milhas por hora
MQO - Mínimos quadrados ordinários
MQNL - Mínimos quadrados não lineares
MV - Máxima Verossimilhança
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
RISØ - Riso National Laboratory
SETAR - Self-Exciting Threshold Autoregressive
SIG - Sistema de Informação Geográfica
UFRJ - Universidade Federal do Rio de Janeiro
UFSC - Universidade Federal de Santa Catarina
VN - Valor Normativo
WWEA - World Wind Energy Association

A fortuna suprema do homem
é a paz da consciência pelo dever cumprido.

Emmanuel

1 Introdução

A geração de energia eólica no Brasil tem crescido muito, principalmente a partir do PROINFA que é um programa do governo de incentivo às fontes alternativas de energia elétrica. Apresentado pelo governo em 2002, o primeiro leilão voltado exclusivamente para fonte de energia eólica ocorreu em 2009. O objetivo do governo é alcançar a meta que, em vinte anos, 10% do consumo de energia provenha das três principais fontes alternativas (biomassa, eólica e PCH).

A busca dos países por energia limpa intensificou os estudos na área de desenvolvimento das tecnologias para geração, com objetivo de diminuir os custos e tornar mais acessível o uso em larga escala de energia renovável.

Uma das áreas de estudo é a previsão de energia eólica disponível ou previsão da geração de energia eólica, sendo o foco desta dissertação na metodologia estatística que tem apresentado bons resultados. Apesar das previsões serem semanais a previsão é um passo à frente, aplicando a metodologia do STAR-TREE com o objetivo de capturar a estrutura da série e fazer as previsões. No subcapítulo 6.2, os resultados dos modelos STAR-TREE serão comparados através de métricas estatísticas, com os modelos Box & Jenkins. A divulgação dos dados é feita pela ONS na frequência semanal.

Com o aumento da contribuição da energia eólica na rede elétrica torna-se fundamental um melhor conhecimento da oferta de energia, ou seja, previsão da geração. É interessante também desenvolver os métodos de previsão pelas seguintes razões: melhorar o gerenciamento do sistema elétrico, otimizar a verificação da capacidade de despacho elétrico pelas linhas de transmissão a fim de melhor atender à demanda por energia elétrica integrando os recursos eólicos ao sistema de integração nacional, programar com eficiência a manutenção dos aerogeradores e a necessidade de prever os ventos extremos para evitar danos nos equipamentos.

A geração de energia eólica é afetada por diversos fatores com destaque para velocidade do vento, rugosidade do terreno e clima (úmido ou seco).

1.1

Estrutura Da Dissertação

O capítulo II possui uma breve apresentação sobre a energia eólica, sua história, características técnicas da geração eólica, vantagens e desvantagens. Além disso, é apresentada a perspectiva atual da energia eólica no Brasil e no mundo. No capítulo seguinte é dada uma breve descrição dos modelos para previsão de energia eólica utilizados em outros estudos. No IV é apresentada a metodologia dos modelos utilizados para o desenvolvimento desta dissertação, ou seja, a metodologia do modelo STAR-TREE e a metodologia do modelo Box & Jenkins que servirá para comparação. O capítulo V possui uma breve apresentação da base de dados. No capítulo VI é dedicado à análise exploratória dos dados, de maneira a justificar a escolha dos modelos a serem utilizados na previsão. O capítulo VII é dedicado às conclusões finais. O capítulo VIII apresenta as referências bibliográficas utilizadas na elaboração desta dissertação. Para finalizar no capítulo IX está o anexo, com a explicação do teste de normalidade Jarque-Bera, e da transformação Boxcox, além de incluir as estatísticas descritivas complementares.

2 Energia Eólica

Devido à importância para o Brasil e para o mundo da energia proveniente dos ventos, será abordado neste capítulo um breve relato sobre a história da energia eólica, suas características técnicas da geração eólica, vantagens e desvantagens e o cenário atual da energia eólica.

2.1

Historia Da Energia Eólica

A energia eólica pode ser considerada como uma das formas em que se manifesta a energia proveniente do Sol. A força dos ventos se origina da diferença no aquecimento da superfície terrestre pelo Sol. Sabe-se que em dado momento o homem sentiu necessidade de obter auxílio em suas atividades, começando pelos Egípcios, que há 3000 a.c iniciaram o uso da vela nos barcos para navegar no rio Nilo [1]. Descobriram mais tarde, que estes mesmos ventos, usados nas embarcações, poderiam ser convertidos em energia mecânica, ajudando também no bombeamento de água e moagem de grãos.



Fonte: [2]

Figura 2.1. Moinho eólico medieval

No século XII, apareceram os primeiros moinhos na Inglaterra, França e Holanda. Estes cata-ventos foram chamados de eixo horizontal ou do tipo “holandês”.

No final do século XIX, o cientista Charles F. Brush (1849-1929) desenvolve a primeira turbina eólica, aumentando expressivamente o uso da

energia elétrica. Esta turbina era usada para carregar um sistema de baterias no inverno, o qual operou durante 20 anos, conforme Figura 2.2. Entretanto, o precursor dos aerogeradores modernos foi o dinamarquês Poul La Cour (1846-1908), que descobriu no final do século XIX que, quanto menor número de pás mais rápidas as turbinas ficavam, conseqüentemente, mais eficiente seria a geração de energia elétrica [3].



Fonte: [2]

Figura 2.2. Moinho com rotor de 17m e 144 pás de madeira

Com o crescimento da energia proveniente dos ventos, por volta de 1930 os moinhos já eram responsáveis pelo bombeamento de água abastecendo as fazendas e regiões rurais na Europa, substituindo assim o trabalho humano e animal.

Com a Segunda Guerra Mundial, turbinas de médio e grande porte usadas principalmente em cidades isoladas para o suprimento de energia, surgem como competidoras de combustíveis fósseis. Entretanto, após a guerra, os aerogeradores entram em declínio, sendo construídos apenas para fins de pesquisa em países como: França, Dinamarca, Estados Unidos e Alemanha.

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. Assim começaram os investimentos em pesquisas para energias alternativas destacando-se países como: Alemanha, Dinamarca, EUA e Espanha.

A partir de 1990, a energia eólica tornou-se uma alternativa de geração para diversificação da matriz energética. Com isso, houve um crescimento contínuo do

desenvolvimento tecnológico dos aerogeradores, permitindo aumentar a capacidade unitária das turbinas e reduzir os custos da geração da energia elétrica. Assim, a energia eólica possui a maior taxa de crescimento de geração energética entre as fontes de energia [2].

2.2

Características Técnicas Da Geração Eólica

Primeiramente devemos estudar os fatores que influenciam e caracterizam o regime dos ventos para assim utilizá-lo como uma forma de energia para analisar o seu comportamento diário, semanal, anual ou até por estação. Desta forma é possível visualizar como o vento se comporta verificando as mudanças de intensidade, direção e velocidade no espaço e no tempo. Apesar que para conversão de energia os ventos devem ser das camadas atmosféricas mais baixas, o comportamento dos ventos determina: a escolha das regiões para montagem do parque eólico e qual o aerogerador mais apropriado influenciando assim na previsão de energia eólica do parque [4].

A direção e a intensidade dos ventos são provocados pelo movimento de rotação da Terra. Existem locais no globo terrestre que jamais cessam de “soprar”, estes ventos podem ser chamados de alísios, contra-alísios, ventos do oeste e polares.

Os ventos alísios são movimentos contínuos das massas de ar, contrários à rotação da terra. Estes ventos são encontrados principalmente na região nordeste do Brasil. Já os ventos contra-alísios são causados por uma alta-pressão.

2.2.1 O Vento

As regiões do equador são mais aquecidas do que as regiões polares, devido à maior incidência de raios solares. O ar quente que se encontra nas regiões tropicais é mais leve e menos denso e tende a subir em direção às regiões polares, sendo substituído por uma massa de ar mais frio que se desloca das regiões polares em direção às regiões do equador. Esse movimento produz uma pressão, então as diferenças de temperatura são as principais responsáveis pelos

deslocamentos das massas de ar sobre a superfície terrestre, pois elas migram das regiões onde a pressão é maior para as de menor pressão. O resultado deste deslocamento são os ventos, que são afetados, em sua direção e intensidade pela rotação da Terra, provocando o comportamento sazonal destes ao longo do ano. [1]

A velocidade do vento é influenciada pela rugosidade do terreno, então, como a água possui menor rugosidade do que a terra, empresas de energia construíram aerogeradores na água a uma distância de 10 km da costa, chamadas de *offshore*. Outros fatores que influenciam a velocidade são o clima (úmido ou seco), acidentes topográficos como o relevo, altura do aerogerador, etc [4].

Uma manifestação bastante conhecida dos ventos acontece nas regiões costeiras onde são observadas as brisas marinhas e terrestres que são manifestações de uma corrente de ar gerada da elevação da temperatura do ar durante o dia formando assim a brisa que sopra do mar para a terra. Já a noite a brisa com a queda da temperatura é de menor intensidade, soprando da terra para o mar. [4]

Para uma melhor análise, é necessário reunir dados de vários anos para poder distinguir os vários tipos de variações temporais, além de variações de curta duração, ou seja, desde pequenas flutuações até rajadas de vento, tornando a previsão mais robusta possível.

Assim, a Agência Nacional de Energia Elétrica (ANEEL) e o Ministério de Minas e Energia (MME) apenas outorgam parques eólicos que possuem um histórico de informações de dois anos. No próximo leilão, provavelmente a condição será que o histórico tenha no mínimo três anos, o que diminuirá a participação das empresas. Ao mesmo tempo, torna os projetos mais eficientes e com menos incerteza na previsão da geração eólica.[5]

O Ministério da Agricultura (INMET) deixava disponível, em seu site, os dados meteorológicos dos últimos três meses nele continha as informações sobre a velocidade e direção do vento. Após a entrada em vigor da Lei da transparência o instituto disponibilizou uma plataforma (BDMEP) que permite acessar as séries históricas das estações meteorológicas convencionais. A Marinha, Aeronáutica e algumas distribuidoras de energia também possuem dados sobre vento. Ao conseguir estes dados geralmente temos um problema de valores faltante nas séries históricas. O melhor é escolher uma série com menor número de falhas ou

talvez utilizar um método de imputação.

2.2.2 Principais Componentes De Um Aerogerador

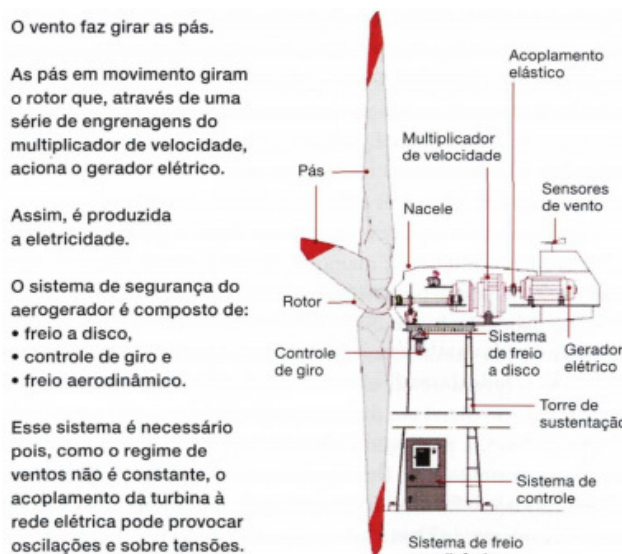
Os aerogeradores convertem a energia cinética do vento em energia mecânica e em eletricidade. As turbinas eólicas funcionam como um ventilador ao contrário para produzir energia, ou seja, o vento move as pás que giram um eixo que se conecta a um gerador e produz eletricidade [6]. Na figura 2.3, pode-se ver como funciona uma turbina eólica que opera de frente para o vento.

Para extrair a energia que está disponível nos ventos utiliza-se principalmente a turbina eólica com eixo horizontal. Nesta turbina o vento passa pelas duas faces da hélice, sendo que passa com maior velocidade na parte superior do que na inferior fazendo movimentos rotatórios como uma turbina de avião, ativando um eixo que está ligado à caixa de engrenagens que aumentam a velocidade do eixo de rotação. Este eixo, conectado ao gerador, produz energia elétrica.

Os aerogeradores podem ser classificados segundo a configuração do eixo rotor:

- Aerogeradores com eixo rotor vertical - Têm a vantagem de não necessitarem de mecanismos de acompanhamento para variações da direção do vento e têm um custo menor. Os principais tipos de rotores são: Darrieus, Savonius e turbinas com torre de vórtices
- Aerogerador com eixo rotor horizontal - Os rotores que giram predominantemente sob o efeito de forças de sustentação permitindo liberar mais potência gerando maior rendimento e eficiência. Assim são os mais utilizados na geração de energia elétrica e são classificados como downwind se recebe o vento por trás da turbina e upwind, que é o mais utilizado, se o vento incide primeiramente sobre o rotor.

Abaixo segue a descrição dos componentes principais do aerogerador e suas funções [1,6]:



Fonte: [7]

Figura 2.3. Turbina eólica

Anemômetro: Mede a intensidade e a velocidade dos ventos, normalmente de 10 em 10 minutos e transmite os dados de velocidade do vento para o controlador. Posicionado em áreas de pouca intensidade de turbulência.

Controlador de giro e motor: encara o vento e mantendo o rotor sempre virado para ele mesmo conforme as mudanças de direção que a Bivota informa.

Mecanismos de controle: É a segurança do sistema, inicia a máquina quando a velocidade do vento está entre 8 à 16 mph e desliga acima de 55 mph acionando o freio a disco que é uma travão para situações de emergência como quando a velocidade do vento pode danificar as turbinas.

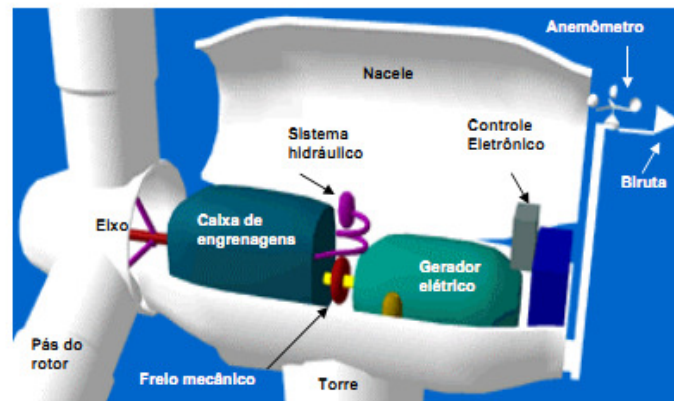
Nacele: Contém os principais componentes da turbina que são, caixa de engrenagens, eixos de baixa e alta velocidade (conecta as pás ao gerador), controlador de freio e o gerador elétrico (converte o torque do giro do rotor em eletricidade). Protege os componentes de elementos externos. Alguns naceles são tão grandes, que têm até espaço suficiente para um helicóptero pousar.

Rotor: Sistema de captação de energia cinética dos ventos, composto pelas pás e o cubo o qual converte em energia mecânica no seu eixo.

Torre: Geralmente de estrutura tubular, sustenta a nacele e o rotor acima do solo para capturar o vento e gerar mais energia, pois quanto mais alto menor a rugosidade. Composta geralmente por aço tubular, concreto ou treliça de aço.

Transmissão: Encaminha a energia mecânica do eixo do rotor para o gerador. Alguns geradores não utilizam este componente – neste caso, o eixo do rotor é acoplado diretamente à carga .

A Figura 2.4 mostra os principais componentes de uma turbina eólica:



Fonte: [1]

Figura 2.4. Componentes do aerogerador

Os aerogeradores devem ser instalados em conjunto, em uma mesma região chamada de parque ou fazendas eólicas, onde haja vento forte e constante, e espaço físico suficiente para sua instalação, atendendo à demanda, e com possibilidade de expansão no futuro. Esta área pode ser utilizada para o uso produtivo da terra, abrigando atividades agrícolas ou de pecuária, e ampliando a oferta de empregos da região.[4]



Fonte: [7]

Figura 2.5. Parque ou fazenda eólica

2.2.3 Potencial Eólico

Nesta seção, há uma breve explicação sobre o potencial eólico e o coeficiente de potência, ou seja, quanto de potência eólica pode ser convertido em

potência mecânica pelo aerogerador. Para o cálculo do potencial eólico devem-se saber os fatores que influenciam na quantidade de energia transferida para o rotor:

- Densidade do ar do seco (ρ)=1,225kg/m³ (PTN)
- Área varrida pelo rotor eólico (A) = $\frac{\pi D^2}{4}$
- Diâmetro das pás em metros (D)
- Deslocamento de uma massa de ar (m)
- Coeficiente de aerodinâmica (C_p)
- Velocidade em m/s (v)

O potencial eólico é em função do cubo da velocidade e é a potência do vento em watts(w) que passa perpendicularmente através de uma área circular.

$$P = \frac{1}{2} \rho v^3 A = \text{fluxo de potência} \left(\frac{1}{2} \rho v^3 \right) \times \text{área da seção transversal} (\pi r^2) \quad (1)$$

Logo, para chegar no cálculo final do potencial eólico (em Watt), é preciso considerar as eficiências do conjunto (η) gerador, transmissão, mecânica e conversão elétrica (varia de aproximadamente 0,93 a 0,98) e o coeficiente de desempenho aerodinâmico (CP), que depende do vento, rotação e parâmetros de controle da turbina [5]:

$$P = \frac{1}{2} \rho v^3 A_r \eta C_p \quad (2)$$

O potencial eólico é maior quando a densidade do ar é maior, pois possuem mais moléculas de ar por metro cúbico, isto ocorre com a temperatura mais baixa, ou seja, mais fria. Quanto mais baixa a temperatura, mais moléculas de ar existem por metro cúbico. Por isso, o potencial eólico é maior quando a densidade do ar é maior, ou seja, quando está mais frio [1].

2.3

Vantagens E Desvantagens Da Energia Eólica

Os principais benefícios da energia eólica estão vinculados a sua disponibilidade na natureza que é abundante e renovável. Além disso, no Brasil, os ventos sopram em abundância em regiões com baixas atividades econômicas, por isso grande parte de usinas eólicas brasileiras estão instaladas no nordeste, gerando não apenas energia, mas emprego e renda.

Apesar dos ventos favoráveis, a energia eólica possui desvantagens como o impacto de pássaros nas pás que é resolvido com as turbinas eólicas de grande porte, pois possuem menores velocidades angulares dos rotores. Outro problema interessante de destacar é o impacto sonoro, que pode ser aerodinâmico – produzido pelo fluxo de vento nas pás; e mecânico – resultado das engrenagens na transmissão e da alta velocidade do gerador. Atualmente os aerogeradores são mais altos e fabricados de fibras de vidro e revestidos de resina diminuindo o impacto sonoro aerodinâmico, e de acordo com as medidas dos fabricantes, uma turbina típica de 600 kW produz um nível sonoro de 55 dB a 50 metros de distância da turbina e 40 dB a 250 metros de distância, o que indica não prejudicar os níveis auditivos humanos. Na tabela 2.1, segue alguns exemplos de sons para compararmos com os aerogeradores modernos [1,2].

Tabela 2.1. Níveis de poluição sonora em decibéis

Fonte	Nível de Poluição Sonora(dB)
Sussurro	30
Aerogerador	55
Ruas	70
Fábrica	90
Avião	150

Fonte:[1,5]


Para instalação de um parque eólico é necessário elaboração de um Estudo de Impacto Ambiental / Relatório de Impacto ao Meio Ambiente, respeitando a Resolução do CONAMA7 01/86 para obtenção de licença para instalação junto ao órgão ambiental e os níveis de ruído devem respeitar a legislação vigente. Lembrando que o terreno pode ser usado também para plantação e criação de animais, pois cada aerogerador ocupa um pequeno espaço de terra [1].

2.4

Energia Eólica No Mundo

Ao analisar o cenário mundial, é possível perceber um crescente interesse por fontes de energias alternativas, em especial, a energia eólica. Mesmo com as crises financeiras, a energia dos ventos continua crescer nos países mais desenvolvidos. De acordo com WWEA (2012), 86 países utilizaram a energia eólica como fonte de energia elétrica.

Conforme relatórios da WWEA (2012), em 10 anos a capacidade eólica passou de 24,32 MW para 239 MW em 2011, superando as expectativas.



Fonte: [8]

Gráfico 2.1. Capacidade instalada

Hoje, o país líder no mercado eólico é a China, que possui 62,7 mil MW de capacidade instalada neste setor. Segundo relatórios da GWEC, o gigante asiático instalou 18,1 MW no ano de 2011.

Em segundo lugar, aparece os Estados Unidos com capacidade eólica de 46,9 mil MW, sendo que em relação a MW instalado em 2011 correspondeu a 17% do crescimento eólico mundial. Eles investiram 6,8 mil MW em 2011, mesmo em meio as incertezas financeiras do período.

Em terceiro lugar no ranking, surge a Alemanha com a capacidade eólica de 29 mil MW, já em relação a MW instalados no ano de 2011 ficou em quarto lugar com investimento no setor eólico de 2,086 mil. Outras nações também

foram influentes no crescimento deste setor, conforme tabela abaixo:

Tabela 2.2. Capacidade instalada em 2011 (MW)

Ranking	País	Capacidade eólica em 2011 (MW)	% em relação ao total
1º	China	62,733	26.2%
2º	EUA	46,919	19.6%
3º	Alemanha	29,075	12.2%
4º	Espanha	21,673	9.1%
5º	Índia	16,084	6.7%
6º	França	6,752	2.8%
7º	Itália	6,747	2.8%
8º	Reino Unido	6,540	2.7%
9º	Canadá	5,265	2.2%
Brasil		1,500	0.6%
Resto do mundo		35,712	14.9%
Total		239,000	

Fonte: Elaboração própria baseado no texto [9]


2.5

Energia Eólica No Brasil

De acordo com estudos realizados pela ANEEL, o Brasil apresenta condições extremamente favoráveis para a instalação de parques eólicos. Em 2001, foi estimado 143 GW de potencial eólico em terras brasileiras. Porém, através de novas medições em 2009, estudos indicaram que o país possui uma capacidade ainda maior de 350 GW.

As pesquisas realizadas demonstram que o Brasil possui posições privilegiadas principalmente na região Nordeste, em particular os estados do Rio Grande do Norte, Ceará, Pernambuco e Bahia e na região Sul, em particular os estados do Rio Grande do Sul e Santa Catarina. Além dos bons ventos, estas regiões possuem características especiais as quais diferenciam o Brasil do resto mundo: a complementaridade.

Em épocas de seca, os ventos são mais fortes agindo assim em parceria com as fontes hídricas. Assim a energia eólica que é uma fonte limpa, renovável e não poluente, é complementar a hidrelétricas, conforme gráfico a seguir:



Fonte: [10]

Gráfico 2.2. Vazão do Rio São Francisco e vento típico do litoral e do interior da Região Nordeste

2.5.1 O MERCADO DE ENERGIA EÓLICA NO BRASIL

A energia elétrica no Brasil é proveniente essencialmente de fontes hídricas. Em 2001, o país passou pela escassez de água e conseqüentemente uma crise de energia, que ficou conhecida como “apagões”. Durante esta mesma época, o Brasil decidiu investir em novas fontes de energia, com intuito de atenuar os riscos de um novo colapso. Para sanar este problema, o Governo brasileiro investiu em usinas baseadas em combustíveis fósseis, os quais possuem preços elevados e altas volatilidades, encarecendo assim a energia.

Em 2002, o governo implanta o programa PROINFA (Programa de Incentivo a Fontes Alternativas) com a finalidade de estimular fontes de energias renováveis, aumentando assim a participação de energias alternativas no mercado, em particular a energia eólica.

Apesar da morosidade, o programa ganhou impulso nos anos de 2008 e 2009, por conta das crises internacionais. Devido ao desaquecimento da economia mundial, os fabricantes de aerogeradores vislumbraram uma oportunidade no Brasil em decorrência dos bons ventos. Por conseqüência, o preço da energia eólica que era de R\$ 306/MWh em 2005, despencou para R\$ 135 em 2009 e em 2011 chegou em R\$ 102, competindo assim com fontes

hídricas.

Por intermédio do PROINFA já foram contratados 7 GW de capacidade eólica no Brasil. De acordo com a Plano Decenal de Energia Elétrica (PDEE) a previsão é que em 2020 a capacidade instalada das centrais eólicas no Brasil alcançará 11 GW.

Conforme relatos da EPE (Empresa de Pesquisa Energética), o país passará de 11º para 4º lugar em capacidade instalada no mundo.

3 Modelagem Eólica De Previsão

Os avanços da previsão em energia eólica são geralmente divididos em três grupos:

- Abordagem física – consiste em centenas de submodelos que, em conjunto, fazem uma tradução da previsão meteorológica de certo ponto, para energia prevista de certa turbina, em determinada altura. Possui interesse em melhorar a previsão considerando a rugosidade do solo do local, a estabilidade atmosférica etc.
- Abordagem estatística – consiste em igualar a relação entre previsão meteorológica, medidas históricas e saídas de geração através de modelos estatísticos cujos parâmetros devem ser estimados pelos dados, sem considerar qualquer fenômeno físico.
- Misto – alguns autores misturam as duas abordagens para melhorar a previsão.

Neste capítulo será apresentado um breve resumo dos estudos sobre previsão da energia eólica no Brasil e no Mundo.

No mundo pode-se destacar os institutos Argonne nos Estados Unidos, que em conjunto com a faculdade INESC do Porto, em Portugal e Risø na Dinamarca, são os principais institutos com textos acadêmicos publicados [11,12].

Já no Brasil, as principais instituições que estudam a previsão de energia eólica é a UFRJ (Universidade Federal do Rio de Janeiro) e PUC-Rio (Pontifícia Universidade Católica) no Rio de Janeiro e a UFSC (Universidade Federal de Santa Catarina) em Santa Catarina.

Em [13] e [1] é encontrado um bom resumo dos trabalhos com modelos estatísticos em energia eólica, inclusive os modelos utilizados ou vendidos por empresas de consultoria.

3.1

Previsão Da Energia Eólica Abordagem Estatística

Existem dois tipos de modelos os puramente estatísticos e os que usam as informações meteorológicas. Assim o primeiro tipo utiliza histórico de dados para prever n passos à frente e o segundo utiliza os dados históricos de geração, de um determinado parque eólico com os dados de previsão da velocidade do vento e direção. A previsão dos dados de vento e direção geralmente é feito por modelos de previsão numérica de tempo (NWP). O uso desses modelos NWP para previsão da geração de energia eólica é chamado na literatura de modelos “wind to power” ou modelos W2P.

No Brasil, é possível conseguir dados históricos meteorológicos através dos institutos SONDA (Sistema de Organização Nacional de Dados Ambientais) e INMET (Instituto Nacional de Meteorologia). O principal problema são os dados faltantes, uma das opções seria escolher um pedaço da série sem dados faltantes, o que poderia tornar a série pequena para previsão.

As principais metodologias estatísticas aplicadas em eólica utilizam os seguintes modelos estatísticos: wavelet, B&J – Box & Jenkins, inteligência artificial, árvore de regressão.

Os modelos utilizados no Brasil do tipo NWP são o ETA da CPTEC/INPE (Centro de Previsão de Tempo e Estudos Climáticos / Instituto Nacional de Pesquisas Espaciais) e RAMS.

Os principais estudos no Brasil são de previsão de velocidade do vento utilizando o modelo Autorregressivos Fracionários Integrados de Médias Móveis (ARFIMA) [14], utilizando o modelo wavelet com redes neurais [15], utilizando redes neurais artificiais [16]. Além disso, tem trabalho que relaciona vento e vazão para determinar a melhor estratégia de comercialização de energia [17], estudo sobre a viabilidade econômica [1] e previsão de geração apartir de dados meteorológicos[3].

4 Metodologia

4.1

Modelos Comparativos

4.1.1

Box & Jenkins

Os estudos dos modelos Box & Jenkins começaram por volta de 1970. Este modelo consiste basicamente em determinar o processo estocástico adequado para representar uma dada série temporal, através da passagem de um ruído branco por um filtro linear. Logo, o valor esperado condicionado fornece a previsão pontual. É o método mais utilizado para previsão de séries temporais.

Série temporal pode ser interpretada como uma parte da trajetória ou uma realização parcial de um processo estocástico ergódico que são processos aleatórios que dependem do tempo, assim y_t com $t=1, \dots, T$ é o estado do processo estocástico ordenado no tempo t (ano ou mês). O conjunto desta variável aleatória forma a série temporal por y_1, y_2, \dots, y_t onde T é o número total de observações existentes na série, ou seja, tamanho da série. Fazendo uma comparação, a série temporal poderia ser considerada a amostra e o processo estocástico a população, assim fazemos inferências na amostra que possam representar perfeitamente a população.

O estudo será no domínio do tempo, observando as relações das observações ao longo do tempo e suas evoluções. As séries temporais são constituídas por um conjunto de componentes não observáveis que podem ser decompostas entre tendência, ciclo, variação sazonal e aleatoriedade.

Tendência em séries temporais é a mudança gradual no nível médio da série a longo-prazo, mesmo após a remoção dos componentes de ciclo, sazonalidade e aleatório.

Ciclos e sazonalidades se referem aos movimentos recorrentes de declínio e elevação em torno do nível médio da série, ao longo de um período definido. Os

ciclos apresentam um comprimento maior que a sazonalidade, não têm duração uniforme e podem variar em comprimento e magnitude. A sazonalidade possui um comprimento constante (3 em 3 meses, 12 em 12 meses, etc).

Retirando os componentes não observáveis da série temporal (tendência, ciclo e sazonalidade) o que sobra é denominada componente residual que pode ser caracterizada como um processo estocástico do tipo “ruído branco”.

É necessário que o processo seja estacionário (ruído branco) para que uma única realização do processo seja capaz de descrever todo o processo. Um processo é chamado de estacionário se suas características são mantidas ao longo do tempo. Existem ainda dois tipos de estacionariedade: fraca (segunda ordem) ou forte.

O modelo $ARIMA(p,d,q)$ se diferencia do modelo $ARMA(p,q)$ por modelar séries não-estacionárias, mas para torná-la estacionária é aplicado sucessivas diferenças.

$$\phi(B)\Delta^d Y_t = \theta(B)a_t \quad (3)$$

Em que p é a ordem de $\phi(B)$ da modelagem $AR(p)$, que é uma combinação linear dos valores observados passados, q é a ordem de $\theta(B)$ da modelagem $MA(q)$, que é a combinação linear dos resíduos, d é o número de diferenças que torna a série estacionária e $\Delta=(1-B)$ representa o operador diferença que é definido como:

$$Y_t - Y_{t-1} = Y_t - BY_t = (1 - B)Y_t = \Delta Y_t$$

Quando a série tem padrões sazonais, ou seja, flutuações periódicas, o modelo que incorpora esta componente é o $SARIMA(p,d,q) * (P,D,Q) = (\phi, \Delta^d, \theta) * (\Phi, \Delta^D, \Theta)$. Sua notação é:

$$\Phi(B^S)\phi(B)\Delta^d \Delta^D Y_t = \Theta(B^S)\theta(B)a_t \quad (4)$$

Em que: $\Phi(B^S)$ é o operador sazonal autorregressivo, $\phi(B)$ é o operador autorregressivo, Δ^d é o operador de diferença, Δ^D é o operador de diferença sazonal, $\Theta(B^S)$ é o operador sazonal de médias móveis e $\theta(B)$ é o operador de médias móveis.

O objetivo principal do modelo quantitativo Box & Jenkins é fazer previsões k passos à frente, utilizando o período dos valores passados conhecidos para inferir sobre o futuro, pensando sempre no princípio da parcimônia (deve-se

escolher um modelo com o menor número de parâmetros possíveis para uma representação matemática apropriada). Os principais passos para utilização da metodologia de Box-Jenkins são:

- (1) Identificação, usando a função de autocorrelação (FAC) e a função de autocorrelação parcial (FACP) identificando as ordens (p, d, q) e se necessário (P, D, Q) ;
- (2) Especificação, através da maximização da função de verossimilhança condicional que é semelhante aos mínimos quadrados ordinários (MQO), assumindo a normalidade de a_t estima-se os parâmetros de interesse;
- (3) Verificação, utilizando teste para verificar a qualidade do modelo proposto, por exemplo, aderência para verificar se a sequência dos resíduos estimados é uma realização de um ruído branco mostrando que as características das séries foram capturadas;
- (4) Previsão, estimando os valores futuros através do modelo devidamente testado.

A seção foi baseada nas seguintes referências bibliográficas: [18], [19], [14], [20] e [21].

4.2

Modelagem Star-Tree

Modelo que mistura o modelo STAR com o modelo CART, justificando a palavra “tree” no nome do modelo que é a sua representação gráfica. A idéia é utilizar o CART na modelagem do STAR para particionar o espaço de transição através de uma árvore binária. Nesta parte do estudo será introduzida a metodologia do STAR e do CART para depois detalhar o STAR-TREE.

4.2.1

Modelo Star

O autorregressivo com transição suave (STAR - Smooth Transition AutoRegressive) é um modelo linear autorregressivo com origem no modelo econométrico TAR - Threshold Autoregressive ou melhor, autorregressivo com

limiar. Proposto inicialmente por Tong em 1978 [22] e discutido mais tarde, detalhadamente, pelo mesmo autor em [23] e [24]. Outros trabalhos surgiram com Tong e Chan [25] e Granger e Teräsvirta [26] com mais dois modelos autorregressivos com transição suave: regressão com transição suave (STR) e autorregressivo com transição suave (STAR): tentando resolver o problema que, em Bacon e Watts [27], foi resolvido com uma regressão linear onde um dos parâmetros tinha uma transição suave. A metodologia detalhada deste modelo está em [26], [28] e [29].

O modelo TAR divide o espaço euclidiano unidimensional em k regimes, sendo cada regime governado por um modelo. Segue a formulação matemática do modelo com transição em dois regimes:

$$F(s_t, \Phi) = \begin{cases} 1 & \text{se } s_t \leq c \\ 0 & \text{se } s_t > c \end{cases} \quad (5)$$

$$y_t = G(z_t, s_t, \Psi) + \varepsilon_t = F(s_t, \Phi)\alpha_1' z_t + [1 - F(s_t, \Phi)]\alpha_2' z_t + \varepsilon_t \quad (6)$$

Sendo:

$F(s_t, \Phi)$ = função de transição, que no caso é uma função indicadora

$z_t = (1, y_{t-1}, y_{t-2}, \dots, y_{t-d})'$

s_t = variável de transição ou limiar

$\Psi = (\Theta, \Phi)$

Φ = parâmetro não linear

Θ = parâmetro linear = $(\alpha_{i0}, \dots, \alpha_{ip})$; $i=1,2$

Verifica-se que a mudança entre os dois regimes é rígida e abrupta, determinada estritamente por c que é o parâmetro de limiar ou de transição. Se esta variável de transição for autoregressora defasada ($d > 0$), ou seja $s_t = y_{t-d}$, o modelo é denominado modelo autorregressivo com limiar auto-excitante SETAR (Self-Exciting Threshold Autoregressive) que é um modelo linear por partes considerando um modelo AR para cada um dos regimes que pode mudar de acordo com a defasagem de y_t [30]. Assim o SETAR($R; p_1, p_2, \dots, p_R; d$) é representado matematicamente por:

$$y_t = \phi_0^{(r)} + \sum_{d=1}^{p_r} \phi_d^{(r)} z_d + \varepsilon_{r,t} \quad (7)$$

Detalhando:

$$y_t = \left\{ \begin{array}{l} \phi_0^{(1)} + \sum_{d=1}^{p_1} \phi_d^{(1)} z_d + \varepsilon_{1,t} \text{ se } r = 1 \text{ então no Regime 1, } z_d \in]-\infty, c_1] \\ \phi_0^{(2)} + \sum_{d=1}^{p_2} \phi_d^{(2)} z_d + \varepsilon_{2,t} \text{ se } r = 2 \text{ então no Regime 2, } z_d \in]c_1, c_2] \\ \vdots \\ \phi_0^{(R)} + \sum_{d=1}^{p_R} \phi_d^{(R)} z_d + \varepsilon_{R,t} \text{ se } r = R \text{ então no Regime } R, z_d \in]c_{R-1}, +\infty[\end{array} \right\}$$

Sendo:

$$c = (c_1, c_2, \dots, c_{R-1})$$

$$r = (1, 2, \dots, R)$$

$$z_d = (1, y_{t-1}, y_{t-2}, \dots, y_{t-p})'$$

Onde r representa a sequência de regimes para o modelo $AR(p_R)$ no regime R . A variância relativa da sequência do ruído $\varepsilon_{r,t} \sim N(0,1)$, é um ruído branco de um processo gaussiano com variância unitária [31].

A variável de transição pode ser regida por autoregressores ($s_t = y_{t-d}$), por uma tendência linear temporal ($s_t = t$), por uma variável exógena ($s_t = x_{t-d}$), ou uma função h de variáveis endógenas ($s_t = h(x_t, \beta)$) que depende do vetor de parâmetros β . Essas mudanças diferenciam o modelo que será utilizado.

O STAR possui os coeficientes determinados de acordo com a posição do vetor de variáveis explicativas, dentro do denominado espaço de transição. Este modelo foi popularizado por Granger e Terasvirta em [26], onde variáveis exógenas são empregadas para modelar os pesos do regime. Entretanto a regra de mudança de regime também pode ser dependente da série observada [32].

Uma revisão do STAR pode ser encontrada em Teravirta [29], além de dois trabalhos desenvolvidos por Tong em [24] e [23] que também abordam o assunto e ajudaram a solucionar alguns problemas do modelo. O uso se popularizou na aplicação em séries temporais não lineares, pois o modelo atribui diferentes regiões para os valores de uma variável determinada pela variável de transição. Na formulação que segue podemos visualizar o modelo de dois regimes com transição suave, função contínua, não linear, limitada entre os valores 0 e 1, utilizando dois modelos autorregressivos de ordem p :

$$y_t = F(s_t; \gamma, c) \phi_1' z_t + [1 - F(s_t; \gamma, c)] \phi_2' z_t + \varepsilon_{r,t} \quad (8)$$

Existem dois principais modelos STAR que se diferenciam pela variável de transição: O modelo STAR com variável de transição logística, denominado LSTAR e o modelo STAR com variável de transição exponencial, conhecido como, ESTAR.

Pode-se escrever o STAR ($R; p_1, p_2, \dots, p_R; d$) [33] considerando a série temporal univariada e o conjunto de variáveis de transição como y_t defasado:

$$\begin{aligned} y_t &= \sum_{r=1}^{R-1} \left\{ \left(\phi_0^{(r)} + \sum_{d=1}^{p_r} \phi_d^{(r)} y_{t-d} \right) \bar{F}_r(s_t, \gamma, c) + \left(\phi_0^{(r+1)} + \sum_{j=1}^{p_{r+1}} \phi_j^{(r+1)} y_{t-j} \right) F_r(s_t, \gamma, c) \right\} + \varepsilon_{r,t} \\ &= \sum_{r=1}^{R-1} \left\{ \left(\sum_{d=1}^{p_r} \phi_d^{(r)} z_d \right) \bar{F}_r(s_t, \gamma, c) + \left(\sum_{j=1}^{p_{r+1}} \phi_j^{(r+1)} z_j \right) F_r(s_t, \gamma, c) \right\} + \varepsilon_{r,t} \end{aligned} \quad (9)$$

Sendo:

$$\gamma > 0$$

$$\Phi = (\gamma, c)$$

γ = grau de suavidade da função de transição

$\phi_d = (\phi_1, \dots, \phi_d)'$ = coeficientes lineares ligados aos regimes;

$F(s_t; \gamma, c)$ = função de transição

$$\bar{F}_r(s_t, \gamma, c) = 1 - F(s_t; \gamma, c)$$

$$E[\varepsilon_{r,t}^*] = 0, \quad E[\varepsilon_{r,t}^{*2}] = \sigma^2, \quad {}^1 E[\varepsilon_{r,t}^*, \varepsilon_{r,t+k}^*] = 0$$

$$z_t = (1, y_{t-1}, y_{t-2}, \dots, y_{t-p})' = z_d = z_j$$

r = sequência de regimes para o modelo AR(p_R) no regime R

A variância relativa $\varepsilon_{r,t}$ é um ruído branco de um processo gaussiano com variância σ_ε^2 , então $\varepsilon_{r,t}^* \sim N(0, \sigma_\varepsilon^2)$ o erro condicional à $y_{t-1}, y_{t-2}, \dots, y_{t-p}$ segue uma distribuição normal. Para aplicações práticas, o principal problema do uso deste modelo é descrever a relação entre o espaço de transição e os coeficientes. Por outro lado, o modelo STAR carrega importantes propriedades dos modelos lineares e ferramentas estatísticas para especificação, estimação e testes de diagnósticos [32].

* Erro aleatório (ε_t) segue uma distribuição normal condicional em relação a $y_{t-1}, y_{t-2}, \dots, y_{t-p}$ então $\varepsilon_{r,t}^* = \varepsilon_{r,t} \mid y_{t-1}, y_{t-2}, \dots, y_{t-p}$

O STAR possui algumas propriedades semelhantes ao modelo de regressão linear.

O interessante é determinar a função de transição para combinar dois modelos $AR(p_R)$ para fazer esta mudança de forma suave. Uma das opções para esta mudança é o LSTAR(1) que utiliza a função logística com função de transição $s_t = y_{t-1}$, assim atribui um peso a cada um dos modelos. Por exemplo, em Terävirta e Anderson [34] é usado a função de transição logística em sua análise do ciclo de negocio em US, que possui expansões e recessões que por convenção é uma característica do uso desta função de transição. Segue a formulação matemática do LSTAR(1):

$$y_t = (\alpha_1 + \beta_1 y_{t-1})F(y_{t-1}; \gamma, c) + (\alpha_2 + \beta_2 y_{t-1})[1 - F(y_{t-1}, \gamma, c)] + \varepsilon_t \quad (10)$$

$$F(s_t; \gamma, c) = \frac{1}{1 + e^{-\gamma(y_{t-1} - c)}} \quad (11)$$

Sendo: $s_t = y_{t-1}$


$$\gamma > 0, E[\varepsilon_t] = 0, E[\varepsilon_t^2] = \sigma^2$$

$\Phi = (\gamma, c) =$ parâmetros não lineares

$\gamma =$ grau de suavidade da função de transição

$c =$ limiar entre os dois regimes

$\Theta =$ parâmetros lineares $= (\alpha_{i0}, \dots, \alpha_{ip}, \dots, \beta_{i0}, \dots, \beta_{ip})'$; $i=1,2$



Fonte: Elaboração própria

Gráfico 4.1. Função logística com $c=0$, $\gamma = (1, 2.5, 5, 25 \text{ e } 1200)$

Através do gráfico 4.1 verifica-se que, ao aumentar o parâmetro não linear γ , a função se aproxima cada vez mais de uma função degrau, ou seja, tem-se uma mudança abrupta de regime. Comprova-se assim, que tendendo ao infinito o parâmetro γ da função de transição logística do modelo LSTAR, chega-se no modelo TAR. Já quando γ tende para zero, a função de transição logística fica igual a 0.5 e torna-se um modelo linear $AR(p)$ com ponderação dos parâmetros lineares como segue:

$$F(s_t; \gamma, c) = \frac{1}{1 + e^{-0(s_t - c)}} = \frac{1}{1 + e^0} = \frac{1}{2}$$

Aplicando no modelo LSTAR(1) temos:

$$y_t = (\alpha_1 + \beta_1 y_{t-1}) \frac{1}{2} + (\alpha_2 + \beta_2 y_{t-1}) \left[1 - \frac{1}{2} \right] + \varepsilon_t = \frac{\Theta}{2} y_{t-1} + \varepsilon_t \quad (12)$$

Sendo: $t = 0, 1, \dots, p$

Quando a função de transição entre dois regimes é governada pela função exponencial, utilizando $s_t = y_{t-1}$ e os modelos como AR(1), existe uma grande vantagem em associar ao mesmo regime valores baixos e altos da variável de transição s_t , então denomina-se o modelo como ESTAR(1) que é uma generalização do modelo EAR estudado por Haggan e Ozaki em [35]. Assim, a única mudança do modelo ESTAR para o LSTAR e a função de transição:

$$F(z_t; \gamma, c) = 1 - e^{-\gamma(y_{t-1} - c)^2} \quad (13)$$

Outro modelo derivado do STAR é o MRSTAR (Multiple Regime Smooth Transition AutoRegression) com propriedades descritas por Dijk e Franses em [36] que permite particionar os dados em mais de dois regimes.

Um modelo muito próximo ao STAR-TREE é o STR-TREE que é um modelo de regressão com transição suave (STR) estruturado em árvore e para cada divisão do nó raiz gera subconjuntos dos dados originais com graus de pertinência diferentes através da função logística e não subconjuntos exclusivos como ocorre no CART.

As etapas de estimação e modelagem são idênticos ao STAR-TREE a diferença é nos nós terminais teremos modelos de regressão linear e não modelos auto-regressivos.

Os passos para construção dos modelos STAR [37]:

- (1) Identificação. Identifica-se a ordem p do modelo AR;
- (2) Teste de Hipótese. Aplica-se o teste de linearidade do multiplicador de Lagrange, não sendo linear seleciona-se a variável de transição e sua respectiva função;
- (3) Especificação. Após a seleção da variável e da função de transição, o vetor dos parâmetros não lineares é estimado por mínimos quadrados ordinários não lineares, que sob certas condições de regularidade os estimadores são consistentes e assintoticamente distribuídos de acordo com a distribuição normal. Já nos parâmetros lineares a estimação é feita por MQO – Mínimos quadrados ordinários;
- (4) Verificação. Nesta etapa aplica-se testes: para verificar a qualidade do ajuste do modelo proposto, para verificar a correlação serial dos resíduos, verificar a constância dos parâmetros, verificar a variância ao longo do tempo e a não linearidade remanescente;
- (5) Previsão. Estimar os valores futuros através do modelo devidamente testado.

4.2.2

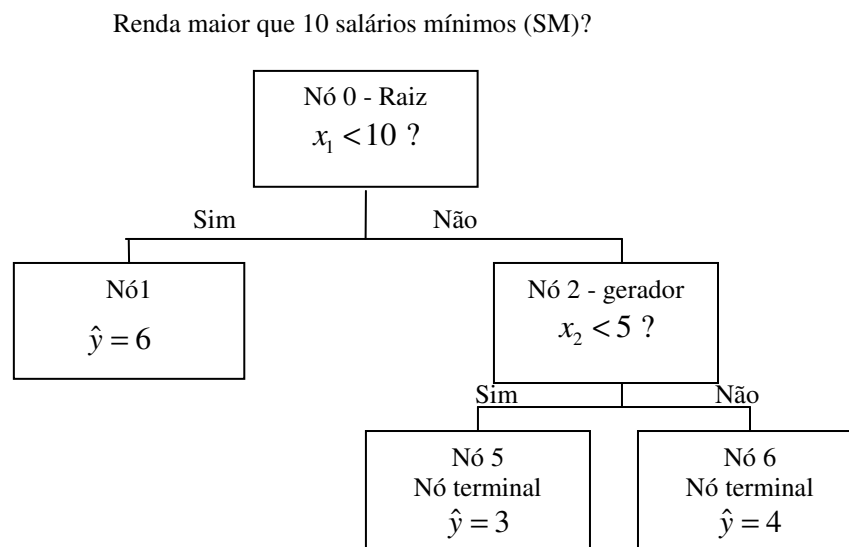
Modelo Cart

Árvore de classificação e regressão (Classification and Regression Tree), proposta inicialmente por Breiman, Friedman e Olshen em 1984 [38] pode ser considerada uma árvore de classificação se o atributo de estudo for nominal, e uma árvore de regressão se o atributo for contínuo. A grande vantagem deste modelo é a capacidade de pesquisar relações não evidentes entre os dados e mostrar de forma clara, podendo assim fazer conclusões mais facilmente, além de não ter premissas em relação à distribuição das variáveis do modelo, também não têm suposições sobre os componentes aleatórios e a forma funcional. A desvantagem é que o método não possui embasamento estatístico, sendo considerado um modelo não paramétrico. Ele simplesmente busca um equilíbrio entre redução do erro da estimação e o nível de complexidade do modelo.

A forma de apresentação é uma árvore binária iniciando com um nó raiz e

respondendo questões simples de “sim” ou “não”, vai se subdividindo através de uma variável de partição (s_i) que será escolhida dentro do conjunto $S = \{1, 2, \dots, m\}$. A divisão é determinada pelo limiar representado por c_i , então o nó que era terminal pode ser dividido em dois grupos tornando-se um nó gerador.

Um exemplo da representação gráfica de um modelo com três nós terminais, quatro folhas e com duas profundidades pode ser visto na figura 4.1. A numeração dos nós inicia-se do nó raiz com valor 0 e continua seqüencialmente, da esquerda para direita, em cada profundidade. Quando um nó não produz ramificações, a numeração prossegue. Assim, na figura 4.1 tem os nós três e quatro, que são os nós inexistentes e não aparecem na figura 4.1.



Fonte: Elaboração própria

Figura 4.1. Exemplo enumeração de árvore para regressão com ausência de alguns nós

A profundidade (d) medirá quantos ancestrais determinado nó possui. Definindo assim a complexidade da interação entre as variáveis explicativas do modelo.

A árvore de decisão forma um conjunto de regras que divide o conjunto em subconjuntos que no caso da figura 4.1 são 3 como segue:

Regra 1 - Se $x_1 < 10$, então a melhor previsão para y é 6.

Regra 2 - Se $x_1 \geq 10$ e $x_2 < 5$, então a melhor previsão para y é 3.

Regra 3 - Se $x_1 \geq 10$ e $x_2 \geq 5$, então a melhor previsão para y é 4.

Tem-se uma relação entre as variáveis explicativas $x_{i,t}$ e y_t como uma regressão linear, onde $s_{it} = \{x_{1t}, x_{2t}, \dots, x_{it}\}$ contém m variáveis explicativas para uma resposta univariada contínua $y_t \in \mathbb{R}$. Segue a formulação matemática do modelo de regressão, onde $f(\cdot)$ é desconhecida e não há suposições sobre a distribuição de ε_t :

$$y_t = f(s_t) + \varepsilon_t \quad (14)$$

A função desconhecida $f(\cdot)$ é aproximada por um modelo não linear que em cada nó é reestimado para cada divisão até obter um modelo final no nó terminal $B_i(s_t)$, que levará em consideração todo o caminho percorrido. Assim é definida uma função por partes em i subregiões. Assim a relação entre as duas variáveis na equação 15 é aproximada por uma regressão linear em um conjunto de m variáveis explicativas:

$$B_i(s_{i,t}) = \prod_{j=1}^{nJ} F_j(s_{i,t}, c_j)^{\frac{n_{i,j}(1+n_{i,j})}{2}} (1 - F_j(s_{i,t}, c_j))^{(1+n_{i,j})(1-n_{i,j})} \quad (15)$$

$$y_t = \sum_{i=1}^{nT} \Theta_i B_i(s_{i,t}) + \varepsilon_t \quad (16)$$

Sendo:

$$F(s_i, c_i) = \begin{cases} 1 & \text{se } s_{i,t} \leq c_i \\ 0 & \text{se } s_{i,t} > c_i \end{cases} \quad (17)$$

nT = total de nós terminais na árvore

nJ = total de nós geradores na árvore

$\Psi = (\Theta, \Phi)$

$\Phi = (c_0, c_1, \dots, c_i)'$ = parâmetros não lineares

Θ = parâmetros lineares = $(\beta_{i0}, \dots, \beta_{ip})'$;

c_i = limiar entre os dois regimes

$s_{i,t} = (x_{1,t}, \dots, x_{i,t})$ = conjunto de variáveis de divisão também chamadas de variáveis de partição ou limiar, pode ser composto por vetores com m variáveis explicativas.

$n_{i,j} = \begin{bmatrix} n_{1,1} & \dots & n_{1,nJ} \\ \vdots & \vdots & \vdots \\ n_{nT,1} & \dots & n_{nT,nJ} \end{bmatrix}$, esta matriz poderá receber os seguintes valores -1, 0 e 1,

de acordo com as seguintes regras:

$$n_{i,j} = \begin{cases} -1 & \text{Se o nó terminal não for filho deste nó gerador} \\ 0 & \text{Se o nó terminal for o filho do lado direito deste nó gerador} \\ 1 & \text{Se o nó terminal for o filho do lado esquerdo deste nó gerador} \end{cases}$$

A função B pode ser contínua quando atribuem diferentes graus de pertinência, ou indicadora quando atribuem dois valores: um se pertence ao conjunto e zero caso contrário, determinando duas regiões bem definidas que é o caso do modelo CART.

A definição da variável e do limiar para divisão é feita de maneira a minimizar os erros quadráticos da previsão. Estimam-se os β , calcula-se a soma do erro quadrático (SQE) do modelo de cada par (s_j, c_k) e o que obtiver o menor valor do SQE é escolhido para o determinado nó terminal. Essa técnica é chamada de pesquisa exaustiva.

A árvore pode ser podada de três formas principais: primeiramente se algum nó tiver menos de 5 observações será o nó terminal, outra forma é com o fator de custo-complexidade ou sua capacidade preditiva, que possui um parâmetro para penalizar a árvore pelo seu tamanho e, por último, validação cruzada que consiste em dividir a série em duas amostras: uma amostra interna conhecida para o modelo (in-sample) e outra fora da amostra (out-of-sample), que não foi vista pelo modelo assim verificando a capacidade preditiva do modelo. Para o nó raiz a equação a ser minimizada pode ser vista a seguir:

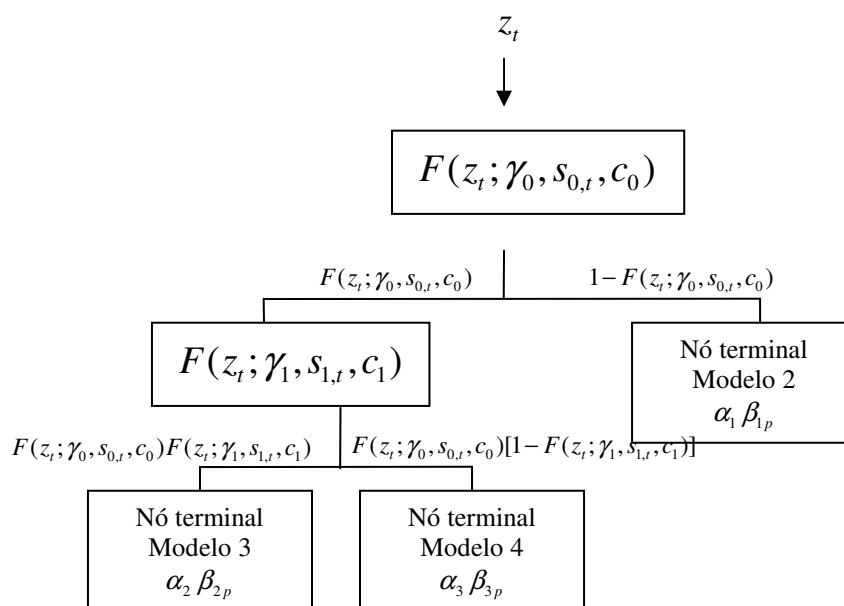
$$SQE_{nT} = \sum_{i=1}^N \left(y_i - \hat{y}_i^{nT} \right)^2 = \sum_{i=1}^N \left(y_i - \left\{ \beta_1 F(s_0, c_0) + \beta_2 [1 - F(s_0, c_0)] \right\} \right)^2$$

Selecionado o par (s_0, c_0) que minimiza a soma dos erros quadráticos, há a divisão da raiz, então é estimado o vetor $(s_0, c_0, \beta_1, \beta_2)$. O processo continua para o próximo nó, e se houver nova divisão o modelo é reespecificado, caso não haja mais ganho no crescimento, realiza-se a podagem determinando os nós terminais de acordo com medidas de custo, complexidade ou capacidade preditiva do modelo. Pode-se dizer que é um método automático de aprendizado por máquina, não possui embasamento estatístico, simplesmente busca minimizar o erro sem tornar o modelo muito complexo.

4.2.3

Modelo Star-Tree

Nesta seção será descrito o STAR-TREE que é a combinação dos modelos CART e STAR já vistos nas seções anteriores. A idéia é utilizar o CART na modelagem do STAR para particionar o espaço de transição através de uma árvore que deixa de ser binária e passa a ser regida pelas funções de pertinência (γ_i) que foi descrita na seção sobre o modelo STAR. Os coeficientes α e β serão determinados nos nós terminais através da combinação de diferentes modelos, que podem ser autorregressivos se o conjunto de variáveis explicativas for autoregressora defasada ($d>0$). Utilizando a função de transição logística da equação 11, generalizando o conjunto de variáveis explicativas para z_t . Pode-se ilustrar como os parâmetros do modelo que estão associados aos nós da árvore e os modelos associados:



Fonte: Elaboração própria

Figura 4.2. Árvore de decisão do STAR-TREE com os parâmetros associados

$$\begin{aligned}
 B_1(z_t, \Psi_1) &= [1 - F(z_t; \gamma_0, s_{0,t}, c_0)](\alpha_1 + \beta_1 z_t) \\
 B_2(z_t, \Psi_2) &= F(z_t; \gamma_0, s_{0,t}, c_0)[(\alpha_2 + \beta_2 z_t)F(z_t; \gamma_1, s_{1,t}, c_1)] \\
 B_3(z_t, \Psi_3) &= F(z_t; \gamma_0, s_{0,t}, c_0)\{(\alpha_3 + \beta_3 z_t)[1 - F(z_t; \gamma_1, s_{1,t}, c_1)]\}
 \end{aligned} \tag{18}$$

Podemos interpretar $B_i(z_t, \Psi_i)$ como o produtório das funções de transição logística. Multiplicando as funções desde os nós de decisão superiores até os nós terminais, onde se encontra o modelo AR(p_R). Chamaremos de Tindex o conjunto com os índices dos nós terminais, no caso Tindex=[2, 3, 4], e Jindex o conjunto com os índices dos nós geradores, no caso Jindex=[0, 1]. Assim temos um total de três nós terminais neste exemplo nT=3 e um total de dois nós geradores nJ=2.

Segue a formulação matemática do modelo STAR-TREE que representa a figura 5.3 [32]:

$$y_t = B_1(z_t, \Psi_1) + B_2(z_t, \Psi_2) + B_3(z_t, \Psi_3) + \varepsilon_t \quad (19)$$

$$y_t = (\alpha_1 + \beta_{1p} z_t)[1 - F(s_{0,t}; \gamma_0, c_0)] + F(s_{0,t}; \gamma_0, c_0) \{ (\alpha_2 + \beta_{2p} z_t) F(s_{1,t}, \gamma_1, c_1) + (\alpha_3 + \beta_{3p} z_t) [1 - F(s_{1,t}, \gamma_1, c_1)] \} + \varepsilon_t \quad (20)$$

$$F(\gamma, s, c) = \frac{1}{1 + e^{-\gamma(s_i - c)}}$$

Generalizando:

$$B_i(z_t) = \prod_{j=1}^{nJ} F_j(s_t; \gamma_j, s_j, c_j)^{\frac{n_{i,j}(1+n_{i,j})}{2}} (1 - F_j(s_t; \gamma_j, s_j, c_j))^{(1+n_{i,j})(1-n_{i,j})} \quad (21)$$

$$y_t = H(z_t; \Phi) \sum_{i=1}^{nT} \Theta_i B_i(z_{s_i,t}) + \varepsilon_t \quad (22)$$

Sendo:

z_t = conjunto de variáveis explicativas que é um sub-conjunto do conjunto de variáveis de transição s_t

γ = grau de suavidade da função de transição

p = quantidade de parâmetros do modelo AR

nT = total de nós terminais na árvore

nJ = total de nós geradores na árvore

$\Psi = (\Theta, \Phi)$

$\Phi = (\gamma, c) = (\gamma_0, \gamma_1, \dots, \gamma_j, c_0, c_1, \dots, c_j)$;

Θ = parâmetro linear = $(\alpha_{i0}, \dots, \alpha_{ip}, \dots, \beta_{i0}, \dots, \beta_{ip})'$;

c_i = limiar entre os dois regimes

$s_t = (y_{t-1}, y_{t-2}, \dots, y_{t-p}, x_{1,t}, \dots, x_{1,t-p_1}, \dots, x_{k,t}, \dots, x_{1,t-p_k})$ = conjunto variáveis de transição também chamadas de variáveis de partição ou limiar, pode ser composta pelo vetor com m variáveis explicativas.

$$\gamma > 0, E[\varepsilon_t] = 0, E[\varepsilon_t^2] = \sigma^2$$

$$n_{i,j} = \begin{bmatrix} n_{1,1} & \dots & n_{1,nJ} \\ \vdots & \vdots & \vdots \\ n_{nT,1} & \dots & n_{nT,nJ} \end{bmatrix}, \text{ esta matriz poderá receber os seguintes valores } -1, 0 \text{ e } 1,$$

de acordo com as seguintes regras:

$$n_{i,j} = \begin{cases} -1 & \text{Se o nó terminal } \tilde{n} \text{ for filho deste nó gerador} \\ 0 & \text{Se o nó terminal for o filho do lado direito deste nó gerador} \\ 1 & \text{Se o nó terminal for o filho do lado esquerdo deste nó gerador} \end{cases}$$

A nomenclatura utilizada para determinar o número de divisões da árvore será d e já o número de nós inexistentes ou nós que não produziram divisões em uma das profundidades será denominado f . A profundidade da árvore pode ser determinada por $nT = 2^d - f$ que será o número de nós terminais. Já o número de variáveis de transição a serem especificadas, que na verdade é a quantidade de nós que dão filhotes que podemos chamar de “nós geradores” é

$$nJ = \sum_{i=0}^{d-1} 2^i - f \text{ onde os parâmetros não lineares devem ser estimados. O}$$

número total de parâmetros a serem estimados será $r = p * nT + 2nJ$ onde p é o número de parâmetros dos modelos $AR(p_R)$. Aplicando no exemplo da figura 4.2, considerando $AR(1)$ e $p=2$, temos duas divisões na árvore e um nó que não produziu divisões na segunda profundidade, então $d=2$ e $f=1$, aplicando as fórmulas temos $nT=3$ nós terminais e $nJ=2$ nós geradores, assim teremos um total de $r = 2 * 3 + 4 = 6 + 4 = 10$ parâmetros a serem estimados sendo seis parâmetros lineares e quatro parâmetros não lineares.

Uma das principais vantagens desta metodologia é que o modelo de transição suave é especificado por um método estatístico. Assim é possível utilizar os testes de hipótese e outras ferramentas estatísticas para especificação e estimação. Outra vantagem é o gráfico final em árvore, que facilita a interpretação além de ser possível particionar os dados em mais do que dois regimes.

O parâmetro γ , determina a suavidade do modelo, fornecendo diferentes graus de pertinência às observações. Quando este parâmetro tende ao infinito, o modelo torna-se um caso particular do modelo de árvore de regressão do CART, já quando tende a zero não há ganho em produzir divisão no nó. Assim não podendo ser aplicada a metodologia.

O parâmetro c aqui vira um localizador da função, tem que ser bem escolhido para não predominar um modelo sobre outro na estimação.

A variável de transição escolhida é a que obtiver o menor valor da estatística ML_F através do teste de multiplicador de Lagrange (ML). Condicionada a esta escolha estima-se o grau de suavidade da função de transição (γ) e o limiar c entre os dois regimes. A estimação é feita por MQNL, mas como o algoritmo é muito sensível aos valores iniciais é feita uma estimação destes parâmetros não lineares através de uma grade de possíveis valores, como segue abaixo:

$c = \{s_{0.05}, s_{0.1}, s_{0.2}, s_{0.3}, s_{0.4}, s_{0.5}, s_{0.6}, s_{0.7}, s_{0.8}, s_{0.9}, s_{0.95}\}$, onde s_i representa o i -ésimo percentil da variável de transição.

$$\gamma = \{0.1 \ 0.5 \ 1 \ 5 \ 10 \ 50 \ 100\}$$

Para cada combinação do (γ , c) estimam-se a função logística, os β , o γ estimado e os resíduos. Calcula-se a soma dos erros quadráticos dos resíduos (SQE) do modelo estimado de cada par (s_j, c_k) , e o que obtiver o menor valor do SQE é escolhido como o par (s_j, c_k) inicial para o determinado nó gerador, pois os valores finais serão calculados pelo método de mínimos quadrados não lineares (MQNL). Essa técnica é chamada de pesquisa exaustiva.

$$SQE_{nT} = \sum_{t=1}^N \left(y_t - \hat{y}_t^{nT} \right)^2 = \sum_{t=1}^N \left(y_t - \left\{ \beta_1 F(\gamma_0, s_0, c_0) + \beta_2 [1 - F(\gamma_0, s_0, c_0)] \right\} \right)^2 \quad (23)$$

Selecionado o par (s_0, c_0) que minimiza a soma dos erros quadráticos, há a divisão da raiz, então é estimado o vetor $(s_0, c_0, \beta_1, \beta_2)$. Avalia-se o modelo estimado, para verificar se pelo menos um parâmetro linear é significativo, se todos forem não significativos então retorna ao estágio de especificação e a

próxima variável de divisão ligada ao ranking de p-valores é selecionada. Após verificar todas as variáveis de divisão e nenhuma produzir parâmetros lineares significativos então será necessário estimar a série através de um modelo linear.

Os passos para construção dos modelos STAR-TREE iniciando do nó raiz:

(1) Especificação :

- a. 1º Profundidade (nó raiz) - Primeiro verificar se há necessidade de divisão do nó através do teste de ML que será detalhado mais adiante, sendo a hipótese nula o modelo mais simples contra a alternativa de um modelo utilizando a expansão de Taylor. Compara-se os modelos através do teste F. Se o p-valor for menor que 0.05 a árvore será dividida.. Seleção da variável de divisão é de acordo com o menor p-valor dentro do conjunto s_t , que pode ser y_{t-1} ou $x_{1,t}$ etc. Se o p-valor for maior que 0.05 então não é possível rejeitar a hipótese nula e não haverá divisão. Neste caso, o modelo mais simples será estimado. Caso contrário, teremos que seguir os passos e verificar se haverá uma segunda profundidade.
- b. 2º Profundidade e seguintes – Dado que o nó raiz foi subdividido, para verificar se os atuais nós terminais também serão subdivididos, primeiramente estima-se valores iniciais de γ e c , como explicado anteriormente. Este par inicial será utilizado nos MQNL para estimar o γ e c finais. Assim calculam-se os modelos finais dos nós terminais e suas respectivas pertinências. Determinados os modelos que serão testados contra o modelo mais simples através do teste de ML, os passos seguintes são idênticos os da 1º profundidade. Este passo é repetido até não haver mais necessidade de divisões.

(2) Avaliação do modelo estimado através da habilidade preditiva nos dados fora da amostra, para verificar se é necessário alterar o nó a ser dividido, alterar a variável de divisão ou até remover a divisão.

(3) Utilizar o modelo final para previsão ou apenas para análise descritiva

O processo continua para o próximo nó, e se houver nova divisão o modelo é reespecificado, caso não haja mais ganho no crescimento, realiza-se a podagem

determinando os nós terminais de acordo com medidas de custo, complexidade ou capacidade preditiva do modelo. Pode-se dizer que é um método automático de aprendizado por máquina, não possui embasamento estatístico, simplesmente busca minimizar o erro sem tornar o modelo muito complexo.

4.2.3.1

Estimador De Mínimos Quadrados Não Lineares (MQNL)

É a forma utilizada para estimar os parâmetros não lineares do modelo, ou seja, $\Phi = (\gamma_1, \gamma_2, \dots, \gamma_j, c_1, c_2, \dots, c_j)$. Equivale à estimação por máxima verossimilhança condicional. Para o uso dessa metodologia é necessário seguir as hipóteses que estão em ROSA [37]. Segue um sucinto resumo:

- (1) Conjunto de dados z_t devem ser IID e provenientes de uma série temporal ou dados em painel.
- (2) Suposição sobre $\{\varepsilon_t\}_{t=1}^T$ ser formado por variáveis aleatórias independentes distribuídas com média zero e variância $\sigma^2 < \infty, \varepsilon_t \sim NID(0, \sigma^2)$
- (3) O vetor ψ com os verdadeiros valores dos parâmetros é um ponto no interior do espaço paramétrico compacto Ψ contido no \mathbb{R} .
- (4) Suposição que garante que o modelo STAR-TREE é identificável. Informando que os parâmetros de suavidade são números reais, com $\gamma_i > 0$ sendo $i = 1, \dots, nJ$ e nJ o nº de nós geradores.

A Máxima verossimilhança condicional é equivalente a Mínimos Quadrados Não-Lineares. Com o uso da MV é possível ter noção da incerteza sobre as estimativas dos parâmetros através do desvio padrão das estimativas. Segue a formulação matemática do estimador MQNL:

$$\hat{\psi} = \arg \min_{\phi \in \Phi} T^{-1} Q_T(\Phi) = \arg \min_{\phi \in \Phi} T^{-1} \sum_{t=1}^T q_t(\Phi) \quad (24)$$

Sendo:

$$\Phi = (\gamma, c) = (\gamma_0, \gamma_1, \dots, \gamma_j, c_0, c_1, \dots, c_j);$$

$$q_t(\Phi) = [y_t - H(z_t; \Phi)]^2$$

A matriz de informação da função de log-verossimilhança é bloco-

diagonal, de modo que a verossimilhança pode ser concentrada e primeiramente estimados os parâmetros não lineares da média condicional dos parâmetros lineares usando o algoritmo de Levenberg-Marquadt. Segue a estimação condicionada ao conhecimento dos parâmetros não lineares:

$$\hat{\beta} = \left[Z(\Phi)' Z(\Phi) \right]^{-1} Z(\Phi)' y \quad (25)$$

Sendo:

$$Z(\Phi) = \begin{bmatrix} \tilde{z}_1 B_1(x_1; \gamma_1, c_1) & \cdots & \tilde{z}_1 B_k(x_1; \gamma_k, c_k) \\ \vdots & \vdots & \vdots \\ \tilde{z}_T B_1(x_T; \gamma_1, c_1) & \cdots & \tilde{z}_T B_k(x_T; \gamma_k, c_k) \end{bmatrix}$$

Os valores iniciais dos parâmetros não lineares são escolhidos através de uma grade de valores que busca a maximização da função de log-verossimilhança concentrada como já explicado anteriormente. O objetivo é minimizar problemas na estimação por MQNL que é sensível aos valores iniciais.

É necessário demonstrações e explicações para verificar se as estimativas geradas pelos estimadores representam bem a população, isso significa verificar a existência, consistência e normalidade dos estimadores MQNL pode ser visto em [37] e [39].

4.2.3.2

Teste Multiplicador De Lagrange – Divisão Dos Nós

Este é o teste que verifica se haverá necessidade de divisão ou não iniciando do nó raiz e escolhe a variável de transição. Assim segue o exemplo que está sendo trabalhado:

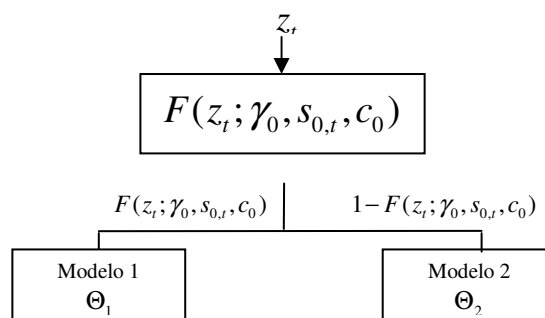


Figura 4.3. Árvore de decisão do STAR-TREE com primeira divisão

$$\begin{aligned} B_1(z_t, \Psi_1) &= \Theta_1 F(z_t; \gamma_0, s_{0,t}, c_0) \\ B_2(z_t, \Psi_2) &= \Theta_2 [1 - F(z_t; \gamma_0, s_{0,t}, c_0)] \end{aligned} \quad (26)$$

$$y_t = \Theta_1 F(z_t; \gamma_0, s_{0,t}, c_0) + \Theta_2 [1 - F(z_t; \gamma_0, s_{0,t}, c_0)] + \varepsilon_t \quad (27)$$

Pode-se reescrever o modelo como um STR-TREE para a árvore mais simples como:

$$\begin{aligned} y_t &= \Theta_1 F(z_t; \gamma_0, s_{0,t}, c_0) + \Theta_2 - \Theta_2 F(z_t; \gamma_0, s_{0,t}, c_0) + \varepsilon_t \\ y_t &= \Theta_2 + (\Theta_1 - \Theta_2) F(z_t; \gamma_0, s_{0,t}, c_0) + \varepsilon_t \\ y_t &= \phi_0 + \lambda_0 F(z_t; \gamma_0, s_{0,t}, c_0) + \varepsilon_t \end{aligned} \quad (28)$$

Sendo:

$$\begin{aligned} \phi_0 &= \Theta_2 \\ \lambda_0 &= (\Theta_1 - \Theta_2) \end{aligned}$$

O teste de hipótese, para verificar se haverá uma primeira divisão ou não, será colocando a hipótese nula do grau de suavidade como 0, ou seja, $\gamma_0 = 0$ ou $\lambda_0 = 0$. Entretanto o modelo não pode ser consistente se estimado em função dos parâmetros de perturbação λ_0 e c_0 , pois podem assumir diferentes valores sem que a função de verossimilhança seja modificada, o que de acordo com [40] e [41] pode criar um problema de identificação.

A solução aplicada foi apresentada em [28] e [29] e aproxima à função de transição $F(\cdot)$ por uma expansão de Taylor de 3º ordem em torno de $\gamma_0 = 0$, como segue:

$$y_t = \alpha_0 + \alpha_1 x_{s_0,t} + \alpha_2 x_{s_0,t}^2 + \alpha_3 x_{s_0,t}^3 + e_t \quad (29)$$

Sendo:

$$\alpha_i \text{ em função de } \gamma_0, c_0, \phi_0 \text{ e } \lambda_0 \quad i = 0, 1, 2, 3$$

$$e_t = \varepsilon_t + \lambda_0 R(z_t; \gamma_0, s_0, c_0)$$

$$R(z_t; \gamma_0, s_0, c_0) \text{ termo remanescente na expansão de Taylor}$$

No novo teste de hipótese, a hipótese nula será a igualdade $\alpha_1 = \alpha_2 = \alpha_3$ e sob ela $\lambda_0 R(z_t; \gamma_0, s_0, c_0) = 0$ e $e_t = \varepsilon_t$. Assim permanecendo inalteradas as propriedades do erro. Desta forma, a inferência assintótica é usada para achar a estatística de teste, através de uma aproximação local para função de máxima

log-verossimilhança:

$$\prod_{i=1}^n \frac{1}{\sigma\sqrt{2\pi}} \exp \left\{ -\frac{\left[y_t - (\alpha_0 + \alpha_1 x_{s_0,t} + \alpha_2 x_{s_0,t}^2 + \alpha_3 x_{s_0,t}^3) \right]^2}{2\sigma^2} \right\} \quad (30)$$

$$= -\frac{1}{2} \ln(2\pi) - \frac{1}{2} \ln(\sigma^2) - \frac{1}{2\sigma^2} \left\{ y_t - \alpha_0 - \alpha_1 x_{s_0,t} - \alpha_2 x_{s_0,t}^2 - \alpha_3 x_{s_0,t}^3 \right\}^2$$

Derivando e assumindo que $E|x_{s_0,t}|^\delta < \infty, \forall s_0 \in \mathbb{S}$, para algum $\delta > 6$ e que $\varepsilon_t \sim NID(0, \sigma^2)$, tem-se o seguinte resultado para ML:

$$ML = \frac{1}{\sigma^2} \sum_{t=1}^T \hat{\varepsilon}_t v_t' \left\{ \sum_{t=1}^T v_t v_t' - \sum_{t=1}^T v_t h_t' \left(\sum_{t=1}^T h_t h_t' \right)^{-1} \sum_{t=1}^T h_t v_t' \right\}^{-1} \sum_{t=1}^T v_t \hat{\varepsilon}_t \quad (31)$$

Sendo:

$$\hat{\varepsilon}_t = y_t - \hat{y}_t^{\text{Arv}(i)} \quad \text{- conjunto de resíduos estimados sob a hipótese nula}$$

$$\hat{\sigma}^2 = (1/T) \sum_{t=1}^T \hat{\varepsilon}_t^2$$

$$\hat{h}_t = \frac{\partial H(x_t; \psi)}{\partial \psi'} \Big|_{\mathcal{H}_0}$$

$$\hat{v}_t = (x_{s_0,t}, x_{s_0,t}^2, x_{s_0,t}^3)'$$

e seguem distribuição assintótica χ_3^2 . Note que sob \mathcal{H}_0 ,

$$\hat{\beta}_0 = \frac{1}{T} \sum_{t=1}^T y_t \xrightarrow{p} E(y_t).$$

Dado que a hipótese nula foi rejeitada, então houve divisão do nó raiz e os parâmetros do modelo mais simples foram estimados. O próximo passo é formular um novo modelo para testar se haverá divisão dentre um dos dois nós criados. Por exemplo, seja o nó filhote esquerdo que constituirá o seguinte modelo:

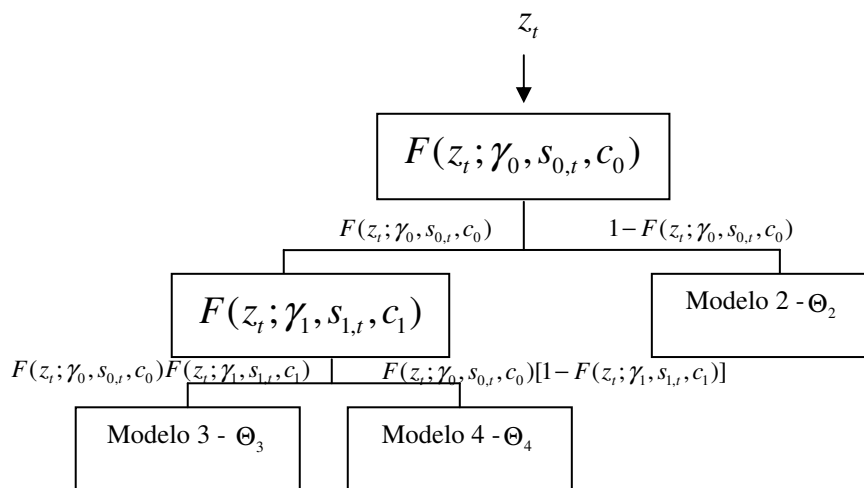


Figura 4.4. Árvore de decisão do STAR-TREE com os parâmetros associados

$$\begin{aligned}
 B_2(z_t, \Psi_2) &= [1 - F(z_t; \gamma_0, s_{0,t}, c_0)] \Theta_2 \\
 B_3(z_t, \Psi_3) &= F(z_t; \gamma_0, s_{0,t}, c_0) [\Theta_3 F(z_t; \gamma_1, s_{1,t}, c_1)] \\
 B_4(z_t, \Psi_4) &= F(z_t; \gamma_0, s_{0,t}, c_0) \{ \Theta_4 [1 - F(z_t; \gamma_1, s_{1,t}, c_1)] \}
 \end{aligned} \tag{32}$$

$$\begin{aligned}
 y_t &= \Theta_2 [1 - F(s_{0t}; \gamma_0, c_0)] + \\
 &F(s_{0t}; \gamma_0, c_0) \{ \Theta_3 F(s_{1t}, \gamma_1, c_1) + \Theta_4 [1 - F(s_{1t}, \gamma_1, c_1)] \} + \varepsilon_t
 \end{aligned} \tag{33}$$

Portanto, reescrevendo a função anterior e seguindo os passos já feitos na raiz, segue:

$$\begin{aligned}
 y_t &= \Theta_2 [1 - F(z_t; \gamma_0, s_{0t}, c_0)] + F(z_t; \gamma_0, s_{0t}, c_0) \\
 &\{ \Theta_3 F(z_t; \gamma_1, s_{1t}, c_1) + \Theta_4 [1 - F(z_t; \gamma_1, s_{1t}, c_1)] \} + \varepsilon_t \\
 y_t &= \Theta_2 [1 - F(z_t; \gamma_0, s_{0t}, c_0)] + [\Theta_4 + (\Theta_3 - \Theta_4) \\
 &F(z_t; \gamma_1, s_{1t}, c_1)] F(z_t; \gamma_0, s_{0t}, c_0) + \varepsilon_t
 \end{aligned} \tag{34}$$

$$\begin{aligned}
 y_t &= \Theta_2 [1 - F(z_t; \gamma_0, s_{0t}, c_0)] + [\phi_1 + \\
 &\lambda_1 F(z_t; \gamma_1, s_{1t}, c_1)] F(z_t; \gamma_0, s_{0t}, c_0) + \varepsilon_t
 \end{aligned}$$

Sendo:

$$\begin{aligned}
 \phi_1 &= \Theta_4 \\
 \lambda_1 &= (\Theta_3 - \Theta_4)
 \end{aligned}$$

Aproximando a função para expansão de 3º ordem da série de Taylor tem-se:

$$y_t = \alpha_0 + \alpha_1 F(z_t; \gamma_0, s_{0t}, c_0) + \alpha_2 F(z_t; \gamma_0, s_{0t}, c_0) x_{s_1, t} + \alpha_3 F(z_t; \gamma_0, s_{0t}, c_0) x_{s_1, t}^2 + \alpha_4 F(z_t; \gamma_0, s_{0t}, c_0) x_{s_1, t}^3 + e_t \quad (35)$$

Sendo:

α_i em função de γ_0, c_0, ϕ_0 e λ_0 $i = 2, 3, 4$

$e_t = \varepsilon_t + R(z_t; \gamma_1, s_1, c_1)$

$R(z_t; \gamma_1, s_1, c_1)$ termo remanescente na expansão

Segue a hipótese nula e a estatística de teste sem o problema da consistência:

$$\mathcal{H}_0 : \alpha_i = 0, i = 2, 3, 4$$

$$\hat{h}_t = \left. \frac{\partial H(x_t; \psi)}{\partial \psi'} \right|_{\mathcal{H}_0} = \left(\left. (1, F(z_t; \gamma_0, s_{0t}, c_0), \frac{\partial F(z_t; \gamma_0, s_{0t}, c_0)}{\partial \gamma_0} \right|_{\mathcal{H}_0}, \left. \frac{\partial F(z_t; \gamma_0, s_{0t}, c_0)}{\partial c_0} \right|_{\mathcal{H}_0} \right)'$$

$$\hat{v}_t = (F(z_t; \hat{\gamma}_0, s_{0t}, \hat{c}_0) x_{s_1, t}, F(z_t; \hat{\gamma}_0, s_{0t}, \hat{c}_0) x_{s_1, t}^2, F(z_t; \hat{\gamma}_0, s_{0t}, \hat{c}_0) x_{s_1, t}^3)'$$

A estatística de decisão pode ser calculada seguindo os passos a seguir, mas deve-se utilizar a versão F do teste do tipo ML e supor a normalidade dos erros, que torna a matriz de informação um bloco diagonal, e a variância do erro fixa. Segue-se os passos:

- (1) Estimar o modelo do nó raiz para verificar se haverá divisão, como demonstrado nas equações 26 à 31 e calcular os resíduos correspondentes deste modelo $\hat{\varepsilon}_t$. Computar também a soma dos

$$\text{resíduos quadráticos (SQE} = \sum_{t=1}^T \hat{\varepsilon}_t^2 \text{)}.$$

- (2) Fazer a regressão de $\hat{\varepsilon}_t$ em h_t e v_t . Computar também a soma dos

$$\text{resíduos quadráticos (SQE} = \sum_{t=1}^T \hat{v}_t^2 \text{)}.$$

- (3) Calcular a estatística χ_m^2

$$ML_F = \frac{\frac{(SQE_0 - SQE_1)}{m}}{\frac{SQE_1}{[T - (p + m)]}} \sim F_{(m, T - n - m)} \quad (36)$$

Sendo: $P = n^\circ$ total de elementos no vetor h_i

$T =$ tamanho da amostra

$m = n^\circ$ de parâmetros no testado modelo em H_1

$p = n^\circ$ de parâmetros no modelo testado em H_0

4.2.3.3

Ciclo De Modelagem – Sequência De Testes

Neste capítulo iremos abordar uma solução para o controle do erro tipo 1, isto é, mostrar um número maior de partições significativas do que realmente deveria ser. Como a complexidade da árvore é toda baseada nos nós terminais que vêm de nós geradores, então, dividir errado um nó pode ocasionar conclusões errôneas no modelo.

O problema ocorre devido aos múltiplos testes de significância que ocorre no teste de multiplicador de Lagrange. Deste modo controlaremos o erro mais grave (erro tipo 1) diminuindo o nível de significância do teste α conforme o crescimento da árvore, equação 37. Assim não é necessário realizar a podagem a posteriori.

$$\alpha(d, n) = \frac{\alpha}{n^d} \quad (37)$$

Sendo:

$d =$ d-ésima profundidade da árvore

$n =$ n-ésimo teste na sequência

4.2.3.4

Previsão

A previsão por combinação de regimes (RC) ocorre com a aplicação do modelo estimado obtendo a previsão um passo a frente, usando as pertinências das observações em cada regime, como peso na soma ponderada dos modelos lineares

4.3

Métricas Para Comparação Dos Modelos

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, SMAPE, Rvar, AIC e BIC.

$$\text{Raiz do erro quadrático médio (RMSE)} = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2} = \sqrt{\frac{1}{N} \sum_{t=1}^N e_t^2} \quad (38)$$

$$\text{Erro absoluto médio (MAE)} = \frac{1}{N} \sum_{t=1}^N |e_t| \quad (39)$$

$$\text{Erro percentual absoluto médio (MAPE)} = \frac{100}{N} \sum_{t=1}^N \frac{|e_t|}{y_t} \quad (40)$$

$$\text{Erro percentual absoluto médio simétrico (SMAPE)} = \frac{100}{N} \sum_{t=1}^N \frac{|e_t|}{\left(\frac{|y_t| + |\hat{y}_t|}{2} \right)} \quad (41)$$

$$\text{Razão entre variâncias (Rvar)} = \frac{\text{Var}(e_t)}{\text{Var}(y_t)} \quad (42)$$

$$\text{Critério de informação Akaike (AIC)} = N \log \left(\frac{\sum_{t=1}^N e_t^2}{N} \right) + 2(nT \times p + 2 \times nJ) \quad (43)$$

$$\text{Critério de informação bayesiano (BIC)} = N \log \left(\frac{\sum_{t=1}^N e_t^2}{N} \right) + (nT \times p + 2 \times nJ) \log(N) \quad (44)$$

Para comparar os modelos lineares com não lineares, será escolhido o

modelo que obtiver menores valores nas estatísticas RMSE, MAPE, SMAPE, MAE e Rvar.

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. Já o SMAPE minimiza o erro do MAPE evitando grandes erros pontuais tenham peso exagerado. O SMAPE é recomendado quando a série possui falhas ou picos.

Rvar verifica se a variância do erro é muito diferente da variância dos dados, quanto mais próxima de um quer dizer que não são muito diferentes, já se for menor que um quer dizer que a variância do erro é menor que a dos dados.

As estatísticas AIC e BIC penalizam os modelos com maior número de parâmetros, sendo para BIC esta penalidade é mais rigorosa. Verificando a metodologia do STAR-TREE pode-se ver que esta modelagem possui parâmetros lineares e não lineares, tendo assim sempre um número maior de parâmetros que os modelos lineares do Box & Jenkins. Assim esta métrica só foi utilizada para escolher o melhor dos modelos STAR-TREE e o melhor dos modelos Box & Jenkins.

5 Estudo De Caso

Os dados utilizados neste trabalho são de geração de energia eólica medidos em MW (megawatt) e foram obtidos através no site da Operadora Nacional do Sistema – ONS². O sistema da ONS fornece a geração de energia hidráulica, térmica e eólica com periodicidade semanal³ por usina e as compara com o valor previsto. O Plano diário de produção (PDP) apura os dados de geração das usinas despachadas centralizadamente, as chamadas usinas do Tipo I. Essa apuração é realizada a partir da entrada em operação em teste da primeira unidade geradora da usina. As usinas estudadas são aquelas com mais de um ano de informação.

O estudo é realizado em um determinado período para cinco parques eólicos como exposto na tabela abaixo:

Tabela 5.1. Usinas eólicas participantes do PDP

	EOL R.DO FOGO		EOL D.INDIOS		EOL SANGRADOU		EOL C.QUEBRADA		EOL ENACEL	
	N	Período	N	Período	N	Período	N	Período	N	Período
Total	312	01/07/06 - 22/06/12	291	25/11/06 - 22/06/12	304	26/08/06 - 22/06/12	132	12/12/09 - 22/06/12	12 1	27/02/10 - 22/06/12
In-sample	250	01/07/06 - 15/04/11	233	25/11/06 - 13/05/11	243	26/08/06 - 08/04/11	106	12/12/09 - 23/12/11	97	27/02/10 - 06/01/12
Out-of-sample	62	16/04/11 - 22/06/12	58	14/05/11 - 22/06/12	61	09/04/11 - 22/06/12	26	24/12/11 - 22/06/12	24	07/01/12 - 22/06/12

Fonte: própria

Na modelagem, os dados foram divididos em dois grupos análise dentro da amostra (in-of-sample) com 80% das observações e os 20% restantes são para fazer as previsões fora da amostra (out-of-sample) validando os modelos ajustados.

A modelagem dos dados foi realizada nos softwares Matlab e R.

² Resultado da operação - Boletim semanal da operação – Geração Hidráulica, térmica e geração por usina – Aba eólica por usina

³ Semanas correspondem ao período que se inicia à 0h00min do sábado e termina às 24h00min da sexta-feira subsequente e abrangem todos os dias do mês a que se refere o estudo, podendo também incluir dias dos meses adjacentes.[42]

Segue tabela com maiores detalhes sobre os parques eólicos e seus aerogeradores:

Tabela 5.2. Características gerais dos parques eólicos em estudo

	EOL R.DO FOGO	EOL D.INDIOS	EOL SANGRAD	EOL C.QUEBRADA	EOL ENACEL
MUNICÍPIO – UF	Rio do Fogo - RN	Osório – RS	Osório – RS	Aracati - CE	Aracati - CE
Região	Nordeste	Sul	Sul	Nordeste	Nordeste
Potência ortogada e fiscalizada (KW)	49.300	50.000	50.000	57.000	31.500
Proprietário	Energias Renováveis do Brasil S.A.	Ventos do Sul Energia S/A		Bons Ventos Geradora de Energia S.A.	
Fator de capacidade estimado(%)	34	30	33	43.5	43.54
Potência Nominal (MW)	49,3	50	50	57	31,5
Aerogeradores	61 de 800 kW e 01 de 500 kW	25 de 2.000 kW	25 de 2.000 kW	22 de 2.100kW e 6 de 1.800kW	15 de 2.100kW

Fonte: Retirado do boletim mensal da ONS de jan/2012

Verifica-se que são três parques eólicos com maior número de informação para modelagem e outros dois parques eólicos com menor número assim é possível verificar o comportamento dos modelos para amostras pequenas.

Em relação a localização dos parques eólicos do estudo na tabela 5.2 é possível ver que duas são da região sul e da mesma localidade e três são da região nordeste, sendo duas da mesma localidade.

6 Aplicação Aos Dados Reais

6.1

Análise Inicial Da Série

Nesta seção serão descritas as análises exploratórias para verificar as principais características da série temporal. Análises e gráficos adicionais serão apresentados no anexo 9.3 que está dividido por parque eólico. Na tabela abaixo, seguem as estatísticas descritivas:

Tabela 6.1. Análise descritiva em MW médio dos parques em estudo

	N	Média	Moda	s^2	s	Mín.	Máx	1° Quartil	2° Quartil	3° Quartil
R DO FOGO	312	15,80	12,00	45,26	6,73	1,71	32,79	11,00	16,00	20,72
INDIOS	291	14,20	11,00	39,70	6,30	3,34	46,25	9,06	13,47	18,60
SANGRAD	304	15,77	14,00	44,83	6,70	2,00	46,76	10,96	15,00	21,00
C.QUEBR	132	19,72	24,00	107,80	10,38	0,00	42,00	11,16	21,00	27,25
ENACEL	121	9,15	13,00	27,59	5,25	0,24	22,00	4,97	8,79	13,00

Fonte: própria

Em geral as eólicas produzem em média 15MW por dia, mas com uma variabilidade muito grande, como pode ser visto no máximo e mínimo, destacando-se neste quesito o parque eólico de Canoa Quebrada. Podemos considerar a grande quantidade de zero no mínimo como problemas no aerogerador. Através do máximo é possível ver o potencial de cada parque eólico registrado desde sua existência.

Tabela 6.2. Teste de normalidade e estatísticas para o cálculo

	Assimetria	Curtose	JB	P-valor	É normal?(5%)
EOL R.DO FOGO	0.03	2.31	6.31	0.04	Não é normal
EOL D.INDIOS	0.69	4.31	43.64	0.00	Não é normal
EOL SANGRADOU	0.48	3.51	14.82	0.00	Não é normal
EOL C.QUEBR	-0.05	2.12	4.28	0.12	É normal
EOL ENACEL	0.43	2.30	6.17	0.05	Não é normal

Fonte: Elaboração própria da saída do software

Na tabela 6.2 é possível verificar que dos cinco parques eólicos apenas EOL Canoa Quebrada é normal. Assim as gerações eólica sem distribuição normal foram transformadas através da metodologia BoxCox que está detalhada no anexo

9.2, principalmente por ter fornecido melhores resultados que quando utilizando os dados originais sem a transformação.

Pelo teste da raiz unitária será verificado se a série não varia em relação ao tempo, no caso pode-se afirmar que todas as eólicas estudadas possuem uma raiz unitária quando o modelo é sem constante o que implica em não-estacionariedade. Foi utilizado para tal o Teste de Dickey-Fuller Aumentado, nos casos modelo sem constante, modelo com constante e com constante e tendência.

Tabela 6.3. Análise sob a estacionariedade da série

		É estacionário?			É estacionário?
EOL RIO DO FOGO	sem constant	NÃO	EOL CANOA QUEBRADA	NÃO	
	com constant	SIM		SIM, ACIMA DE 5%	
	c/const e tendencia	SIM, ACIMA DE 1%		SIM	
EOL INDÍOS	sem constant	NÃO	EOL ENACEL	NÃO	
	com constant	SIM		NÃO	
	c/const e tendencia	SIM		NÃO	
EOL SANGRADOURO	sem constant	NÃO			
	com constant	SIM			
	c/const e tendencia	SIM			

Fonte: Elaboração própria da saída do teste da raiz unitária

Observando a tabela 6.4 podemos dizer que as três primeiras eólicas possuem alta irregularidade, ou melhor, aleatoriedade. Já Canoa quebrada e Enacel são sazonais.

Tabela 6.4. Análise dos componentes não observáveis

	Tendencia	Sazonalidade	Irregularidade
EOL R.DO FOGO	2,94%	38,13%	58,93%
EOL D.INDIOS	1,47%	22,46%	76,07%
EOL SANGRADOURO	1,44%	22,55%	76,01%
EOL C.QUEBRADA	13,88%	50,16%	35,96%
EOL ENACEL	34,12%	42,53%	23,35%

Fonte: Elaboração própria da saída do software FPW

6.2

Resultados dos Modelos De Previsão Da Geração Eólica

Para se comparar os valores históricos reais com os valores históricos ajustados, é calculado o nível de erro de previsão gerado pelo modelo ao se projetar os dados históricos. Deste modo, com este erro, é possível calcular várias métricas para medir o desempenho do modelo. Assim o melhor modelo será o que obtiver valores menores nas estatísticas MAE, MAPE, SMAPE, RMSE e Rvar, já detalhados anteriormente.

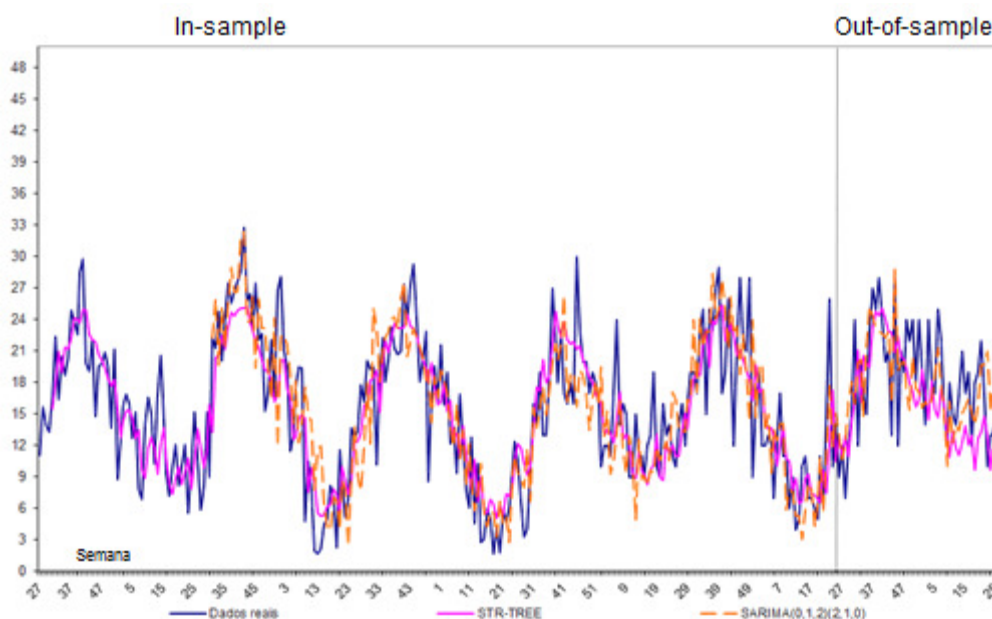
- **EOL Rio do Fogo**

Tabela 6.5. Análise comparativa dentro da amostra da EOL Rio do Fogo

	STR-TREE	STAR-TREE	ARIMA(0,1,1)	SARIMA(0,1,2) (2,1,0) [52]
MAE	2,18	2,20	2,45	2,57
MAPE (%)	36,46	37,30	37,53	47,95
SMAPE (%)	25,57	25,73	27,28	27,55
RMSE	2,70	2,74	3,06	3,37
Rvar	0,33	0,34	0,42	0,47

Fonte: Elaboração própria da saída do software

Na EOL FOGO dentro da amostra os resultados das métricas estatísticas ficaram melhores no modelo STR-TREE com os nós finais modelando uma constante e tendo com variável de transição as variáveis, semana e y_{t-1} . Entretanto os parâmetros lineares do STR-TREE não são significativos individualmente e alguns parâmetros não lineares também. Observando o gráfico real versus o predito é possível visualizar o desempenho da previsão in e out-sample dos modelos.



Fonte: Elaboração própria da saída do software


Gráfico 6.1. Gráfico dos dados reais da geração da EOL FOGO versus a previsão de cada modelo

Tabela 6.6. Análise comparativa fora da amostra da EOL Rio do Fogo

	STR-TREE	STAR-TREE	ARIMA(0,1,1)	SARIMA(0,1,2) (2,1,0) [52]
MAE	2,86	2,82	2,72	2.16
MAPE (%)	26,39	26,99	25,58	20.55
SMAPE (%)	27,69	27,14	25,55	20,29
RMSE	3,53	3,51	3,42	2.68
Rvar	0,74	0,77	0,76	0.46

Fonte: Elaboração própria da saída do software

Entretanto o melhor modelo fora da amostra foi um modelo linear SARIMA(0,1,2)(2,1,0)[52], pois obteve melhores resultados em todas as estatísticas utilizadas para comparação. No gráfico abaixo podemos verificar como a linha pontilhada acompanha os dados reais.



Fonte: Elaboração própria da saída do software

Gráfico 6.2. Gráfico dos dados previstos da geração da EOL FOGO

Os resíduos padronizados de ambos os modelos estão distribuídos em torno de zero, mas com alguns valores extremos. A modelagem do SARIMA viola a hipótese de normalidade dos resíduos na amostra in-sample. Entretanto para previsão fora da amostra apresentou-se como melhor modelo.

Tabela 6.7. Análise descritiva dos resíduos padronizados EOL Rio do Fogo dentro e fora da amostra dos modelos escolhidos nas estatísticas de comparação

	Resíduos In-sample		Resíduos Out-of-sample	
	STR-TREE	SARIMA(0,1,2) (2,1,0)[52]	STR-TREE	SARIMA(0,1,2) (2,1,0)[52]
N	246	246	62	62
Média	0,00	-0,08	1,04	0,24
Variância	7,34	9,01	11,60	7,22
Desvio - padrão	2,71	3,00	3,41	2,69
Mínimo	-7,05	-10,01	-6,87	-7,35
Máximo	6,28	9,64	8,98	5,38
1º quartil	-1,89	-1,35	-0,94	-1,44
2º quartil	0,25	0,00	1,07	0,28
3º quartil	1,84	1,32	3,16	2,08
Assimetria	-0,13	-0,13	-0,20	-0,27
Curtose	2,70	4,45	2,64	2,91
JB	1,62	22,27	0,74	0,78

Fonte: Elaboração própria da saída do software

- **EOL dos Índios**

Tabela 6.8. Análise comparativa dentro da amostra da EOL Índios

	STR-TREE	STAR-TREE	AR(2)	SARIMA(0,1,1) (0,1,1) [52]
MAE	1,06	1,06	1,13	1,03
MAPE (%)	26,80	26,72	28,74	25,50
SMAPE (%)	33,44	33,44	36,48	33,53
RMSE	1,34	1,33	1,41	1,35
Rvar	0,84	0,84	0,94	0,81

Fonte: Elaboração própria da saída do software

A EOL ÍNDIOS apresenta uma irregularidade muito grande e o modelo linear foi o que contemplou a sazonalidade visível no gráfico, assim o modelo SARIMA(0,1,1)(0,1,1)[52] obteve os menores valores nas métricas estatísticas de comparação dentro e fora da amostra.


Tabela 6.9. Análise comparativa fora da amostra da EOL Índios

	STR-TREE	STAR-TREE	AR(2)	SARIMA(0,1,1) (0,1,1) [52]
MAE	0,96	0,97	0,99	1,06
MAPE (%)	23,19	23,53	24,17	24,76
SMAPE (%)	30,90	31,42	35,15	34,42
RMSE	1,15	1,16	1,20	1,27
Rvar	0,75	0,77	0,81	0,90

Fonte: Elaboração própria da saída do software

No gráfico abaixo é possível visualizar a linha pontilhada que representa o

modelo SARIMA acompanhando as irregularidades dos dados originais da série:



Fonte: Elaboração própria da saída do software

Gráfico 6.3. Gráfico dos dados reais da geração da EOL ÍNDIOS versus a previsão de cada modelo

Observando os resíduos do SARIMA dentro da amostra eles não são normais, entretanto para previsão fora da amostra os resíduos são normais e em ambos os casos os resíduos se comportam de forma aleatória em torno de zero.

Tabela 6.10. Análise descritiva dos resíduos padronizados EOL Índios dentro e fora da amostra dos modelos escolhidos nas estatísticas de comparação

SARIMA(0,1,1)(0,1,1) [52]	Resíduos In-sample	Resíduos Out-of-sample
N	230	57
Média	-0,02	0,14
Variância	1,41	1,63
Desvio - padrão	1,19	1,28
Mínimo	-2,83	-2,33
Máximo	5,57	2,77
1º quartil	-0,72	-0,75
2º quartil	0,00	0,18
3º quartil	0,42	1,06
Assimetria	0,76	-0,07
Curtose	5,54	2,15
JB	83,90	1,77

Fonte: Elaboração própria da saída do software


- **EOL Sangradouro**

Tabela 6.11. Análise comparativa dentro da amostra da EOL Sangradouro

	STR-TREE	STAR-TREE	AR(2)	SARIMA(0,1,1)(0,1,1) [52]
MAE	1,52	1,51	1,62	1,49
MAPE (%)	31,00	30,83	33,33	30,48
SMAPE (%)	32,47	32,47	34,23	33,41
RMSE	1,89	1,89	2,00	1,92
Rvar	0,83	0,82	0,93	0,78

Fonte: Elaboração própria da saída do software

A EOL SANGRADOURO apresenta uma forte sazonalidade e o SARIMA(0,1,1)(0,1,1) [52] foi o que melhor conseguiu prever considerando esta sazonalidade de uma forma média e conseqüentemente obteve os menores valores em praticamente todas as métricas.



Fonte: Elaboração própria da saída do software

Gráfico 6.4. Gráfico dos dados reais da geração da EOL SANGRADOURO versus a previsão de cada modelo

A modelagem não linear do STR-TREE possui as medidas estatísticas menores que os modelos lineares, assim sendo o melhor modelo para fora da amostra. Possui os parâmetros lineares e não lineares significativos e utiliza como variável de transição a variável semana.

Tabela 6.12. Análise comparativa fora da amostra da EOL Sangradouro

	STR-TREE	STAR-TREE	AR(2)	SARIMA(0,1,1)(0,1,1) [52]
MAE	1,28	1,31	1,33	1,47
MAPE (%)	24,05	24,52	25,34	26,46
SMAPE (%)	28,75	29,42	29,72	33,29
RMSE	1,54	1,57	1,58	1,76
Rvar	0,74	0,77	0,77	0,96

Fonte: Elaboração própria da saída do software

O modelo linear escolhido para modelar dentro da amostra e o modelo não linear escolhido para modelar fora da amostra estão com os resíduos padronizados aleatoriamente em volta de zero. Entretanto os resíduos do SARIMA dentro da amostra não são normais. Assim o modelo STR-TREE tendo a variável de transição a semana, poderia ser o modelo para modelar a geração semanal deste parque eólico, devido suas características não serem distante do SARIMA na modelagem in-sample e seu comportamento na fora da amostra obteve melhores resultados.

Tabela 6.13. Análise descritiva dos resíduos padronizados EOL Sangradouro dentro e fora da amostra dos modelos escolhidos nas estatísticas de comparação

	Resíduos In-sample		Resíduos Out-of-sample	
	STR-TREE	SARIMA(0,1,1) (0,1,1) [52]	STR-TREE	SARIMA(0,1,1) (0,1,1) [52]
N	240	240	60,00	60
Média	0,00	-0,10	-0,08	0,18
Variância	3,60	2,88	2,41	3,12
Desvio - padrão	1,90	1,70	1,55	1,77
Mínimo	-4,75	-4,75	-2,84	-3,24
Máximo	6,13	6,00	3,15	4,30
1º quartil	-1,44	-1,01	-1,42	-1,04
2º quartil	0,12	0,00	0,17	0,27
3º quartil	1,25	0,74	0,89	1,45
Assimetria	0,11	0,47	0,01	0,01
Curtose	2,95	4,25	2,19	2,27
JB	0,48	24,25	1,63	1,34

Fonte: Elaboração própria da saída do software


- **EOL Canoa Quebrada**

Tabela 6.14. Análise comparativa dentro da amostra da EOL Canoa Quebrada

	STR-TREE	STAR-TREE	AR(0,2,2)	SARIMA(2,1,1)(0,1,0) [52]
MAE	4,35	4,45	4,91	6,27
MAPE (%)	37,54	40,52	35,95	65,03
SMAPE (%)	31,31	30,47	29,84	45,61
RMSE	5,45	5,51	6,19	8,37
Rvar	0,28	0,28	0,54	2,17

Fonte: Elaboração própria da saída do software

A EOL CANOA QUEBRADA possui uma amostra menor com 132 dados disponíveis e início em 2009. O modelo STR-TREE acompanhou os dados reais e foi o que obteve menores valores em todas as métricas, demonstrando assim ter um bom desempenho mesmo em pequenas amostras.



Fonte: Elaboração própria da saída do software

Gráfico 6.5. Gráfico dos dados reais da geração da EOL CANOA QUEBRADA versus a previsão de cada modelo

Na modelagem fora da amostra os modelos lineares obtiveram estatísticas de comparação menores que os modelos não lineares. Assim o melhor modelo para fora da amostra para EOL Canoa Quebrada é o modelo SARIMA(2,1,1)(0,1,0) [52] que modelou a sazonalidade as série.

Tabela 6.15. Análise comparativa fora da amostra da EOL Canoa Quebrada

	STR-TREE	STAR-TREE	AR(0,2,2)	SARIMA(2,1,1)(0,1,0) [52]
MAE	7,64	5,93	4,88	5,11
MAPE (%)	28,48	22,21	20,59	19,22
SMAPE (%)	33,65	25,77	19,83	20,18
RMSE	8,79	7,47	5,71	6,55
Rvar	0,88	0,99	0,29	0,47

Fonte: Elaboração própria da saída do software

Tabela 6.16. Análise descritiva dos resíduos padronizados EOL Canoa Quebrada dentro e fora da amostra dos modelos escolhidos nas estatísticas de comparação

	Resíduos In-sample		Resíduos Out-of-sample	
	STR-TREE	SARIMA(2,1,1)(0,1,0) [52]	STR-TREE	SARIMA(2,1,1)(0,1,0) [52]
N	102	102	26,00	26
Média	0,00	0,20	7,18	0,97
Variância	30,22	34,63	26,63	43,68
Desvio - padrão	5,50	5,88	5,16	6,61
Mínimo	-15,83	-18,94	-4,16	-11,15
Máximo	13,86	21,15	21,69	18,13
1º quartil	-3,48	-0,01	4,12	-2,63
2º quartil	-0,60	0,00	6,13	-0,73
3º quartil	3,77	0,95	9,82	4,32
Assimetria	-0,01	-0,26	0,40	0,44
Curtose	3,04	6,96	4,01	3,02
JB	0,01	67,71	1,81	0,84

Fonte: Elaboração própria da saída do software

- **EOL Enacel**

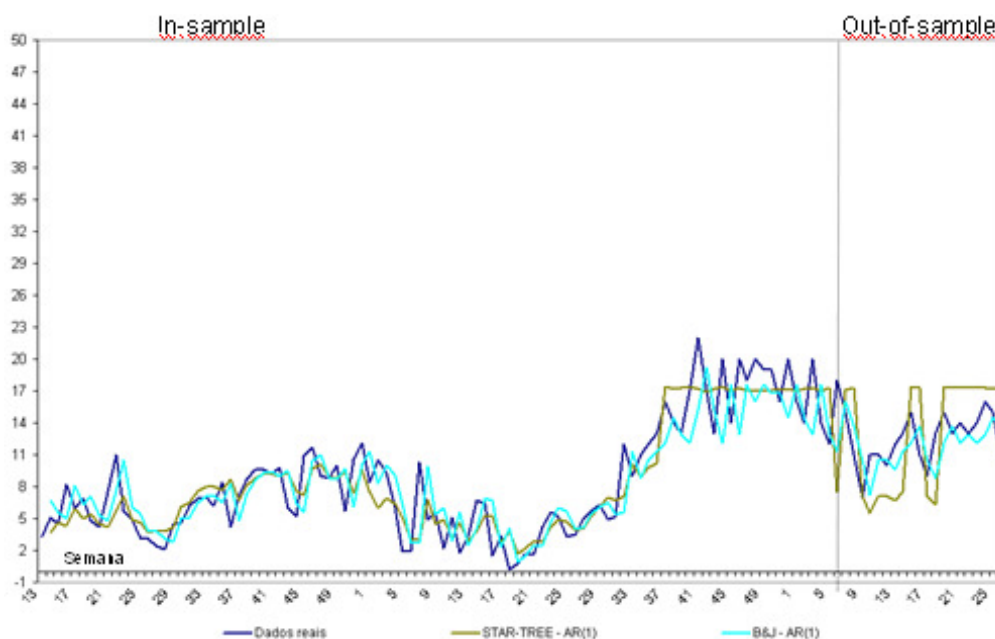
Tabela 6.17. Análise comparativa dentro da amostra da EOL Enacel

	STR-TREE	STAR-TREE	AR(1)	SARIMA(0,1,1)(0,1,0) [52]
MAE	0,83	0,77	0,90	1,06
MAPE (%)	49,87	41,37	35,96	41,23
SMAPE (%)	30,14	29,80	29,29	34,25
RMSE	1,06	0,99	1,17	1,42
Rvar	0,27	0,23	0,86	2,24

Fonte: Elaboração própria da saída do software

A EOL ENACEL é a menor amostra deste trabalho com 121 dados disponíveis e início em 2010. Apesar dos poucos dados é visível uma sazonalidade no final do período assim como EOL Canoa quebrada, isso porque

elas se situam na mesma cidade de Aracati no estado do Ceará. O modelo STAR-TREE obteve os menores valores nas métricas estatísticas de comparação.



Fonte: Elaboração própria da saída do software


Gráfico 6.6. Gráfico dos dados real da geração da EOL ENACEL versus a previsão de cada modelo

O modelo AR(1) obteve melhores resultados out-of-sample, como pode ser visto mais detalhadamente no gráfico 6.7.

Tabela 6.18. Análise comparativa fora da amostra da EOL Enacel

	STR-TREE	STAR-TREE	AR(1)	SARIMA(0,1,1) (0,1,0)[52]
MAE	1,02	1,34	0,73	1,13
MAPE (%)	18,83	24,42	13,67	20,53
SMAPE (%)	26,82	34,09	18,78	28,82
RMSE	1,24	1,54	0,88	1,39
Rvar	2,40	3,87	0,23	0,40

Fonte: Elaboração própria da saída do software



Fonte: Elaboração própria da saída do software

Gráfico 6.7. Gráfico dos dados previstos da geração da EOL ENACEL

Tabela 6.19. Análise descritiva dos resíduos padronizados EOL Enacel dentro e fora da amostra dos modelos escolhidos nas estatísticas de comparação

	Resíduos In-sample		Resíduos Out-of-sample	
	STAR-TREE	AR(1)	STAR-TREE	AR(1)
N	94	94.00	23	23.00
Média	0.00	0.02	-0.02	0.18
Variância	0.99	1.38	2.47	0.77
Desvio - padrão	0.99	1.18	1.57	0.88
Mínimo	-2.97	-3.12	-1.90	-1.30
Máximo	3.20	3.39	3.39	2.01
1º quartil	-0.73	-0.66	-1.11	-0.41
2º quartil	0.02	0.01	-0.63	0.16
3º quartil	0.70	0.71	1.27	0.85
Assimetria	-0.01	-0.06	0.60	0.16
Curtose	3.69	3.36	2.00	2.02
JB	1.86	0.56	2.36	1.01

Fonte: Elaboração própria da saída do software

7 Conclusão

Neste trabalho foi aplicado o modelo denominado STAR-TREE aplicado a série de geração de energia eólica fornecida pelo ONS, com periodicidade semanal. A ideia principal do modelo é a substituição da função indicadora utilizada pela metodologia CART, pela função logística para que a mudança entre os regimes seja mais suave. O modelo resultante pode ser analisado como uma regressão com transição suave entre os múltiplos regimes. Além disso, os resultados do modelo não linear STAR-TREE foram comparados através de métricas estatísticas com o modelo linear Box & Jenkins.

Detalhou-se a construção do modelo, que é realizada através de testes de não linearidade, estimando os parâmetros por mínimos quadrados não lineares e ajustando, nos nós terminais, modelos autorregressivos. Além, de utilizar o teste do tipo Multiplicadores de Lagrange (ML) para não quebrar nenhuma propriedades assintóticas dos estimadores.

Os resultados demonstram que o modelo não linear STAR-TREE apesar de obter um bom desempenho, não obteve um desempenho superior ao se comparar com o modelo linear do SARIMA.

Para aprimorar os estudos sugere-se como trabalho futuro, utilizar os dados de velocidade e direção dos ventos como variável explicativa de entrada do modelo de transição. Testar a estimação dos parâmetros por aprendizado da informação teórica (ITL) introduzido por Bessa [43]. Utilizar outros modelos para previsão de geração de energia eólica semanal. Estudar as outras séries de geração dos parques eólicos brasileiros que não foram utilizados neste trabalho, a fim de se diminuir as incertezas e ampliar a confiabilidade da previsão da geração eólica, no Brasil.

- [1] SALLES, A.C.N. de, Metodologias De Análise De Risco Para Avaliação Financeira De Projetos De Geração Eólica. Dissertação (Mestrado em planejamento energético), Universidade Federal do Rio de Janeiro, Rio de Janeiro - RJ, 2004.
- [2] RÜNCOS, F., CARLSON, R., KUO-PENG, P., VOLTOLINI, H., BATISTELA, N.J., Geração de Energia Eólica–Tecnologias Atuais e Futuras. GRUCAD-EEL-CTC-UFSC, WEG MÁQUINAS 2000.
- [3] DALMAZ, A., PASSOS, J.C., COLLE, S., Energia eólica para geração de eletricidade e a importância da previsão. Revista ABCM–Engenharia, Florianópolis 2008, 13.
- [4] SILVA, P. de C. da, Sistema Para Tratamento, Armazenamento e Disseminação De Dados De Vento. Dissertação (Mestrado em Engenharia Mecânica), Universidade Federal do Rio de Janeiro, Rio de Janeiro - RJ, 1999.
- [5] RICOSTI, J.F.C., Inserção Da Energia Eólica No Sistema Hidrotérmico Brasileiro. Dissertação (Mestrado em Energia), Universidade de São Paulo, São Paulo - SP. 2011.
- [6] EERE - Energy Efficiency & Renewable Energy, Wind Program: How Wind Turbines Work. Disponível em: < http://www1.eere.energy.gov/wind/wind_how.html >. Acesso em: Maio de 2012.
- [7] BURATTINI, M.P.T.C., Energia uma abordagem multidisciplinar. 1 ed., São Paulo: Editora Livraria da física, 2008.
- [8] WWEA - World Wind Energy Association, World Market recovers and sets a new record: 42 GW of new capacity in 2011, total at 239 GW. Disponível em: < <http://www.wwindea.org/home> >. Acesso em: Fevereiro de 2012.
- [9] GWEC - Global Wind Energy Council, Global Wind Report - Annual market update 2011. 2 ed. Disponível em: < <http://www.gwec.net/publications/global-wind-report-2> > Acesso em: Julho de 2012.
- [10] DUTRA, R., Viabilidade Técnico-Econômica Da Energia Eólica Face Ao Novo Marco Regulatório Do Setor Elétrico Brasileiro. Dissertação (Mestrado Em Planejamento Energético). Universidade Federal do Rio de Janeiro, Rio de Janeiro - RJ, 2001.
- [11] BESSA, R.J., SUMAILI, J., MIRANDA, V., BOTTERUD, A., et al., Time-adaptive kernel density forecast: A new method for wind power uncertainty modeling. Proc. 17th Power System Computation Conf 2010.
- [12] WANG, J., BOTTERUD, A., BESSA, R., KEKO, H., et al., Wind power forecasting uncertainty and unit commitment. Applied Energy 2011.
- [13] MONTEIRO, C., ZACHOS, J.C., BESSA, R., MIRANDA, V., et al., A quick guide to wind power forecasting: state-of-the-art 2009. Project report for Argonne National Laboratory - Decision and Information Sciences

- Division. Illinois, U.S. 2006, 1–37.
- [14] DANTAS, T.M., Modelo Tempo-Frequência Para Previsão De Curto Prazo De Velocidade De Vento. Dissertação (Mestrado em Engenharia Elétrica), Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro - RJ, 2011.
- [15] JÚNIOR, L.A.T., PESSANHA, J.F.M., SOUZA, R.C., MENEZES, M.L., CASSIANO, K.M., Análise Wavelet E Redes Neurais Artificiais Na Previsão Da Velocidade De Vento. Em: International workshop on Energy Efficiency for a More Sustainable World EEMSW, Açores - São Miguel. Book of Abstracts 2012, 19–19.
- [16] RODRIGUES, G.C., Utilização De Redes Neurais Para Previsão De Ventos No Horizonte De 24 Horas. Dissertação (Mestrado em Engenharia Elétrica), Universidade Federal do Rio de Janeiro, Rio de Janeiro - RJ, 2007.
- [17] AMARAL, B.M., Modelos varx para geração de cenários de vento e vazão alicados À comercialização de energia. Dissertação (Mestrado em Engenharia Elétrica), Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro - RJ, 2011.
- [18] BARROS, M., Processos estocásticos. Rio de Janeiro-RJ: Papel Virtual Editora 2004.
- [19] BOX, G.E.P., JENKINS, G.M., Time series analysis: forecasting and control. Rev. Ed. Holden—Day 1976.
- [20] MORETTIN, P.A., TOLOI, C.M. de C., Modelos para previsão de séries temporais, Instituto de matematica pura e aplicada, 1981.
- [21] SOUZA, R.C., CAMARGO, M.E., Análise e previsão de séries temporais: os modelos ARIMA, vol. 242, 1996.
- [22] TONG, H., CHEN, C., in: In: Pattern recognition and signal processing. Proceedings of the NATO ASI Series E: Applied Sc. (29)., vol. 5, Sijthoff & Noordhoff, Holanda - Amesterdan 1978, pp. 575–586.
- [23] TONG, H., Threshold models in non-linear time series analysis. Springer Lecture notes in statistics, No. 21, Springer-Verlag (ed.), Berlin 1983.
- [24] TONG, H., LIM, K., Threshold autoregression, limit cycles, and data. Journal of the Royal Statistical Society: Series B 1980, 42, 245–292.
- [25] CHAN, K.S., TONG, H., On estimating thresholds in autoregressive models. Journal of time series analysis 1986, 7, 179–190.
- [26] GRANGER, C.W.J., TERÄSVIRTA, T., Modelling nonlinear economic relations hips, University Press, Oxford 1993.
- [27] BACON, D.W., WATTS, D.G., Estimating the transition between two intersecting straight lines. Biometrika 1971, 58, 525–534.
- [28] LUUKKONEN, R., SAIKKONEN, P., TERÄSVIRTA, T., Testing linearity against smooth transition autoregressive models. Biometrika 1988, 75, 491–499.
- [29] TERÄSVIRTA, T., Specification, estimation, and evaluation of smooth transition autoregressive models. Journal of the american Statistical association 1994, 208–218.
- [30] TONG, H., Non-linear time series: a dynamical system approach, Oxford University Press, 1990.
- [31] CLEMENTS, M.P., SMITH, J., The performance of alternative forecasting methods for SETAR models. International Journal of Forecasting 1997, 13, 463–475.
- [32] EPPRECHT, C.R., Modelos De Transição Suave Para Média e Volatilidade

- Realizada Aplicados à Previsão De Retornos e Negociação Automática. Dissertação (Mestrado em Engenharia Elétrica), Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro - RJ, 2008.
- [33] PINSON, P., CHRISTENSEN, L., MADSEN, H., SØRENSEN, P.E., et al., Fluctuations of offshore wind generation: Statistical modelling. European Wind Energy Conference and Exhibition 2007, 87–92.
- [34] TERÄSVIRTA, T., ANDERSON, H.M., Modelling nonlinearities in business cycles using smooth transition autoregressive models. *Journal of Applied Econometrics* 1992, S119–S136.
- [35] HAGGAN, V., OSAKI, T., Modelling nonlinear random vibrations using an amplitude-dependent autoregressive time series model. *Biometrika* 1981, 68, 189–196.
- [36] DIJK, D.V., FRANSES, P., Modelling multiple regimes in the business cycle. *Macroeconomic Dynamics* 1999, 3, 311–340.
- [37] ROSA, J., Modelos De Regressão Com Transição Suave Estruturados Por Árvores. Tese (Doutorado em Engenharia Elétrica), Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro - RJ, 2005.
- [38] BREIMAN, L., FRIEDMAN, J.H., OLSHEN, R.A., Classification and Regression Tree. Wadsworth 1984.
- [39] JENNRICH, R.I., Asymptotic properties of non-linear least squares estimators. *The Annals of Mathematical Statistics* 1969, 40, 633–643.
- [40] DAVIES, R.B., Hypothesis testing when a nuisance parameter is present only under the alternative. *Biometrika* 1977, 64, 247–254.
- [41] DAVIES, R.B., Hypothesis testing when a nuisance parameter is present only under the alternative. *Biometrika* 1987, 74, 33–43.
- [42] ONS - Operadora Nacional do Sistema, Submódulo 7.3 - Sistemática para classificação da modalidade de operação de usinas. Procedimento de rede 2009.
- [43] BESSA, R.J., MIRANDA, V., PRINCIPE, J.C., BOTTERUD, A., WANG, J., Information theoretic learning applied to wind power modeling. *Neural Networks (IJCNN), The 2010 International Joint Conference on* 2010, 1–8.
- [44] JARQUE, C.M., BERA, A.K., Efficient tests for normality, homoscedasticity and serial independence of regression residuals. *Economics Letters* 1980, 6, 255–259.
- [45] BOX, G.E.P., COX, D.R., An analysis of transformations. *Journal of the Royal Statistical Society: Series B* 1964, 26, 211–252.
- [46] OLIVEIRA, A.L.M., SOUZA, C.C., BOEHME, P., SAMOHYLI, R.W., A Normalização De Distribuições Não-Normais Através Da Transformação De Box-Cox E Alguns Comentários Sobre A Avaliação De Qualidade n.d.

9 Anexo

9.1

Teste De Normalidade Jarque-Bera

Teste de normalidade que se baseia na diferença entre os coeficientes de assimetria e curtose. Proposto inicialmente por Jarque & Bera (1980) [44] é um teste paramétrico e assintótico, com a hipótese nula se a distribuição de probabilidade da variável em estudo segue uma distribuição normal e a hipótese alternativa que não segue uma normal:

$$JB = n \left[\frac{(\text{assimetria})^2}{6} + \frac{(\text{curtose} - 3)^2}{24} \right] \quad (45)$$

$$\text{assimetria} = \frac{\frac{\sum_{i=1}^n (x_i - \bar{x})^3}{n}}{s^3} \quad (46)$$

$$\text{curtose} = \frac{\frac{\sum_{i=1}^n (x_i - \bar{x})^4}{n}}{s^4} \quad (47)$$

Sendo:

$$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1} \quad s = \sqrt{s^2}$$

9.2

Boxcox

Tipo de transformação para tornar dados que não possuem distribuição normal em normais ou aproximadamente normais, introduzida em 1964 por BOX & COX [45]. Baseia-se em encontrar a transformação λ variando de (-1,1) para minimizar as medidas de assimetria e curtose. Aplicando a transformação da seguinte maneira:

$$y = \frac{x^\lambda - 1}{\lambda} \quad (48)$$

Sendo:

y = série de dados transformados

x = série de dados originais

Segue alguns valores transformados para determinados valores de λ :

se λ for igual a:	então $\frac{y^\lambda - 1}{\lambda}$ será igual a:
-1,0	$\frac{1}{y} + 1$
-0,5	$\frac{\frac{1}{\sqrt{y}} - 1}{-0,5}$
0,0	$\ln y$ (da regra de L'Hospital)
0,5	$\frac{\sqrt{y} - 1}{0,5}$
1,0	$y - 1$

Fonte: [46]

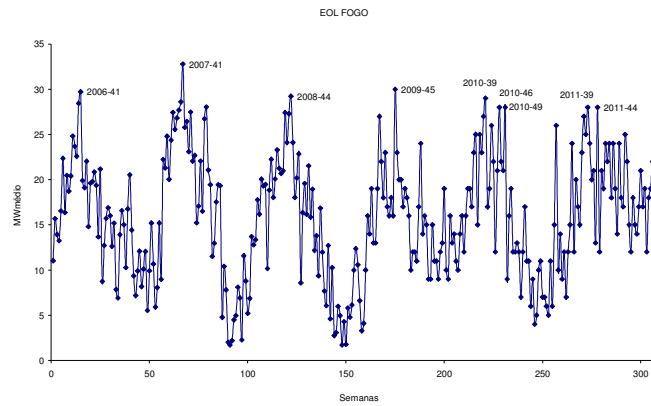
9.3

Anexo Análise Exploratória


9.3.1

Rio Do Fogo


- Comportamento da série inicial:




- Histograma da série inicial:



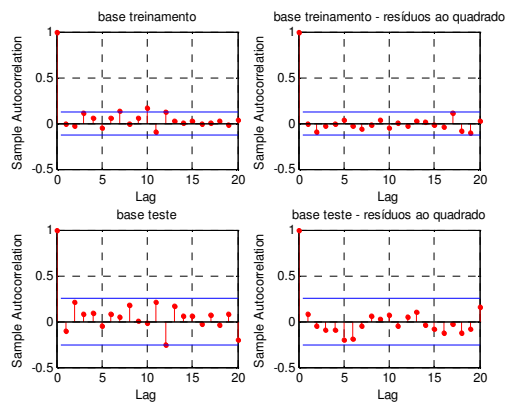
- Decomposição da série inicial:



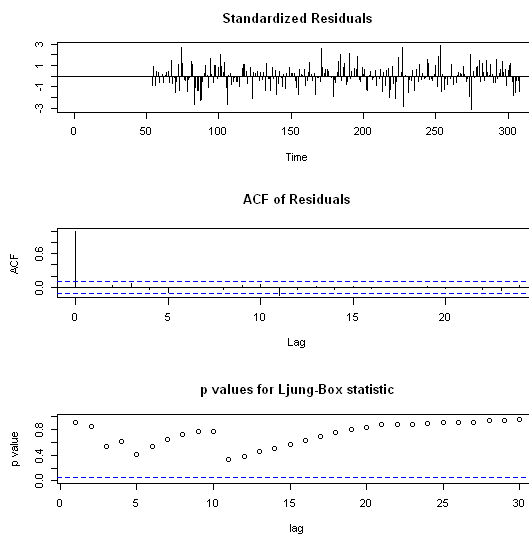
- Gráfico para verificação da sazonalidade:



- Função de autocorrelação dos resíduos padronizados e resíduos padronizados ao quadrado STR-TREE:

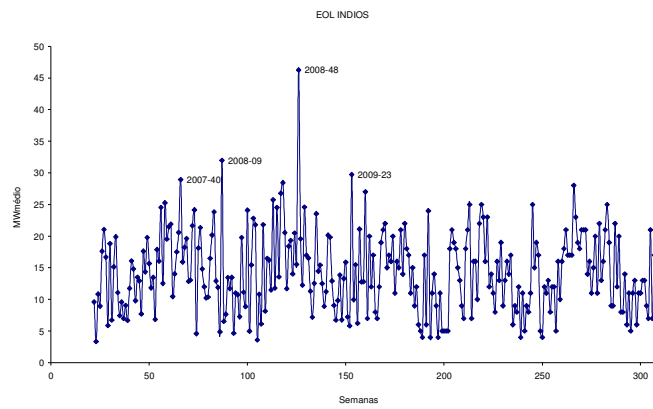


- Função de autocorrelação dos resíduos padronizados SARIMA(0,1,2)(2,1,0)[52] do BOX & JENKINS:




9.3.2 Índios


- Comportamento da série inicial:



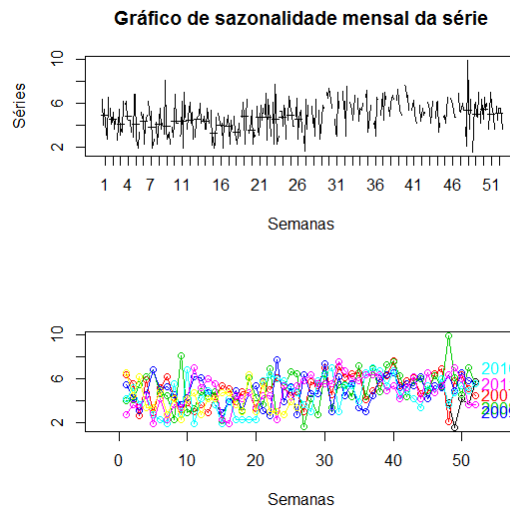
- Histograma da série inicial:



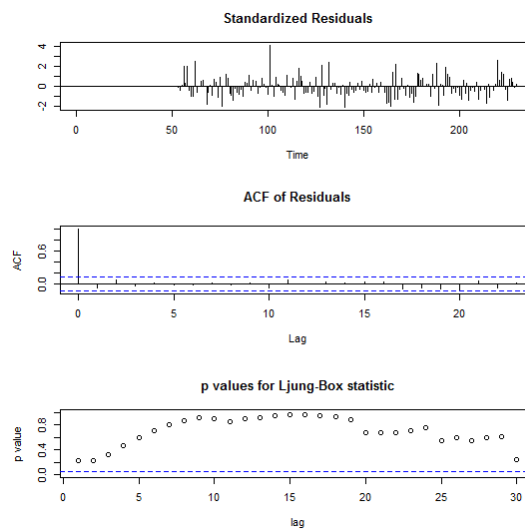
- Decomposição da série inicial:



- Gráfico para verificação da sazonalidade:



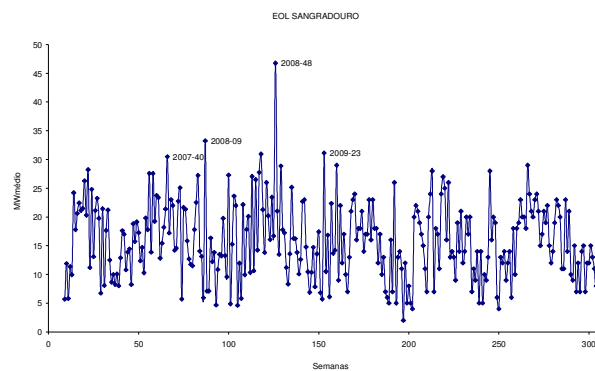
- Função de autocorrelação dos resíduos padronizados e resíduos padronizados ao quadrado SARIMA(0,1,1)(0,1,1)[52]:




9.3.3

Sangradouro

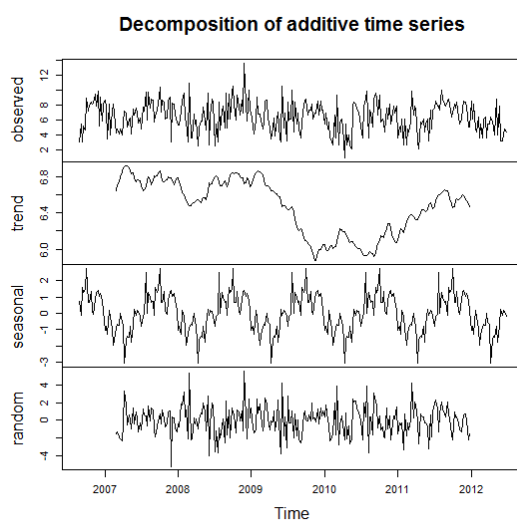
- Comportamento da série inicial:




- Histograma da série inicial:



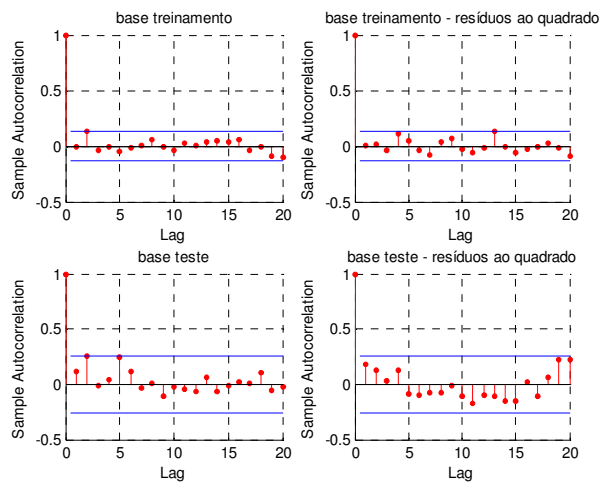
- Decomposição da série inicial:



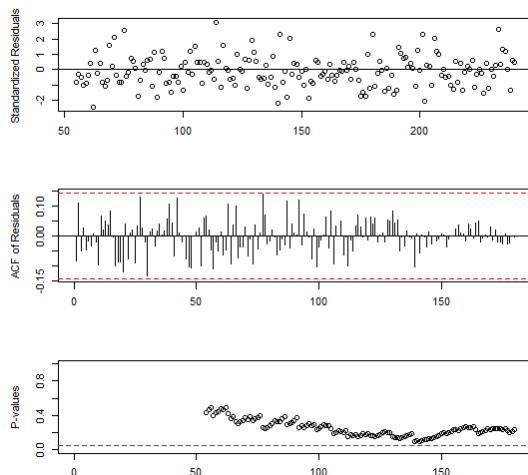
- Gráfico para verificação da sazonalidade:



- Função de autocorrelação dos resíduos padronizados e resíduos padronizados ao quadrado STR-TREE:




- Função de autocorrelação dos resíduos padronizados e resíduos padronizados ao quadrado SARIMA(0,1,1)(0,1,1)[52]:




9.3.4 Canoa Quebrada


- Comportamento da série inicial:




- Histograma da série inicial:



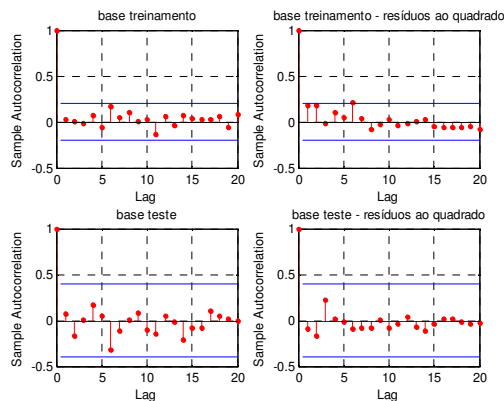
- Decomposição da série inicial:




- Gráfico para verificação da sazonalidade:



- Função de autocorrelação dos resíduos padronizados e resíduos padronizados ao quadrado STR-TREE:

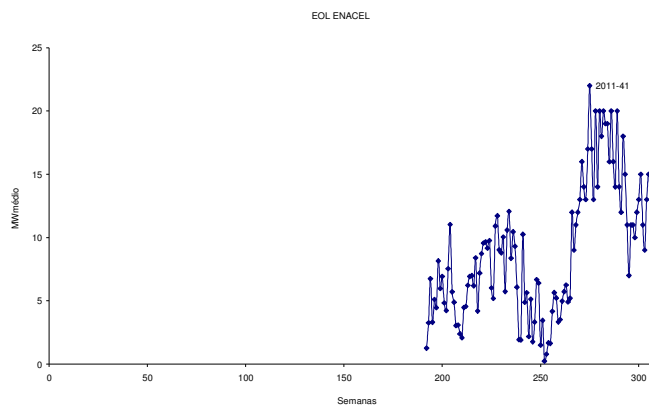


- Função de autocorrelação dos resíduos padronizados e resíduos padronizados ao quadrado SARIMA(2,1,1)(0,1,0)[52]:




9.3.5 Enacel


- Comportamento da série inicial:




- Histograma da série inicial:




- Decomposição da série inicial:




- Gráfico para verificação da sazonalidade:



- Função de autocorrelação dos resíduos padronizados e resíduos padronizados ao quadrado STAR-TREE – AR(1):



- Função de autocorrelação dos resíduos padronizados B&J – AR(1):



- Correlação entre os resíduos dos modelos

	EOL FOGO STR-TREE	EOL FOGO SARIMA	EOL ÍNDIOS SARIMA
EOL FOGO STR-TREE	1,00	0,70	-0,05
EOL FOGO SARIMA	0,70	1,00	0,03
EOL ÍNDIOS SARIMA	-0,05	0,03	1,00
EOL SANGRADOURO STR-TREE	0,01	0,02	0,85
EOL SANGRADOURO SARIMA	0,01	0,06	0,95
EOL CANOA QUEBRADA STR-TREE	0,55	0,22	0,00
EOL CANOA QUEBRADA SARIMA	0,32	0,27	0,09
EOL ENACEL STAR-TREE	-0,13	-0,11	0,05
EOL ENACEL AR(1)	0,28	0,25	0,15

	EOL SANGRADO URO STR- TREE	EOL SANGRADO URO SARIMA	EOL CANOA QUEBRADA STR-TREE
EOL FOGO STR-TREE	0,01	0,01	0,55
EOL FOGO SARIMA	0,02	0,06	0,22
EOL ÍNDIOS SARIMA	0,85	0,95	0,00
EOL SANGRADOURO STR-TREE	1,00	0,89	0,10
EOL SANGRADOURO SARIMA	0,89	1,00	0,03
EOL CANOA QUEBRADA STR-TREE	0,10	0,03	1,00
EOL CANOA QUEBRADA SARIMA	0,14	0,19	0,29
EOL ENACEL STAR-TREE	0,08	0,10	0,04
EOL ENACEL AR(1)	0,21	0,20	0,45

	EOL CANOA QUEBRADA SARIMA	EOL ENACEL STAR-TREE	EOL ENACEL AR(1)
EOL FOGO STR-TREE	0,32	-0,13	0,28
EOL FOGO SARIMA	0,27	-0,11	0,25
EOL ÍNDIOS SARIMA	0,09	0,05	0,15
EOL SANGRADOURO STR-TREE	0,14	0,08	0,21
EOL SANGRADOURO SARIMA	0,19	0,10	0,20
EOL CANOA QUEBRADA STR-TREE	0,29	0,04	0,45
EOL CANOA QUEBRADA SARIMA	1,00	0,14	0,47
EOL ENACEL STAR-TREE	0,14	1,00	0,15
EOL ENACEL AR(1)	0,47	0,15	1,00