

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO
INSTITUTO DE ECONOMIA
MONOGRAFIA DE BACHARELADO

**MUDANÇAS DE REGIME NO PROCESSO DE
GERAÇÃO DE VENTOS NO BRASIL**

LUCAS MEDEIROS REIS
matrícula nº: 107326521

ORIENTADOR(A): Prof. Getúlio Borges da Silveira

ABRIL 2011

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO
INSTITUTO DE ECONOMIA
MONOGRAFIA DE BACHARELADO

**MUDANÇAS DE REGIME NO PROCESSO DE
GERAÇÃO DE VENTOS NO BRASIL**

LUCAS MEDEIROS REIS
matrícula nº: 107326521

ORIENTADOR(A): Prof. Getúlio Borges da Silveira

ABRIL 2011

As opiniões expressas neste trabalho são de exclusiva responsabilidade do autor.

Dedico este trabalho aos meus companheiros de jornada Adam Baqui, André Corsetti e Danilo Falconi, porque essa vitória também pertence a eles.

RESUMO

O trabalho focaliza num importante aspecto da produção de energia eólica no Brasil: o processo de formação de ventos.

O objetivo principal é verificar mudanças de regimes nesse processo. O modelo utilizado foi o modelo de Espaço de Estados com Chaveamento de Markov.

Um segundo objetivo é verificar em caráter exploratório a relação destas mudanças com a presença dos fenômenos El Niño e La Niña.

Conclui-se ao final que não há evidências o bastante para a aceitação deste modelo.

Índice

Introdução	7
Capítulo 1 – Energia Eólica no Brasil e no Mundo	9
Capítulo 2 – Análise Exploratória	12
Capítulo 3 – Modelagem	17
Capítulo 4 – Um Modelo Com Chaveamento De Markov	21
Capítulo 5 – Estimação.....	30
Conclusão	37
Bibliografia.....	38
Anexo	39

Introdução

Este trabalho visa investigar o processo de formação de ventos no Brasil, e verificar a presença ou não de mudanças de regimes neste processo. Num primeiro momento vai se averiguar a adequabilidade de um modelo do tipo *Periódico Auto-Regressivo* aos dados. Num segundo momento irá se conferir se há ou não mudanças de regimes na série estudada, através da teoria do *Chaveamento de Markov*. Ainda irá se verificar se tais mudanças seriam ou não causadas pelos fenômenos El Niño e La Niña.

Os dados utilizados foram compilados pela consultoria Camargo & Schubert, e compreendem o período de janeiro de 1976 a dezembro de 2008. São relativos ao estado do Ceará, da Bahia, do Rio Grande do Norte e do Rio Grande do Sul.

O modelo Periódico Auto-Regressivo se adequou bem aos dados, mas o modelo com chaveamento de Markov não. As evidências não foram a favor de um processo desse tipo.

Isso significa que o investimento em energia eólica no Brasil é menos incerto do que o esperado, já que as evidências apontam para um processo de formação de ventos sem mudança de regimes.

O **capítulo 1** mostra a importância deste assunto. Os ventos são hoje uma fonte de energia alternativa viável para a produção de energia elétrica. No Brasil, inclusive, a possibilidade de uma complementaridade com a produção de energia hidrelétrica torna o estudo da energia eólica mais pertinente ainda.

O **capítulo 2** consiste de uma análise exploratória dos dados da Camargo & Schubert. Também vai se investigar se uma modelagem do tipo AR, ARMA ou ARIMA se aplica aos dados, e concluir que não.

O modelo Periódico Auto-Regressivo (PAR) é apresentado no **capítulo 3**. Este modelo, como será visto, se adequa bem melhor aos dados.

O modelo de Espaço de Estados com Chaveamento de Markov é apresentado no **capítulo 4**. Neste capítulo será introduzida rapidamente a teoria das Cadeias de Markov.

Além disso, será deduzida uma representação do modelo PAR como um modelo de Espaço de Estados.

O **capítulo 5** consiste da estimação do modelo com os dados da Camargo & Schubert. Conclui-se que os processos dos quatro estados não mudam de regime ao mesmo tempo, descartando também a hipótese dos fenômenos El Niño e La Niña influenciarem nesta mudança de regimes.

Capítulo 1 – Energia Eólica no Brasil e no Mundo

Nos últimos 12 anos os ventos têm sido a fonte primária de energia elétrica de maior ritmo de expansão no mundo, apresentando incremento exponencial da potência instalada. Entre 1990 e 2008, a potência instalada em aerogeradores cresceu à taxa média de 27% ao ano, alcançando 121.000 MW, dos quais mais de 54% instalados na Europa (Global Wind Energy Council, acessado em 03/12/2010). Enquanto apresenta forte expansão na Ásia, particularmente na Índia e China, e notável crescimento nos Estados Unidos onde, só no ano de 2008 foram instalados 8.400 MW, no Brasil a expansão eólica tem sido modesta. É apoiada em iniciativas governamentais como o Programa de Incentivo às Fontes Alternativas de Energia Elétrica – PROINFA (2002) e o Leilão de Energia de Reserva - LER, realizado em dezembro de 2009 (Ministério de Minas e Energia, acessado em 03/12/2010).

É necessário reconhecer que o impulso maior da geração eólica ocorre em países cuja geração de energia elétrica é predominantemente de base térmica. Nestes países a atratividade econômica da fonte eólica está associada a aspectos elétricos e energéticos de curto prazo e ambientais, vale dizer, à substituição de combustíveis fósseis e à redução das emissões de CO₂.

No Brasil, diferentemente, são diferentes os aspectos energéticos que definem a atratividade econômica das diversas fontes de geração da energia elétrica. Uma possível complementaridade com a produção hidrelétrica determina a confiabilidade do suprimento de energia elétrica em períodos de hidraulicidade desfavorável.

Pela composição do parque gerador nacional, onde a principal fonte energética – hidrelétrica - é dependente de fatores climáticos não determinísticos, a valoração econômico-energética das fontes de energia elétrica é função não apenas de seus custos intrínsecos, mas também da maior ou menor coincidência entres disponibilidades hídrica e de fontes alternativas.

De fato, tem-se atribuído aos parques eólicos, como benefício energético, apenas a sua geração individual média ao longo da vida útil, não sendo considerados os ganhos sinérgicos decorrentes da operação conjunta do parque eólico com o sistema

predominantemente hidrelétrico. Em outras palavras, tem-se adotado no Brasil o mesmo critério de valoração econômico-energética utilizado nos países de base térmica.

Estima-se que mais de 80% da energia elétrica utilizada no Brasil é proveniente de recursos hídricos (Brandão, Castro, Dantas, Martini & Timponi, 2009). Uma importante característica positiva da energia eólica no Brasil é a sua provável complementaridade com a produção hidrelétrica. Em resumo, o período de seca no país parece coincidir com o período no qual o regime de ventos é mais intenso. A figura 1.1 ilustra bem esta complementaridade:

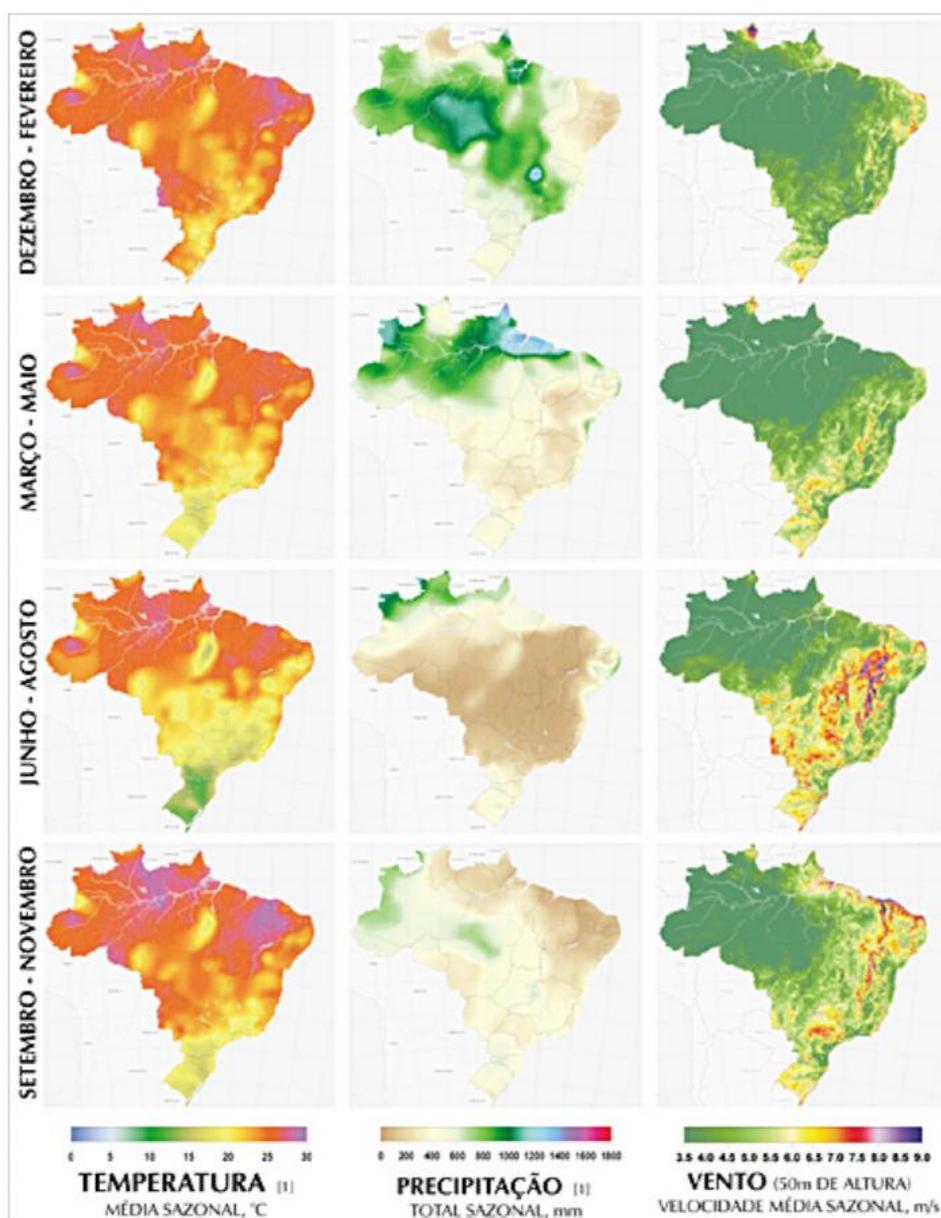


Figura 1.1: Complementaridade Hídrica-Eólica no Brasil Fonte: MME (2001)

Como se pode ver na figura, o período de Dezembro a Fevereiro corresponde ao pico de precipitação, localizada nas regiões norte, centro-oeste e sudeste. Neste mesmo período, os ventos apresentam baixa velocidade, exceto em pontos isolados.

O período de Junho a Agosto, diferentemente, corresponde ao pico da velocidade dos ventos, localizados no Sul, Sudeste, Nordeste e parte do Norte. Ao mesmo tempo, são observados os menores índices de precipitação.

As medições e registros de velocidade e direção dos ventos (a partir das quais se pode inferir a capacidade de geração eólica local) anteriores à década de 80 em geral eram destinadas ao suporte à aviação ou a estudos meteorológicos. Isso porque a geração eólica tem desenvolvimento recente, a partir dos anos oitenta, e apenas na década de 90 viabilizou-se técnica e economicamente como alternativa segura para o suprimento da demanda de energia elétrica.

A confessa limitação do conhecimento das características energéticas de longo prazo, evidenciada desde a época do PROINFA e, mais recentemente, nas discussões preparatórias para a formulação das regras do Leilão de Energia de Reserva – LER 2009, tem se revelado um obstáculo à valoração econômica adequada da geração eólica no Brasil.

Capítulo 2 – Análise Exploratória

O objetivo deste capítulo é apresentar dados referentes à série de fatores de capacidade de produção de energia eólica no Brasil. Além disso, irá se mostrar as primeiras evidências contra uma modelagem do tipo ARIMA para a série.

Em meados de 2009, a consultoria Camargo & Schubert, conceituada empresa nacional de consultoria sobre energia eólica, tomou a iniciativa de compor um histórico mensal de geração em quatro regiões do país. Os dados compreendem o período de janeiro de 1976 a dezembro de 2008. As grandezas foram baseadas em medições anemométricas próprias ou adquiridas em bancos de dados internacionais, inferências e correlações estatísticas. Ressalta-se que o histórico reconstituído retrata situações regionais médias e não locais específicos.

A série representa os *fatores de capacidade* da produção de energia eólica em cada região. Fatores de capacidade são um conceito muito usado nas engenharias. A maneira como será usado nesta monografia corresponde à proporção entre a produção efetiva de uma usina em um período de tempo e a capacidade total máxima neste mesmo período.

A série a ser estudada mostra a evolução dos fatores de capacidade dos estados do Ceará, Rio Grande do Norte, Bahia e Rio Grande do Sul, de Janeiro de 1976 até Dezembro de 2008.

Fatores de Capacidade

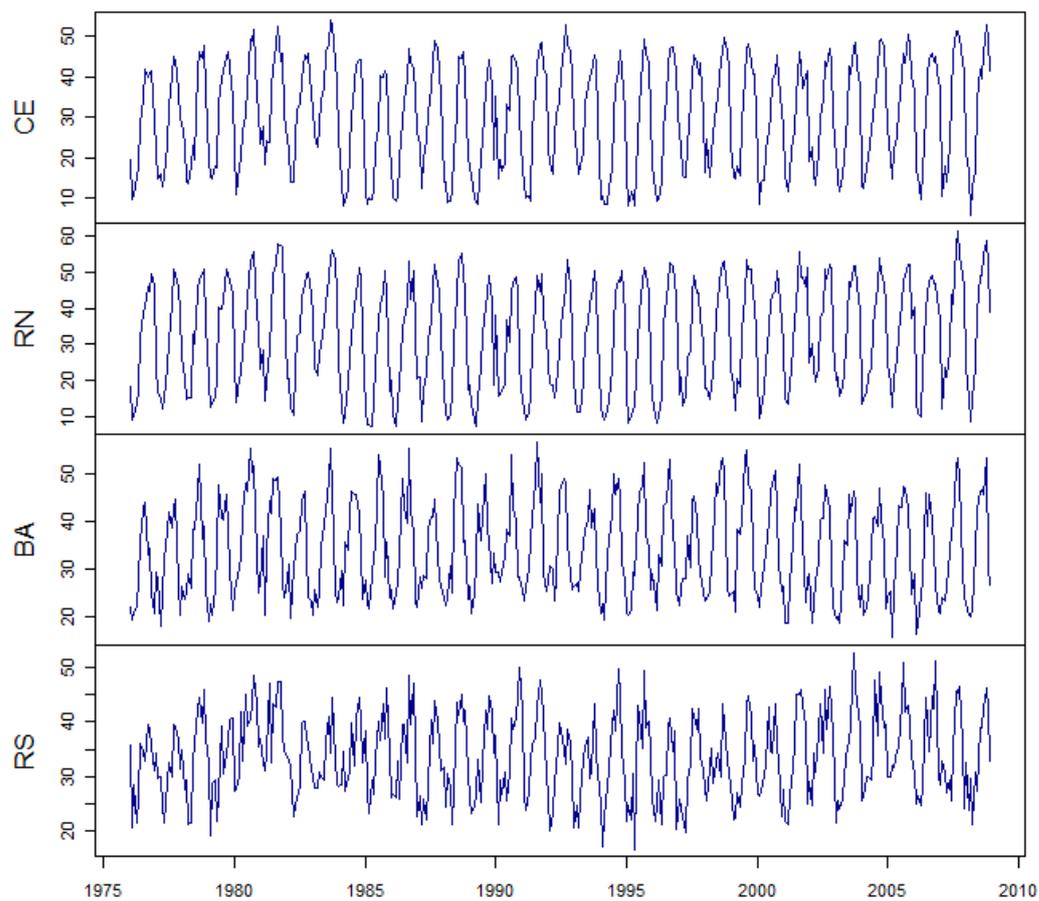


Gráfico 2.1: Evolução dos fatores de capacidade, médias mensais. Fonte: Camargo & Schubert

O gráfico 2.2 é do tipo *monthplot*:

Estado do Ceará

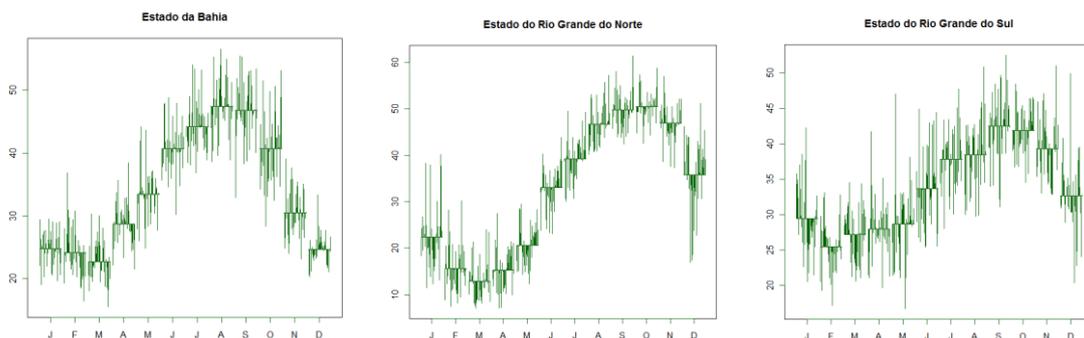
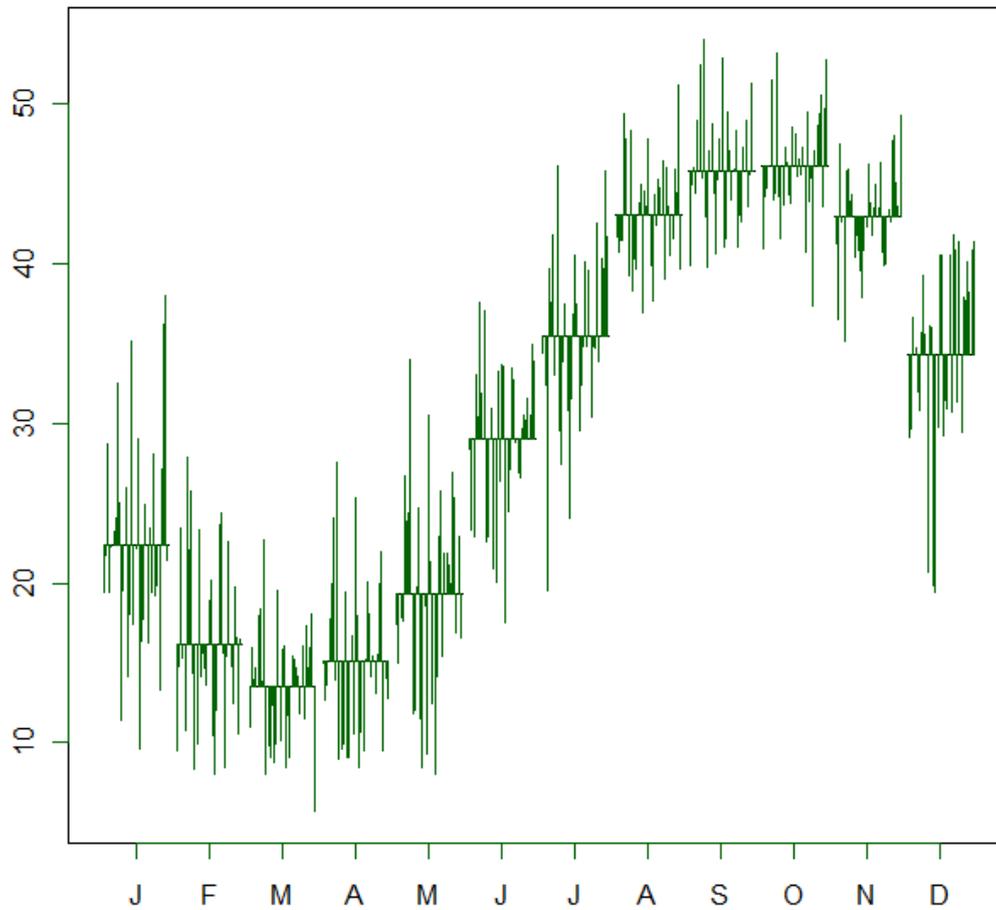


Gráfico 2.2: Monthplot dos fatores de capacidade dos estados do CE, BA, RN e RS.

Em um gráfico desse tipo, as linhas horizontais representam as médias mensais. Representados como linhas verticais estão as observações daquele mês em todos os

anos. Pode-se observar nestes gráficos que as médias não são constantes, e, portanto, esta seria uma evidência de que as séries não exibem estacionaridade. Logo, uma modelagem do tipo ARMA estaria fora de cogitação.

Os dois gráficos a seguir são o gráfico das funções de autocorrelações e autocorrelações parciais, separadas por mês. Pode-se notar uma heterogeneidade entre os meses, mais notadamente entre Janeiro e Junho, nas funções. Apenas os gráficos referentes ao Ceará estão representados, os outros gráficos relativos aos outros Estados se encontram no Anexo.

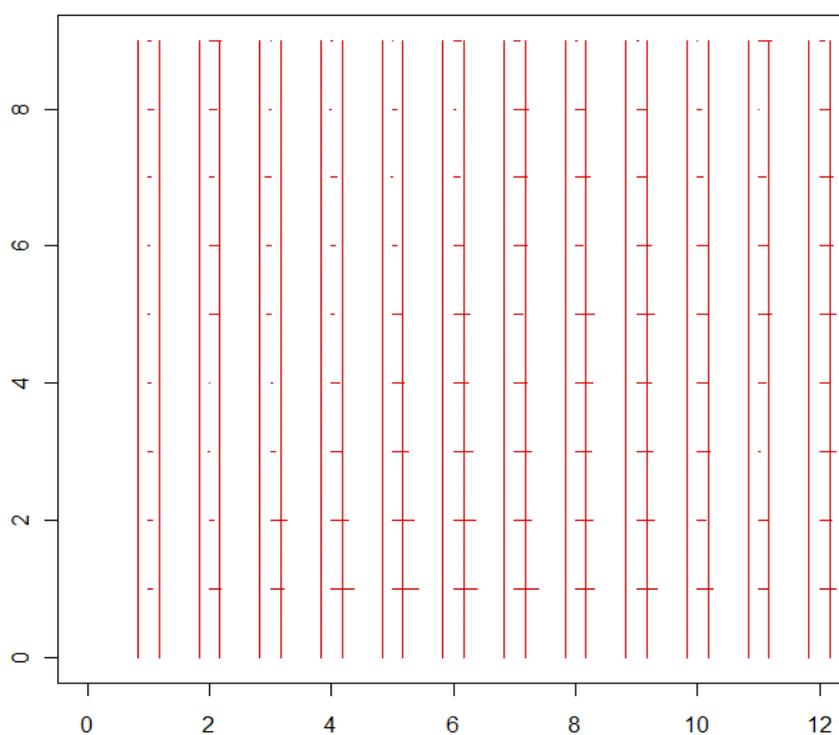


Gráfico 2.3: autocorrelações no estado do CE (eixo Y = lag, eixo X = mês)

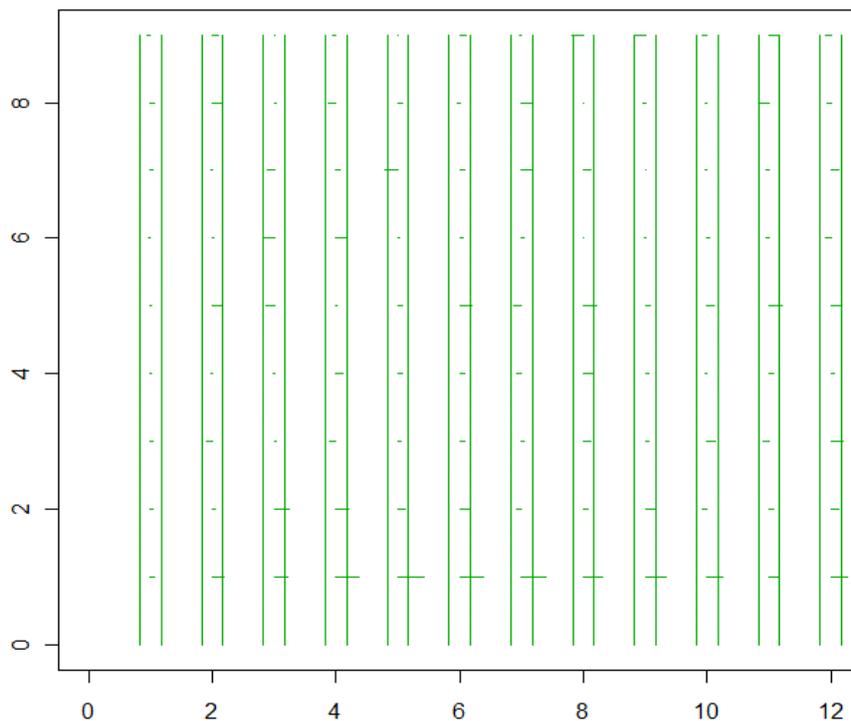


Gráfico 2.4: autocorrelações parciais no estado do CE (eixo Y = lag, eixo X = mês)

Além disso, há a possibilidade do modelo ser do tipo ARIMA. Nesse caso, as séries teriam um comportamento de uma possível raiz unitária. Ou seja, a série poderia apresentar algum tipo de tendência ao longo dos anos, não se mantendo em torno de valores próximos.

Mas, observando o gráfico 2.1, vemos que esse não é o caso. Por mais que as séries variem bastante mês a mês, olhando para maiores intervalos de tempo vê-se que oscilam em torno de um valor, isto é, que não têm uma tendência de longo prazo, estocástica ou não.

Como observa-se uma regularidade entre meses iguais ao longo dos anos, e um modelo do tipo ARIMA foi descartado, um outro tipo de modelo será apresentado. Esse modelo faz parte de uma família de modelos de caráter periódico e é uma das modelagens recomendadas quando se lida com esse tipo de comportamento (Hipel, McLeod, acessado em 7/12/2010), e será apresentado no próximo capítulo.

Capítulo 3 – Modelagem

Este capítulo tem como objetivo apresentar o modelo periódico auto-regressivo e verificar sua aplicabilidade nos dados em questão.

Os fatores de capacidade compilados, como visto no capítulo anterior, apresentam um forte comportamento sazonal. Mas ao mesmo tempo, não parecem apresentar alguma tendência de crescimento ou decrescimento no longo prazo. O gráfico da série do Ceará a seguir explicita bem este comportamento:

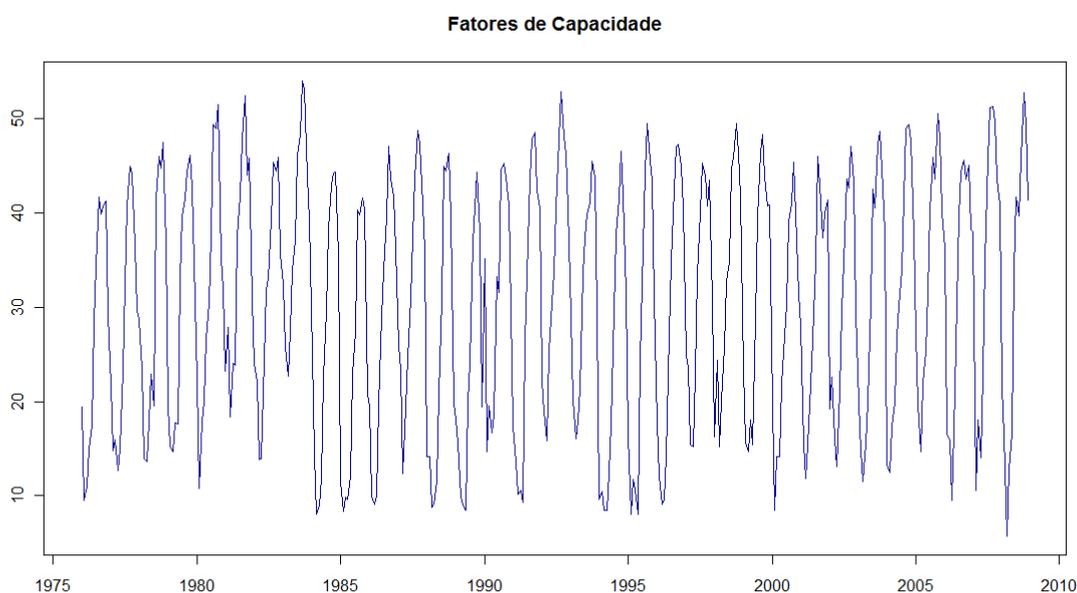


Gráfico 3.1: Evolução dos fatores de capacidade da série referente ao Ceará.

Em casos como este um dos modelos recomendados para se trabalhar é o modelo periódico auto-regressivo, o PAR. Para fins de exposição, é conveniente considerarmos uma formulação simples, o PAR(2). Considere uma série $\{y_t\}$ que evolui segundo:

$$y_t = \varphi_1(t) \cdot y_{t-1} + \varphi_2(t) \cdot y_{t-2} + a_t$$

Com a_t identicamente distribuídos e não correlacionados entre si, com $E(a_t) = 0$ e $Var(a_t) = \tau(t)$, e tanto $\tau(t)$ quanto $\varphi_1(t)$ e $\varphi_2(t)$ sendo funções periódicas. Ou seja, no caso mensal, $\tau(t) = \tau(t - 12)$ e assim por diante. É importante frisar que a normalidade de a_t não é necessária. Esta série segue o modelo PAR(2).

No exercício de modelagem foi utilizado o pacote *pear* da linguagem R. A série a ser modelada foi a referente ao estado do Ceará. Em modelos do tipo PAR, a estimação dos coeficientes é feita de maneira parecida com a estimação de moldes AR: as ordens auto-regressivas foram estimadas analisando-se o gráfico de auto-correlações parciais periódicas (gráfico 2.4) e utilizando o critério AIC.

Após a estimação foi simulada uma série de 1800 observações seguindo o modelo estimado. Nesta simulação foi assumido que o vetor a_t tem distribuição Normal com médias e variâncias baseadas nos resultados do modelo.

Além dessa, foi feita outra simulação com a_t sendo uma amostra dos resíduos estimados. Isso foi feito separando-se os resíduos de cada mês e sorteando com reposição um resíduo para cada mês período simulado. No gráfico a seguir estão representados os *boxplots* da série original e das simulações.

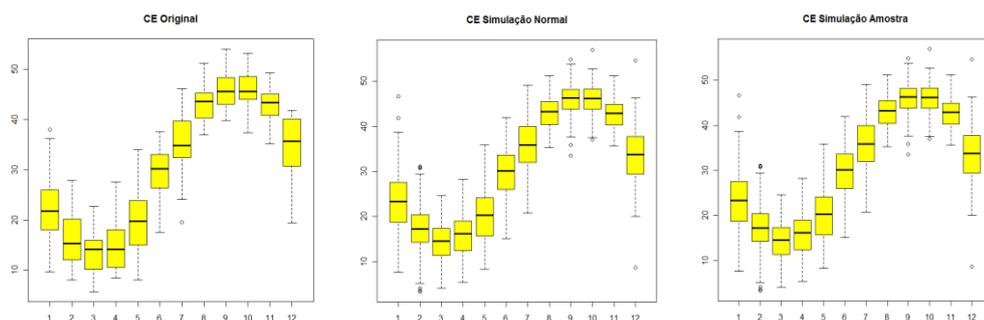


Gráfico 3.1: Boxplots dos dados da série original e das simulações. O eixo Y corresponde aos fatores de capacidade estimados e o eixo X corresponde ao mês.

Fica claro que as simulações parecem reproduzir a variabilidade da série original. A adequabilidade do PAR pode ser checada via teste *portmanteau* (Ljung-Box adaptados ao caso periódico), (Hipel, McLeod, acessado em 7/12/2010):

Testes Portmanteau				
Mês				
sendo	Lags	p-valor	Lags	p-valor
modelado				
Jan	4	0,97	8	0,98
Fev	4	0,63	8	0,31
Mar	3	0,45	7	0,51
Abr	3	0,59	7	0,29
Mai	4	0,55	8	0,21
Jun	4	0,18	8	0,50
Jul	4	0,40	8	0,10
Ago	4	0,23	8	0,08
Set	4	0,55	8	0,69
Out	4	0,47	8	0,57
Nov	4	0,14	8	0,07
Dez	2	0,20	6	0,31

Tabela 3.1: Testes *portmanteau* para a adequabilidade do modelo PAR à série do Ceará.

Os coeficientes estimados para a série do Ceará são:

Coeficientes Estimados			
Mês sendo			
modelado	Lag 1	Lag 2	Lag 3
Jan	0,12	0,00	0,00
Fev	0,29	0,00	0,00
Mar	0,19	0,26	0,00
Abr	0,78	0,28	0,00
Mai	1,05	0,00	0,00
Jun	0,58	0,00	0,00
Jul	0,93	0,00	0,00
Ago	0,37	0,00	0,00

Set	0,70	0,00	0,00
Out	0,47	0,00	0,00
Nov	0,29	0,00	0,00
Dez	0,81	0,09	0,64

Tabela 3.2: Coeficientes estimados para a série do Ceará.

Capítulo 4 – Um Modelo Com Chaveamento De Markov

Fenômenos climáticos são regidos por muitos fatores, e muitas vezes passam por mudanças estruturais. Por isso, é razoável assumir que momentos diferentes podem ser regidos por modelos diferentes. Mais precisamente neste caso, podemos investigar se o modelo que rege os fatores de capacidade dos ventos muda ou não de regime, ano a ano. O objetivo deste capítulo é apresentar o *Modelo de Espaço de Estados com Chaveamento de Markov*, um tipo de modelo no qual ocorrem mudanças de regimes no processo determinadas por uma *Cadeia de Markov*.

Em cada regime é especificado um *Modelo de Espaço de Estados (MEE)*, que também será apresentado. Além disso, vai-se representar o modelo PAR apresentado anteriormente como um MEE, para podermos converter nosso modelo anterior. Antes, vamos apresentar um pequeno resumo da teoria da Cadeia de Markov, que é o processo que define a mudança de regimes no modelo.

Vamos assumir que existe uma mudança estrutural no processo de geração de ventos, e que esta mudança é regida por variáveis não observadas. Vamos supor que a série alterne entre dois regimes, **1** e **2**. Como exemplo, vamos supor que o regime **1** ocorra na presença do fenômeno El Niño e o regime **2** na presença do fenômeno La Niña.

Essa mudança de regimes pode ser representada por uma variável aleatória que assume os valores **1** ou **2** em determinado período t , e a mudança de regimes pode ser relacionada à ela: o regime vigente no período t é o regime que corresponde ao valor da variável também no período t .

Vamos supor também que, dado que a variável tenha o valor **1** no período t , exista uma probabilidade $P_{1,1}$ de ela continuar em **1**, e uma probabilidade $P_{1,2}$ de ela mudar para **2** no período $t + 1$. Como esses são os únicos valores possíveis, $P_{1,1} + P_{1,2} = 1$. Aplicando o mesmo raciocínio caso o valor seja **2** no período t , podemos formalizar a variável da seguinte maneira:

Supõe-se uma variável cujo estado S_t pode ter dois valores, 1 e 2, regidos pela seguinte regra:

$$P(S_t = i | S_{t-1} = j) = P_{j,i}$$

onde $i, j \in \{1,2\}$, e se observa a seguinte propriedade:

$$\sum_{i=1}^2 P(S_t = i | S_{t-1} = j) = 1$$

Um processo que possui essas características é chamada de *Cadeia de Markov*¹. Um modelo com *Chaveamento de Markov* é um modelo cujo regime é justamente definido por uma variável deste tipo.

Em Economia, o primeiro autor a propor o uso de um modelo com o chaveamento de Markov foi Hamilton (Hamilton, 1994). Em seu artigo, propôs modelar a evolução do PIB americano como um modelo auto-regressivo simples com o chaveamento de Markov. A partir de então, a teoria foi bem difundida e aplicada principalmente no ramo de Finanças (Wang, Zivot, 2006, pág. 687). Na Estatística uma versão um pouco mais geral do chaveamento de Markov é dada pelos modelos *Hidden Markov Models* (MacDonald, Zucchini, 2009).

A seguir é apresentada uma simulação de uma série AR(1) com chaveamento de Markov. A única diferença entre um regime e outro é a constante:

¹ Uma Cadeia de Markov é mais que isso, mas nesta monografia vamos trabalhar com estas propriedades apenas. Para mais detalhes, consultar (Norris, 1998).

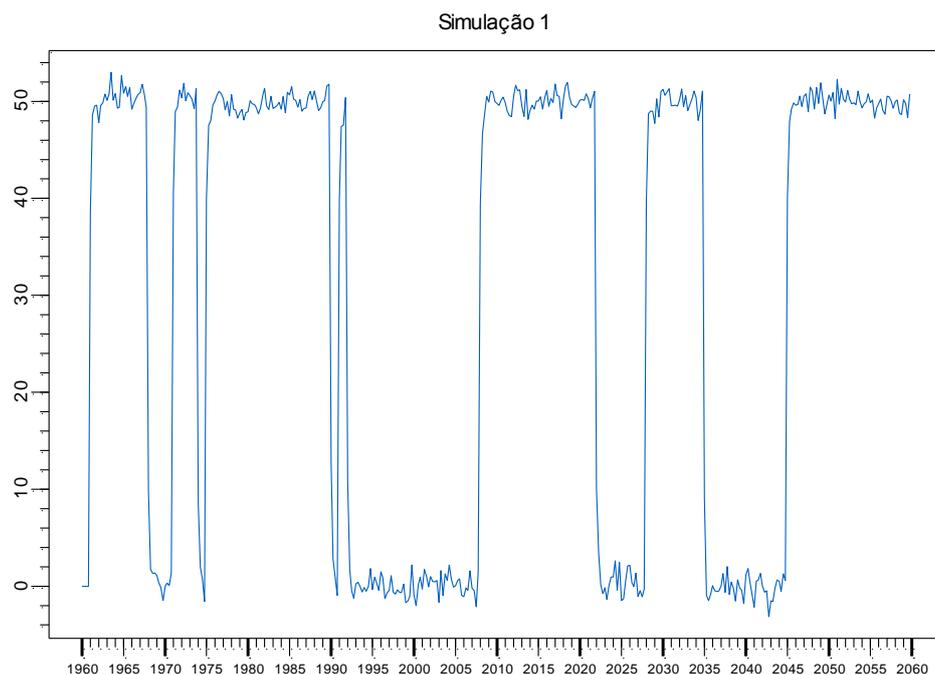


Gráfico 4.1: Simulação de uma série com chaveamento de Markov.

É possível observar com facilidade a mudança de um regime para o outro. As probabilidades de transição da cadeia de Markov são as seguintes (essa forma de apresentar é conhecida por *Matriz de Transição*):

$$\mathbf{P} = \begin{bmatrix} P_{1,1} & P_{1,2} \\ P_{2,1} & P_{2,2} \end{bmatrix} = \begin{bmatrix} 0.9 & 0.1 \\ 0.1 & 0.9 \end{bmatrix}$$

Essa cadeia é do tipo que tende a ficar no mesmo estado, vide a baixa probabilidade de mudar em $t + 1$ (10% de chance de mudar de regime). A próxima simulação também é um AR com chaveamento:

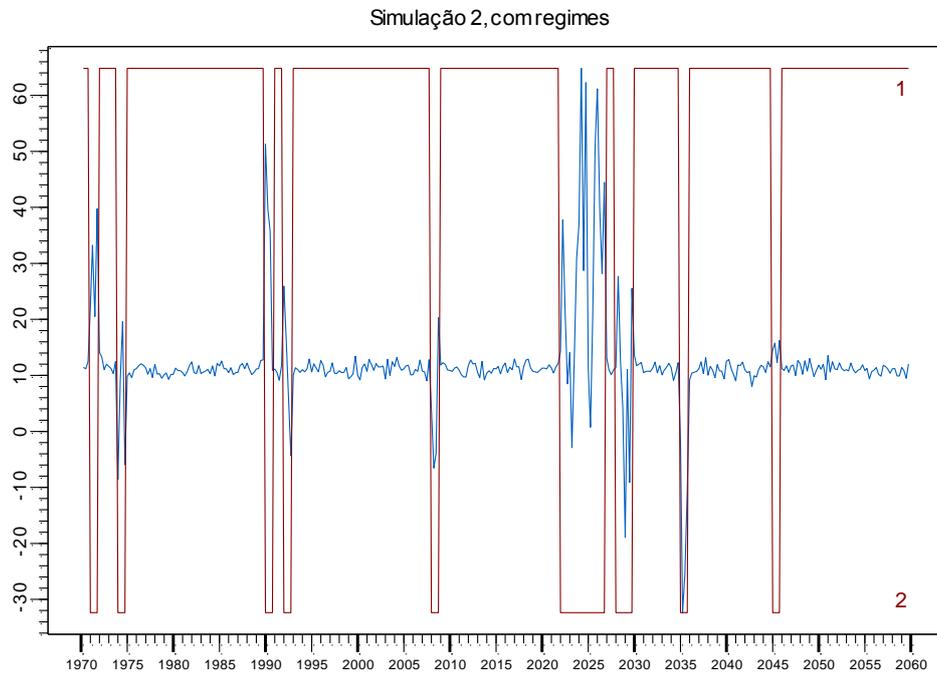
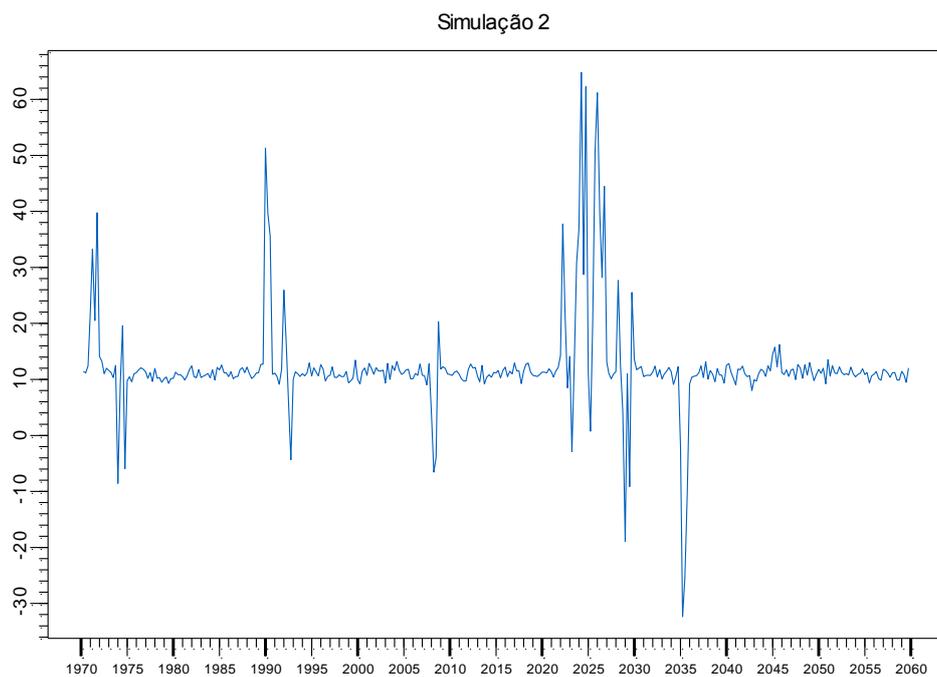


Gráfico 4.2: Simulação 2, sem o com os regimes plotados.

Na simulação do gráfico 4.2, o regime 2 possui o mesmo valor esperado, mas uma variância bem maior. O gráfico de baixo mostra os valores da cadeia de Markov plotados por cima da série simulada. A matriz de transição deste caso é:

$$\mathbf{P} = \begin{bmatrix} P_{1,1} & P_{1,2} \\ P_{2,1} & P_{2,2} \end{bmatrix} = \begin{bmatrix} 0.9 & 0.1 \\ 0.8 & 0.2 \end{bmatrix}$$

Como pode se observar, $P_{1,2} = 0.1$ e $P_{2,2} = 0.2$, o que significa que é raro a série ir para o segundo regime, e, uma vez lá, a tendência é voltar rapidamente. Neste caso, o segundo regime é chamado de *regime transiente*.

Então, o modelo com mudança de regimes a ser estimado possui estas mudanças regidas por uma cadeia de Markov como a descrita acima. Parte do trabalho é estimar as probabilidades de transição das séries.

O algoritmo a ser utilizado para estimar o modelo é implementado pela função *SsfFitMS*, do pacote *S+FinMetrics* da linguagem *S-PLUS*. Ele estima os parâmetros de um modelo de Espaço de Estados com Chaveamento de Markov. Portanto, temos que representar nosso modelo PAR como um modelo de Espaço de Estados.

Primeiro vamos apresentar o MEE. Este modelo tem a seguinte forma (Wang, Zivot, 2006, pág. 520):²

$$\alpha_{t+1} = \mathbf{d} + \mathbf{T}\alpha_t + \mathbf{H}\eta_t \quad (1)$$

$$\mathbf{y}_t = \mathbf{c} + \mathbf{Z}\alpha_t + \mathbf{G}\varepsilon_t \quad (2)$$

onde α_t é o *vetor de estados* de dimensão \mathbf{m} e \mathbf{y}_t é o *vetor de medida* de dimensão \mathbf{n} . η_t e ε_t são vetores de dimensões \mathbf{m} e \mathbf{n} , respectivamente, e seus componentes são *iid* $N(0,1)$. \mathbf{d} e \mathbf{c} são vetores constantes de dimensões \mathbf{m} e \mathbf{n} , respectivamente, e \mathbf{T} e \mathbf{Z} são matrizes \mathbf{m} por \mathbf{m} e \mathbf{n} por \mathbf{n} , respectivamente. O vetor de medida é o vetor observado.

Portanto, as equações (1) e (2) podem ser reescritas da seguinte forma:

² O modelo de Espaço de Estados tem uma forma mais geral. A forma aqui mostrada é a que se vai utilizar nesta monografia.

$$\begin{bmatrix} \alpha_{t+1} \\ \mathbf{y}_t \end{bmatrix} = \boldsymbol{\delta} + \boldsymbol{\Phi}\alpha_t + \mathbf{u}_t$$

onde $u_t \sim iid N(0, \Omega)$ e

$$\boldsymbol{\delta} = \begin{bmatrix} \mathbf{d} \\ \mathbf{c} \end{bmatrix}$$

$$\boldsymbol{\Phi} = \begin{bmatrix} \mathbf{T} \\ \mathbf{Z} \end{bmatrix}$$

$$\mathbf{u}_t = \begin{bmatrix} \mathbf{H}\eta_t \\ \mathbf{G}\varepsilon_t \end{bmatrix}$$

$$\Omega = \begin{bmatrix} \mathbf{H}\mathbf{H}' & \mathbf{0} \\ \mathbf{0} & \mathbf{G}\mathbf{G}' \end{bmatrix}$$

Para se caracterizar o modelo, nota-se que é apenas necessário especificar o vetor $\boldsymbol{\delta}$, a matriz $\boldsymbol{\Phi}$ e a matriz de covariância Ω .

Para representar um modelo PAR desta maneira, vamos primeiro supor um modelo PAR(1) de periodicidade trimestral. Este modelo pode ser representado pelo seguinte sistema:

$$T_{1,t} = c_1 + \phi(1)T_{4,t-1} + u_{1,t}$$

$$T_{2,t} = c_2 + \phi(2)T_{1,t} + u_{2,t}$$

$$T_{3,t} = c_3 + \phi(3)T_{2,t} + u_{3,t}$$

$$T_{4,t} = c_4 + \phi(4)T_{3,t} + u_{4,t}$$

onde $T_{i,t}$ é o valor do trimestre i no ano t , c_i são constantes e $u_{i,t}$ são $iid N(0, \sigma_i^2)$.

Este sistema pode ser escrito matricialmente da seguinte maneira:

$$\mathbf{A}\mathbf{X}_t = \mathbf{c} + \mathbf{B}\mathbf{X}_{t-1} + \mathbf{d}\mathbf{u}_t$$

onde \mathbf{X}_t é o vetor de quatro dimensões com componentes $T_{i,t}$. Essas quatro dimensões representam os trimestres, logo o vetor representa um ano. Temos ainda \mathbf{u}_t , um vetor também de quatro dimensões com os componentes *iid* $N(0,1)$. Ainda:

$$\mathbf{A} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ -\phi(2) & 1 & 0 & 0 \\ 0 & -\phi(3) & 1 & 0 \\ 0 & 0 & -\phi(4) & 1 \end{bmatrix}; \quad \mathbf{c} = \begin{bmatrix} c_1 \\ c_2 \\ c_3 \\ c_4 \end{bmatrix}$$

$$\mathbf{B} = \begin{bmatrix} 0 & 0 & 0 & \phi(1) \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix}; \quad \mathbf{d} = \begin{bmatrix} \sigma_1 & 0 & 0 & 0 \\ 0 & \sigma_2 & 0 & 0 \\ 0 & 0 & \sigma_3 & 0 \\ 0 & 0 & 0 & \sigma_4 \end{bmatrix}$$

Temos:

$$\mathbf{A}^{-1} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ \phi(2) & 1 & 0 & 0 \\ \phi(2)\phi(3) & \phi(3) & 1 & 0 \\ \phi(2)\phi(3)\phi(4) & \phi(3)\phi(4) & \phi(4) & 1 \end{bmatrix}$$

E o sistema pode ser reescrita da seguinte maneira:

$$\mathbf{X}_t = \mathbf{A}^{-1}\mathbf{c} + \mathbf{A}^{-1}\mathbf{B}\mathbf{X}_{t-1} + \mathbf{A}^{-1}\mathbf{d}\mathbf{u}_t$$

As variáveis definidas nas *Equações de Medida* no modelo MEE são as variáveis de fato observadas. Vamos inserir as quatro equações de medida neste modelo:

$$y_{1,t} = T_{4,t-1}$$

$$y_{2,t} = T_{1,t}$$

$$y_{3,t} = T_{2,t}$$

$$y_{4,t} = T_{3,t}$$

E o modelo final tem a seguinte representação:

$$\mathbf{X}_t = \mathbf{A}^{-1}\mathbf{c} + \mathbf{A}^{-1}\mathbf{B}\mathbf{X}_{t-1} + \mathbf{A}^{-1}\mathbf{d}u_t$$

Com:

$$\mathbf{X}_t = \begin{bmatrix} T_{1,t} \\ T_{2,t} \\ T_{3,t} \\ T_{4,t} \\ y_{1,t} \\ y_{2,t} \\ y_{3,t} \\ y_{4,t} \end{bmatrix}; \quad \mathbf{A}^{-1} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ \phi(2) & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ \phi(2)\phi(3) & \phi(3) & 1 & 0 & 0 & 0 & 0 & 0 \\ \phi(2)\phi(3)\phi(4) & \phi(3)\phi(4) & \phi(4) & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}$$

$$\mathbf{c} = \begin{bmatrix} c_1 \\ c_2 \\ c_3 \\ c_4 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}; \quad \mathbf{B} = \begin{bmatrix} 0 & 0 & 0 & \phi(1) \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}; \quad \mathbf{d} = \begin{bmatrix} \sigma_1 & 0 & 0 & 0 \\ 0 & \sigma_2 & 0 & 0 \\ 0 & 0 & \sigma_3 & 0 \\ 0 & 0 & 0 & \sigma_4 \\ \mathbf{0} & & & \mathbf{0} \end{bmatrix}$$

As matrizes relativas ao MEE são, portanto:

$$\boldsymbol{\delta} = \mathbf{A}^{-1}\mathbf{c}$$

$$\boldsymbol{\Phi} = \mathbf{A}^{-1}\mathbf{B}$$

$$\boldsymbol{\Omega} = \mathbf{A}^{-1}\mathbf{d}(\mathbf{A}^{-1})'$$

Como estamos lidando com um modelo regido por um chaveamento de Markov, temos uma destas matrizes para cada regime. Ao todo, as matrizes a serem estimadas são:

$$\boldsymbol{\delta}_1, \boldsymbol{\delta}_2, \boldsymbol{\Phi}_1, \boldsymbol{\Phi}_2, \boldsymbol{\Omega}_1, \boldsymbol{\Omega}_2, \mathbf{P}$$

sendo \mathbf{P} a matriz de transição.

Ou seja, teremos as matrizes de índice **1** representando o comportamento da série na presença do El Niño (no nosso exemplo), e as matrizes de índice **2** representando esse comportamento na presença da La Niña. Temos ainda a matriz de transição que guarda os valores das probabilidades de se mudar e se manter no mesmo regime.

O problema da estimação será tratado no próximo capítulo.

Capítulo 5 – Estimação

Neste capítulo vamos analisar os resultados da estimação.

No modelo apresentado, cada regime possui 12 parâmetros a serem estimados: 4 constantes, 4 coeficientes auto-regressivos e 4 desvios-padrão. Além disso, serão estimadas duas probabilidades de transição, $P_{1,2}$ e $P_{2,1}$, totalizando 26 parâmetros no total. A amostra relativa aos estados é de 33 anos, e isso torna inviável utilizar um modelo com mais parâmetros que o descrito acima. Daí a escolha de um PAR(1), e não um PAR(3) como estimado anteriormente, e do uso das médias trimestrais ao invés dos dados mensais da série original.

Feita a estimação no pacote R, a primeira observação importante é o fato de alguns t-valores terem seus módulos baixos demais. Como foram estimados 26 parâmetros em uma amostra de 33 anos, tal grau de incerteza era esperado. A tabela completa com todos os parâmetros estimados, seus erros padrões e os t-valores respectivos se encontram no Anexo.

Na primeira tabela, vamos comparar as probabilidades de transição dos regimes:

Probabilidades Estimadas				
	CE	BA	RN	RS
$P_{1,2}$	10%	30%	10%	28%
$P_{2,1}$	75%	69%	11%	68%

Tabela 5.1: Probabilidades de transição estimadas.

Pode-se notar uma diferença entre os estados como um todo – exceto entre a Bahia e o Rio Grande do Sul, que têm probabilidades semelhantes. O Ceará apresenta o segundo regime como um *regime transiente*. Isso é reflexo de uma baixa probabilidade de se sair do primeiro regime e uma grande probabilidade de voltar para este, caso vá para o segundo. BA e RS apresentam probabilidades semelhantes, mas não tão fortes quanto CE.

Rio Grande do Norte possui o padrão mais diferente dos quatro: ambas as probabilidades de transição são baixas. Isso significa que, uma vez em um regime, o modelo tende a continuar nele.

Este resultado não era o esperado – faria mais sentido os estados do Nordeste terem as probabilidades mais parecidas, e, se houvesse alguma discrepância, esta seria observada na série do RS.

Este pode ser um reflexo da pequena amostra. Também pode ser uma evidência contra a hipótese de que a produção de ventos no Brasil sofre uma mudança de regime como um todo.

O algoritmo utilizado também calcula a probabilidade da série estar em cada período. Os próximos gráficos são as probabilidades estimadas (*smoothed probabilities*) da série estar no primeiro regime:

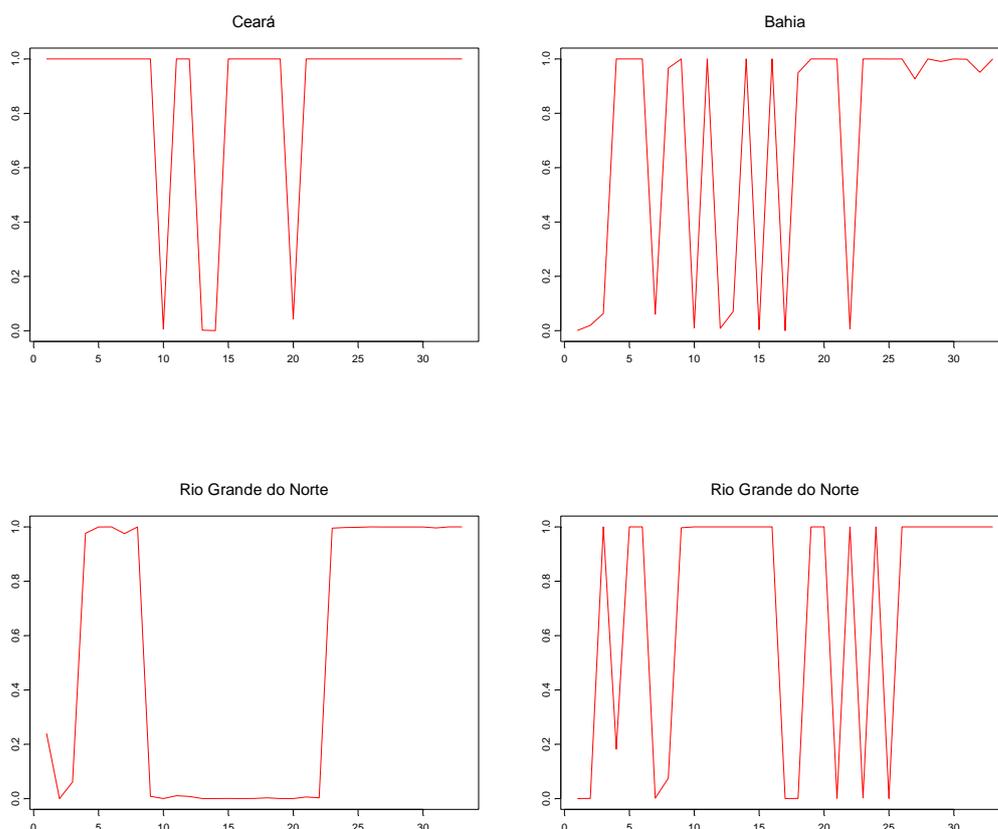


Gráfico 5.1: Probabilidades dos regimes.

Os gráficos ilustram as conclusões anteriores: o CE indo raramente ao segundo regime, e ficando lá no máximo dois períodos; BA e RS com um segundo regime transiente também, mas não tão raro; e RN com pouca mudança de regimes.

A tabela 5.2 compara os coeficientes auto-regressivos das séries e de seus regimes:

	Coefficientes Estimados			
	CE	BA	RN	RS
$\phi_1(1)$	0.12	-0.12	0.16	0.36
$\phi_1(2)$	0.70	0.72	0.39	0.28
$\phi_1(3)$	0.54	0.60	0.91	0.17
$\phi_1(4)$	0.33	0.35	0.32	-0.34
$\phi_2(1)$	-0.56	0.18	0.05	-0.03
$\phi_2(2)$	-0.50	0.41	0.35	-0.60
$\phi_2(3)$	1.81	1.13	0.26	0.08
$\phi_2(4)$	0.63	0.24	-0.17	-1.07

Tabela 5.2: Coeficientes auto-regressivos estimados.

É importante ressaltar a presença de coeficientes negativos. Esse fato também não era esperado, vide que, como explicado no capítulo 1, os dados são relativos a fatores de capacidade, e variam de 0 a 1 (0% a 100% nesse caso). Valores de constantes altos podem resolver esse problema – podem fazer com que a série num período t tenha valor positivo, mesmo somando com o valor anterior multiplicado por um coeficiente negativo. A tabela a seguir mostra as constantes, grifadas nos períodos que têm coeficiente negativo:

	Constantes Estimadas			
	CE	BA	RN	RS
$c_1(1)$	13.19	26.98	12.13	13.64
$c_1(2)$	9.42	18.52	18.94	22.67
$c_1(3)$	29.92	25.50	23.63	36.08
$c_1(4)$	27.83	16.23	31.81	53.34

$c_2(1)$	34.14	20.35	12.76	28.16
$c_2(2)$	20.00	21.53	14.58	45.73
$c_2(3)$	12.71	8.93	37.80	33.30
$c_2(4)$	11.77	19.02	49.08	72.61

Tabela 5.3: Constantes estimadas.

No RS, os coeficientes negativos de maior módulo são acompanhados de uma grande constante. BA e RN têm pequenos coeficientes negativos. Já no caso do CE, os coeficientes não têm módulo tão pequeno e nem as constantes são tão grandes. Isso pode ser um reflexo da pequena amostragem do segundo regime nesta série (vide gráfico 5.1).

Resta ainda mostrar os desvios padrão:

	Desvios Padrão Estimados			
	CE	BA	RN	RS
$\sigma_1(1)$	14.70	4.79	14.96	8.33
$\sigma_1(2)$	12.39	3.38	3.59	15.03
$\sigma_1(3)$	6.46	6.68	5.94	5.42
$\sigma_1(4)$	6.71	4.09	5.33	6.06
$\sigma_2(1)$	0.78	2.75	15.51	10.75
$\sigma_2(2)$	0.06	0.84	5.42	8.52
$\sigma_2(3)$	8.15	11.94	9.08	1.85
$\sigma_2(4)$	1.61	3.90	11.69	3.15

Tabela 5.4: Desvios padrão estimados.

Uma hipótese levantada na Introdução foi a de que as mudanças de regime pudessem ser acionadas por um fator exógeno, no caso os fenômenos El Niño/La Niña. O próximo gráfico é um gráfico da média anual do *Multivariate ENSO Index* (MEI). Este índice é a referência ao se falar de El Niño/La Niña, pois reflete o *El Niño/Southern Oscillation*, o fenômeno relacionado à mudanças climáticas globais:

El Niño/Southern Oscillation (ENSO) is the most important coupled ocean-atmosphere phenomenon to cause global climate variability on interannual time scales. Here we attempt to monitor ENSO by basing the Multivariate ENSO Index (MEI) on the six main observed variables over the tropical Pacific. These six variables are: sea-level pressure (P), zonal (U) and meridional (V) components of the surface wind, sea surface temperature (S), surface air temperature (A), and total cloudiness fraction of the sky (C).
Fonte: (National Oceanic & Atmospheric Administration, acessado em 7 de Dezembro de 2010)

Valores positivos significam presença do fenômeno El Niño e negativos significam presença do fenômeno La Niña:

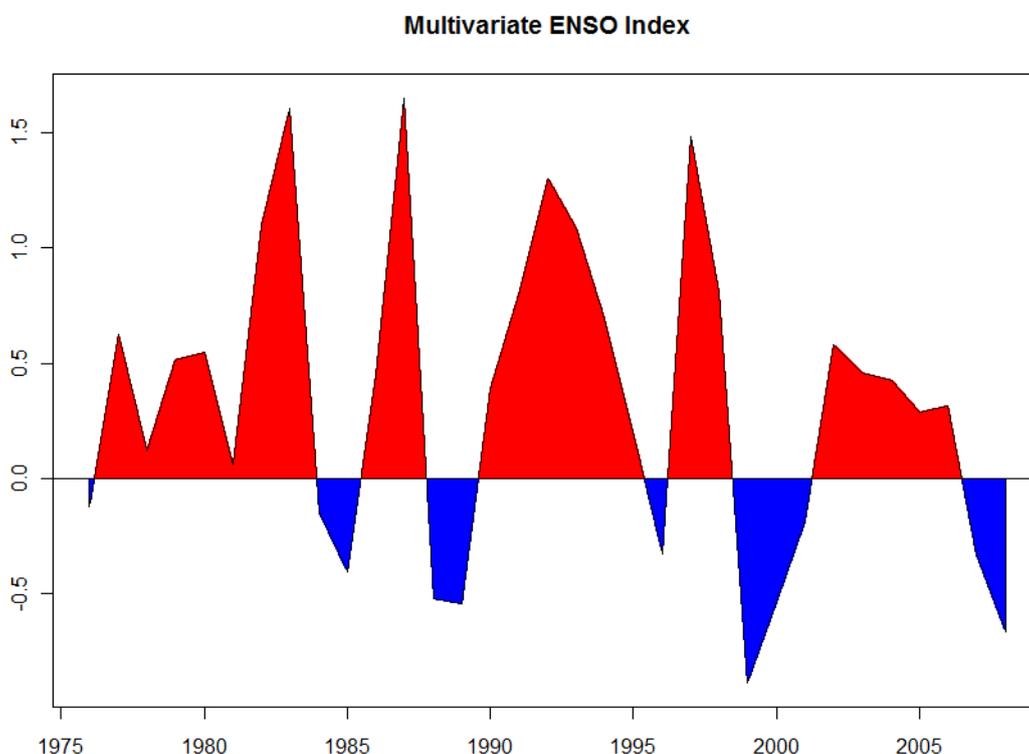


Gráfico 5.2: MEI, de 1976 a 2009. Fonte: NOAA (2010).

A tabela a seguir mostra o índice MEI em conjunto com a probabilidade das séries estarem no regime 1. As células estão codificadas por cor; nos anos de El Niño as células são alaranjadas, e nos anos de La Niña são azuladas. As células das

probabilidades são cinza quando a série se encontra no segundo regime, e brancas no primeiro:

Ano	MEI	CE	BA	RN	RS
1976	-0.11	100%	0%	24%	0%
1977	0.62	100%	2%	0%	0%
1978	0.12	100%	6%	6%	100%
1979	0.51	100%	100%	98%	18%
1980	0.55	100%	100%	100%	100%
1981	0.06	100%	100%	100%	100%
1982	1.09	100%	6%	98%	0%
1983	1.60	100%	97%	100%	8%
1984	-0.14	100%	100%	1%	100%
1985	-0.40	1%	1%	0%	100%
1986	0.45	100%	100%	1%	100%
1987	1.65	100%	1%	1%	100%
1988	-0.52	0%	7%	0%	100%
1989	-0.54	0%	100%	0%	100%
1990	0.39	100%	0%	0%	100%
1991	0.80	100%	100%	0%	100%
1992	1.30	100%	0%	0%	0%
1993	1.08	100%	95%	0%	0%
1994	0.69	100%	100%	0%	100%
1995	0.21	4%	100%	0%	100%
1996	-0.33	100%	100%	1%	0%
1997	1.49	100%	1%	0%	100%
1998	0.81	100%	100%	100%	0%
1999	-0.89	100%	100%	100%	100%
2000	-0.53	100%	100%	100%	0%
2001	-0.18	100%	100%	100%	100%
2002	0.58	100%	93%	100%	100%
2003	0.46	100%	100%	100%	100%

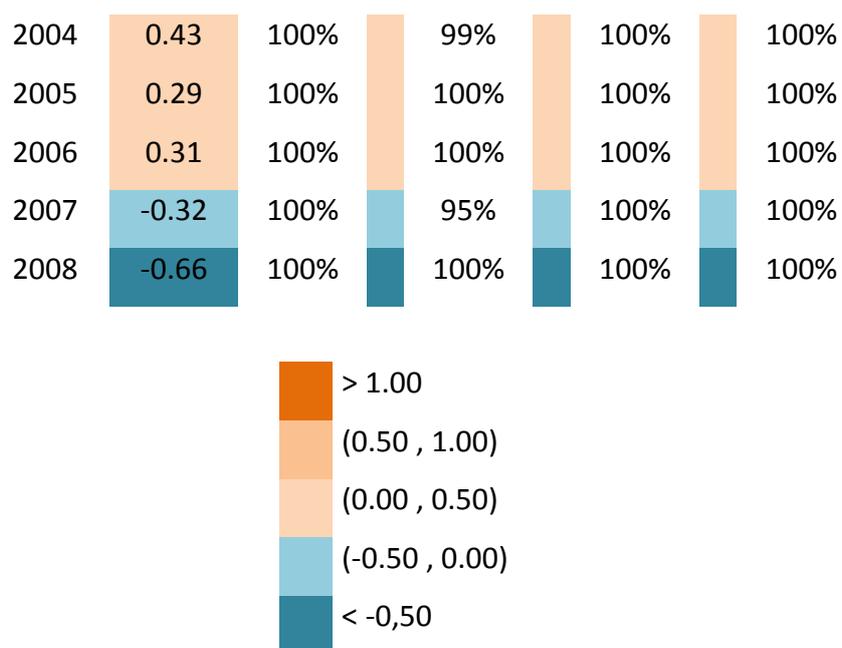


Tabela 5.2: MEI e Regime 1.

A análise exploratória aqui feita parece não fornecer evidências a favor da hipótese. Independente da ação do ENSO, as mudanças de regime das séries não são coincidentes, ou mesmo próximas.

Conclusão

Neste trabalho conclui-se que não há evidências de que o processo de formação de ventos no Brasil passe por mudanças de regime, nem sob influência dos efeitos El Niño ou La Niña. Isso significa um problema a menos no investimento em energia eólica neste país.

Num primeiro momento foi estudado o comportamento da série temporal compilada pela consultoria Camargo & Schubert. Na análise exploratória foi deixada de lado a hipótese de que o modelo que rege a série fosse do tipo ARIMA. Depois, o modelo PAR foi apresentado, e verificou-se que este se adequava bem aos dados.

A hipótese de que havia mudanças de regime foi tratada a partir do capítulo 4. Foi apresentado o modelo de Espaço de Estados com Chaveamento de Markov e, em seguida, estimado seus coeficientes.

As mudanças de regime foram muito diferentes de estado para estado, sugerindo que não existiria uma mudança de regime que envolvesse todo o país. Além disso, foram analisados os períodos de El Niño e La Niña e visto que estes não estão correlacionados com as mudanças de regime observadas.

Algo a se frisar é que o número de amostras foi pequeno perante o número de parâmetros a se estimar. Logo, essa conclusão pode ser consequência desta pequena amostra, visto que muitos parâmetros tiveram t-valor alto na estimação (tabela A.1). Com o tempo, mais dados serão coletados e a possibilidade de se responder essa pergunta com uma solução satisfatória aumentará.

Bibliografia

BRANDÃO, Roberto; CASTRO, Nivalde José de; DANTAS, Guilherme de A.; MARTINI, Sidnei; TIMPONI, Raul R. *A Importância das Fontes Alternativas e Renováveis na Evolução da Matriz Elétrica Brasileira*. V Seminário de Geração e Desenvolvimento Sustentável, Fundación MAPFRE, 2009.

GWEC. Global Energy Council, <http://www.gwec.net>, acessado em 3 de Dezembro de 2010.

HAMILTON, J. D. *A New Approach to the Economic Analysis of Nonstationary Time Series Subject to Changes in Regime*. *Econometrica*, 57, págs. 357-384, 1989.

HIPEL, K. W.; McLEOD, A.I. *Time Series Modelling of Water Resources and Environmental Systems*, <http://www.systems.uwaterloo.ca/Faculty/Hipel/Time%20Series%20Book.htm>. acessado em 7 de Dezembro de 2010.

MacDONALD, Iain L.; ZUCCHINI, Walter. *Hidden Markov Models for Time Series: An Introduction Using R*. Boca Ratton: Chapman & Hall/CRC, 2009.

MME. Ministério de Minas e Energia, <http://www.mme.gov.br>, acessado em 3 de Dezembro de 2010.

MORETTIN, Pedro A.; TOLOI, Clélia M. *Análise de Séries Temporais*. 2ª edição, São Paulo: Edgar Blucher, 2006.

NOAA. National Oceanic & Atmospheric Administration, <http://www.esrl.noaa.gov/psd/people/klaus.wolter/MEI/mei.html>, acessado em 7 de Dezembro de 2010.

NORRIS, J. R. *Markov Chains*. Cambridge: Cambridge University Press, 1998.

WANG, Jiahui; ZIVOT, Eric. *Modelling Financial Time Series With S-PLUS*. 2ª edição, New York: Springer, 2006.

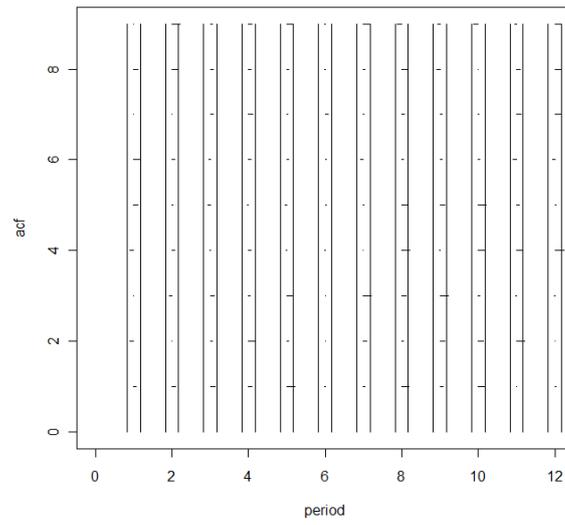
Anexo

Gráfico A.1: Função de autocorrelação periódica, BA

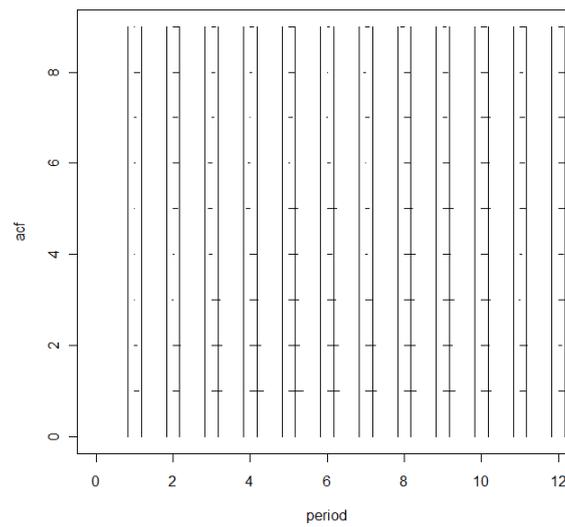


Gráfico A.2: Função de autocorrelação periódica, RN

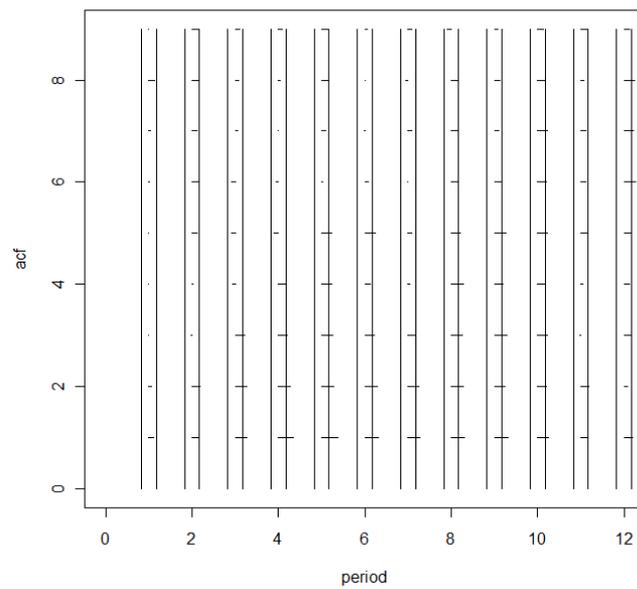


Gráfico A.3: Função autocorrelação periódica, RS

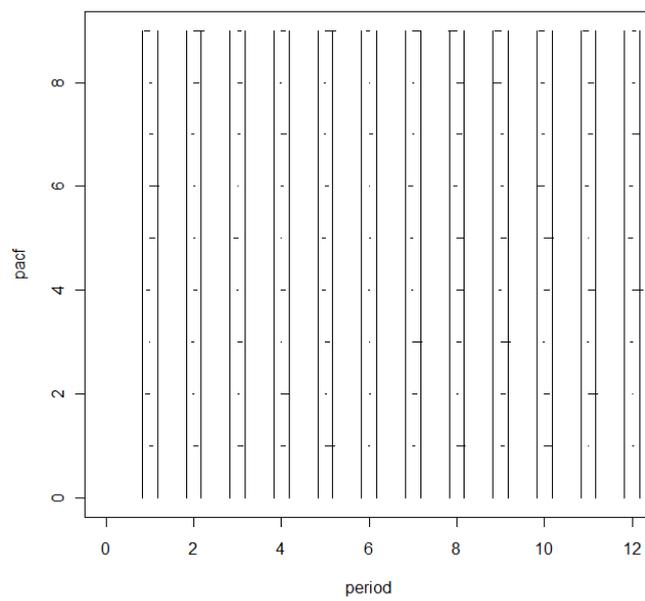


Gráfico A.4: Função autocorrelação parcial periódica, BA

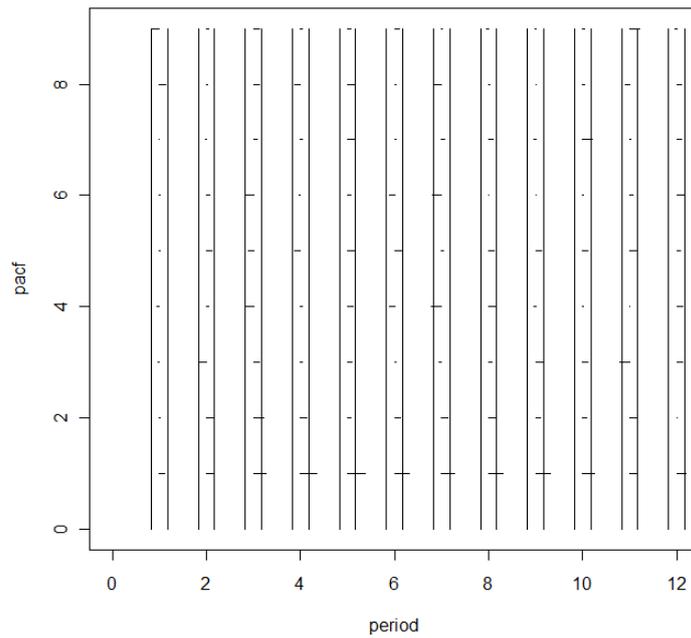


Gráfico A.5: Função autocorrelação parcial periódica, RN

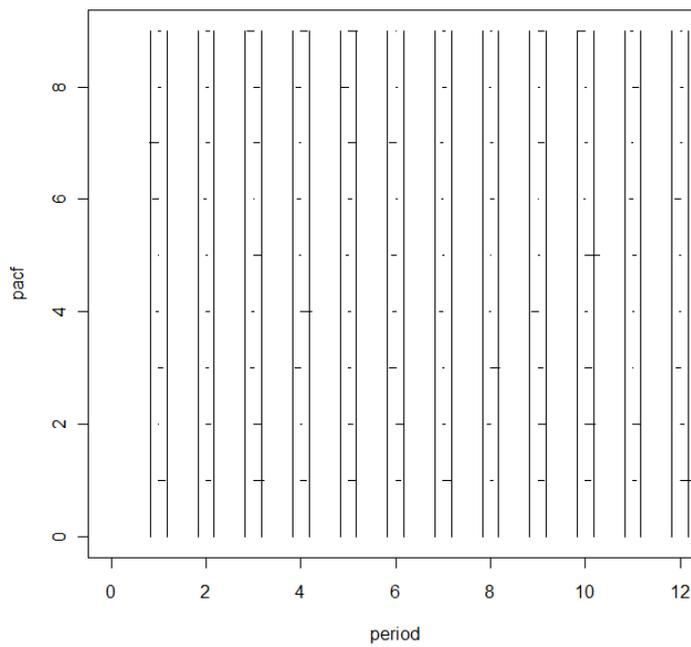


Gráfico A.6: Função autocorrelação parcial periódica, RS

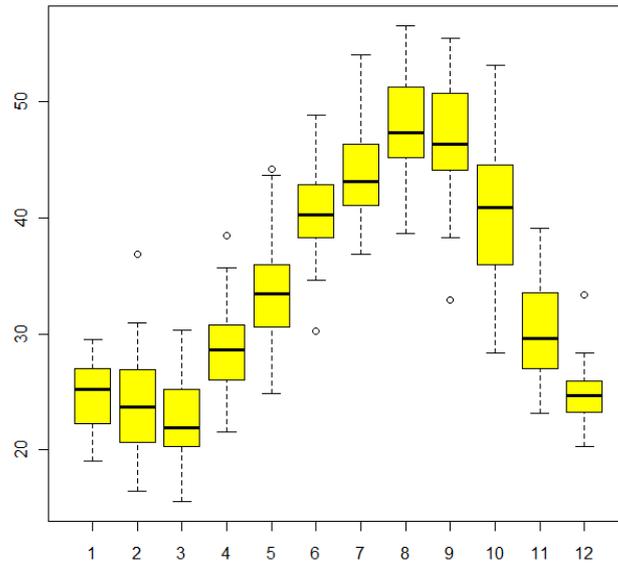


Gráfico A.7: Boxplot periódico, BA

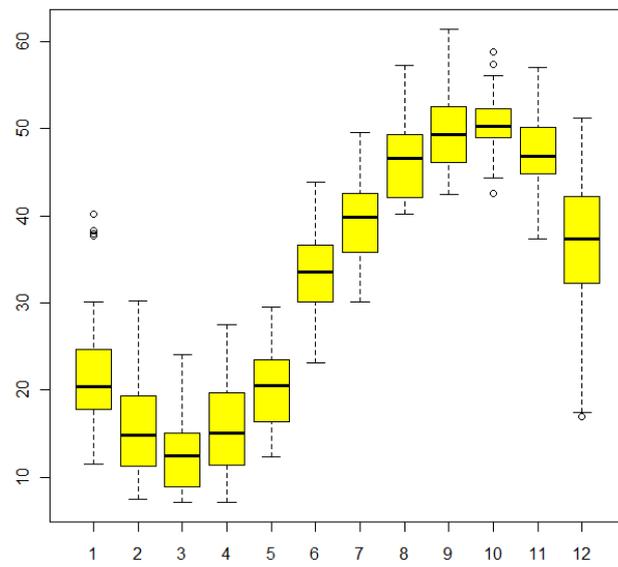


Gráfico A.8: Boxplot periódico, RN

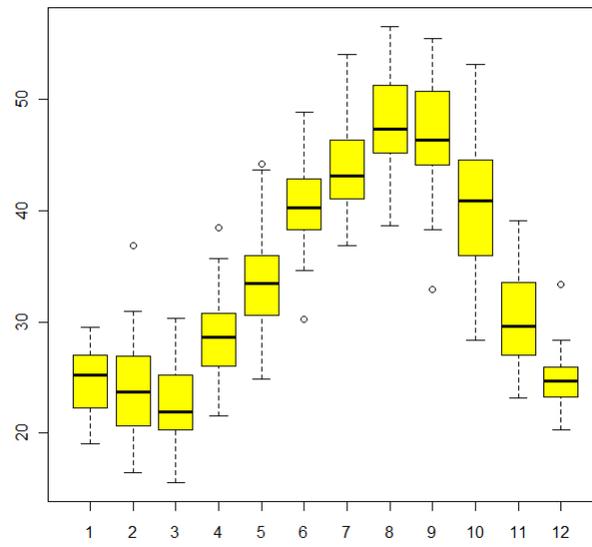


Gráfico A.9: Boxplot periódico, RS

Parâmetros Estimados

	Ceará			Bahia			Rio Grande do Norte			Rio Grande do Sul		
	valor	erro padrão	t-valor	valor	erro padrão	t-valor	valor	erro padrão	t-valor	valor	erro padrão	t-valor
$\phi_1(1)$	0.12	0.09	1.42	-0.12	0.19	-0.61	0.16	0.15	1.04	0.36	0.17	2.17
$\phi_1(2)$	0.70	0.17	4.25	0.72	0.18	3.96	0.39	0.12	3.10	0.28	0.25	1.12
$\phi_1(3)$	0.54	0.11	5.12	0.60	0.23	2.61	0.91	0.25	3.58	0.17	0.13	1.33
$\phi_1(4)$	0.33	0.14	2.43	0.35	0.15	2.39	0.32	0.18	1.81	-0.34	0.23	-1.49
$\phi_2(1)$	-0.56	0.18	-3.16	0.18	0.05	3.27	0.05	0.10	0.50	-0.03	0.09	-0.30
$\phi_2(2)$	-0.50	0.08	-6.56	0.41	0.13	3.14	0.35	0.14	2.42	-0.60	0.28	-2.12
$\phi_2(3)$	1.81	1.68	1.08	1.13	0.86	1.31	0.26	0.27	0.96	0.08	0.12	0.61
$\phi_2(4)$	0.63	0.20	3.17	0.24	0.17	1.43	-0.17	0.27	-0.62	-1.07	0.43	-2.50
$c_1(1)$	13.19	3.53	3.74	26.98	6.07	4.44	12.13	6.95	1.75	13.64	6.37	2.14
$c_1(2)$	9.42	3.06	3.08	18.52	4.22	4.39	18.94	2.49	7.60	22.67	7.02	3.23
$c_1(3)$	29.92	2.39	12.50	25.50	8.15	3.13	23.63	6.75	3.50	36.08	3.98	9.06
$c_1(4)$	27.83	5.76	4.83	16.23	6.92	2.34	31.81	8.50	3.74	53.34	9.49	5.62
$c_2(1)$	34.14	6.95	4.91	20.35	1.62	12.56	12.76	4.16	3.07	28.16	3.23	8.71
$c_2(2)$	20.00	0.94	21.33	21.53	3.36	6.42	14.58	2.21	6.60	45.73	7.81	5.86
$c_2(3)$	12.71	23.34	0.54	8.93	27.39	0.33	37.80	5.44	6.96	33.30	3.67	9.09
$c_2(4)$	11.77	7.58	1.55	19.02	7.68	2.48	49.08	11.76	4.17	72.61	15.23	4.77
$\sigma_1(1)$	14.70	3.86	3.81	4.79	1.42	3.38	14.96	5.28	2.83	8.33	2.45	3.40
$\sigma_1(2)$	12.39	3.25	3.81	3.38	1.10	3.08	3.59	1.43	2.50	15.03	4.41	3.41
$\sigma_1(3)$	6.46	1.70	3.81	6.68	2.08	3.22	5.94	2.09	2.84	5.42	1.78	3.06
$\sigma_1(4)$	6.71	1.76	3.81	4.09	1.23	3.33	5.33	1.90	2.81	6.06	1.80	3.36
$\sigma_2(1)$	0.78	0.55	1.40	2.75	1.25	2.20	15.51	5.40	2.87	10.75	4.93	2.18
$\sigma_2(2)$	0.06	0.04	1.39	0.84	0.44	1.90	5.42	1.90	2.86	8.52	3.87	2.20
$\sigma_2(3)$	8.15	5.82	1.40	11.94	5.48	2.18	9.08	3.15	2.88	1.85	0.84	2.20
$\sigma_2(4)$	1.61	1.15	1.40	3.90	1.91	2.04	11.69	4.08	2.87	3.15	1.58	1.99
$P_{1,2}$	0.10	0.06	1.78	0.30	0.10	2.94	0.10	0.07	1.37	0.28	0.10	2.88
$P_{2,1}$	0.75	0.21	3.54	0.69	0.16	4.29	0.11	0.08	1.35	0.68	0.16	4.30

Tabela A.1: Parâmetros estimados para as quatro séries.