

6

Resultados

Apresenta-se neste capítulo a escolha do melhor modelo para cada técnica de modelagem empregada, além da avaliação deste quanto ao ajuste dentro da amostra (in sample) e fora da amostra (out of sample). No último tópico é feita a comparação e escolha do melhor modelo para a realização da previsão da média diária de temperatura, tendo como foco a escolha do *fair strike* para a precificação do derivativo climático. Para se chegar a melhor estimativa do *strike* para a precificação do derivativo é necessário calcular os graus-dia para cada dia da previsão e fazer o somatório para o período desejado. Como exemplo, se o período do contrato compreender o mês de dezembro de 2005, basta somar os DD obtidos da previsão, de 01/12/2005 a 31/12/2005, como explicado em detalhes no Capítulo 3.

Para finalizar a precificação, além dos dados do contrato e da definição de um nível de *strike*, falta a definição do valor do *tick* e do prêmio. O *tick* é diretamente dependente da exposição climática de cada companhia e, conseqüentemente, do impacto financeiro que uma situação adversa do clima pode causar. Há também diversas metodologias que envolvem a quantificação do prêmio, principalmente para *calls* e *puts*, no entanto foge do escopo deste estudo que foca a previsão da série relacionada ao clima. Uma boa referência bibliográfica para a definição do valor do prêmio dos contratos de derivativos é Jewson, 2005.

A série temporal utilizada para a realização de previsões foi a temperatura média diária, em graus Celsius da cidade do Rio de Janeiro. O período de dados utilizado para a construção do modelo compreende três anos e um mês, de 01/10/2002 a 31/10/2005, e o período utilizado para validação do modelo se estende de 01/11/2005 a 31/01/2006. Os *softwares* computacionais utilizados para suporte na estimação dos modelos foram o Matlab, Forecast-Pro e o Econometric-views.

6.1

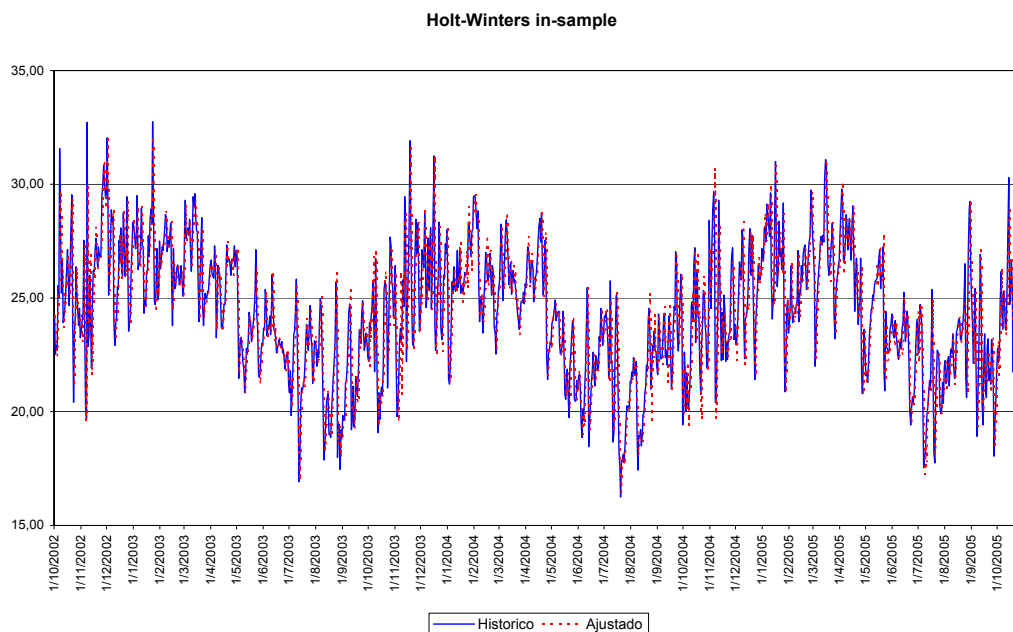
Modelo Holt-Winters

O melhor modelo escolhido para a previsão pela metodologia de Holt-Winters não possui tendência, é multiplicativo e apresenta sazonalidade. Assim como foi constatado pela análise gráfica da série de temperatura média, a tendência não se mostrou significativa para o modelo. Dessa forma o modelo encontrado reflete a seguinte equação, com os coeficientes sazonais expostos em anexo, pois foram gerados 365 fatores sazonais correspondentes a cada dia do ano.

$$Z_t = (21,418) * \rho_t + \varepsilon_t$$

O modelo apresenta um ajuste razoável aos dados, como pode ser observado pelo Gráfico 4 e pelas estatísticas do modelo apresentadas no Quadro 2.

Gráfico 4 – Ajuste do modelo Holt-Winters na amostra.




Quadro 2 – Estatísticas do modelo Holt-Winters na amostra

Estatísticas HW - In Sample	
Observações	1.127
Média	24,360
Desvio Padrão	2,727
R² Ajustado	0,655
MAPE	0,048
RMSE	1,600
MAD	1,155

Assim como o ajuste dentro da amostra não foi tão bom, a comparação das previsões com os valores reais não apresentou um ajuste perfeito, como pode ser visualizado no Gráfico5 e pelas estatísticas apresentadas no Quadro 3.

Gráfico 5 – Ajuste do modelo Holt-Winters fora da amostra.



Quadro 3 – Estatísticas do modelo Holt-Winters fora da amostra

Estatísticas HW - Out of Sample	
Observações	92
Média	25,515
Desvio Padrão	2,347
MAPE	0,055
RMSE	1,805
MAD	1,395

6.2

Modelo Box & Jenkins

Para a escolha do melhor modelo pela metodologia de Box & Jenkins foram analisadas as autocorrelações e autocorrelações parciais da série além realização de testes e da comparação das estatísticas dos modelos testados. Foram realizados os testes de sobrefixação e de ruídos e as estatísticas comparadas foram o MAPE, MAD, RMSE, R2 Ajustado, BIC (Bayesian Information Criterion) e AIC (Akaike Information Criterion).

Pelos gráficos de autocorrelação e autocorrelação parcial (Gráficos 6 e 7) percebemos que a série possui um forte componente sazonal e alta autocorrelação no 1º *Lag*.

Gráfico 6 – Função de autocorrelação da série.


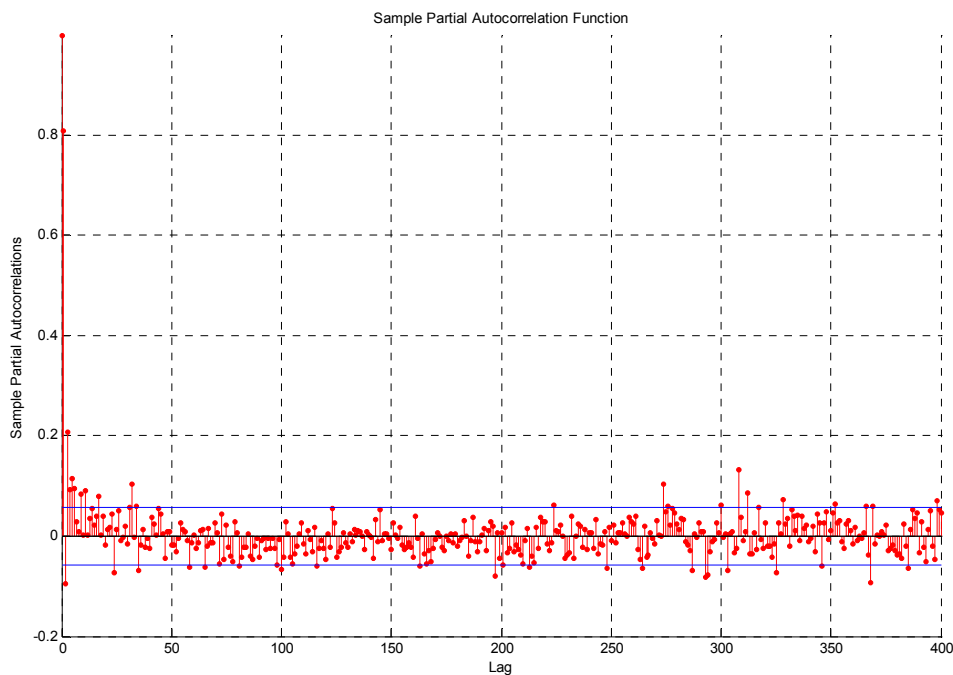


Gráfico 7 – Função de autocorrelação parcial da série.



O melhor modelo foi encontrado na configuração SARIMA (1,1,1)(1,1,1), com a aplicação de uma diferenciação simples e uma diferenciação sazonal na série. Também foram encontrados um componente autorregressivo e um média móvel, tanto na parte simples como na sazonal. Os coeficientes encontrados para os parâmetros do modelo e as estatísticas do modelo estão apresentadas nos Quadros 4 e 5. As autocorrelações e autocorrelações parciais dos erros estão representadas nos Gráficos 8 e 9, respectivamente.

Quadro 4 – Coeficientes do modelo SARIMA

SARIMA (1,1,1)(1,1,1)				
Termo	Coeficiente	Desv. Pad.	Estat. T	Signif.
<i>p</i>	0,732	0,050	14,604	1,000
<i>q</i>	0,928	0,037	25,317	1,000
<i>P</i>	-0,984	0,007	-140,437	1,000
<i>Q</i>	-0,719	0,019	-38,158	1,000

Gráfico 8 – Função de autocorrelação dos erros do modelo.


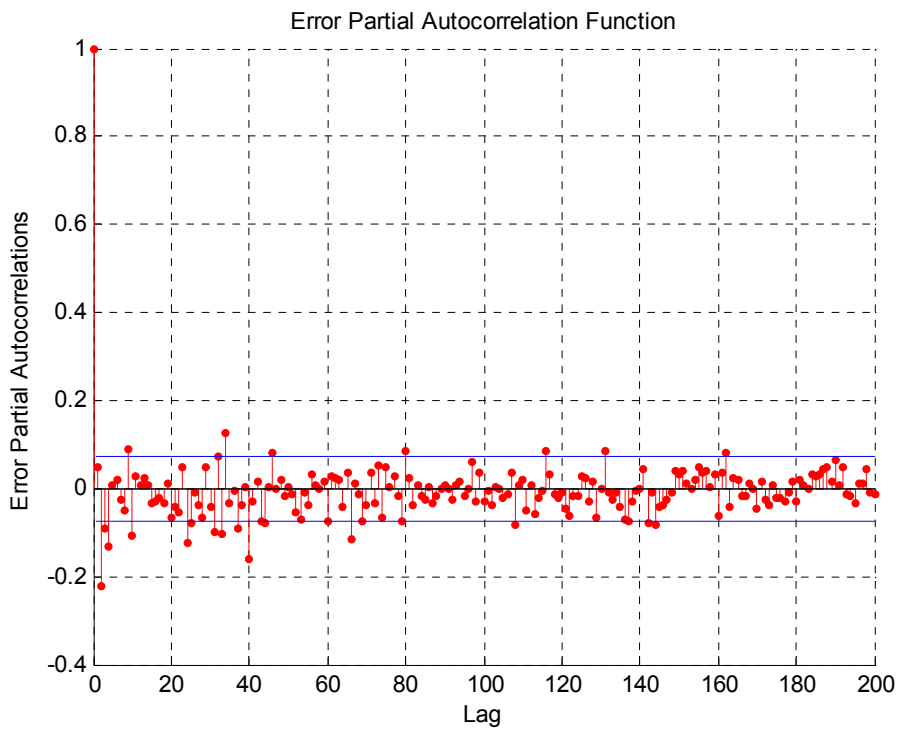


Gráfico 9 – Função de autocorrelação parcial dos erros do modelo.




Quadro 5 – Estatísticas do modelo SARIMA na amostra.

Estatísticas SARIMA(1,1,1)(1,1,1) - In Sample	
Observações	1.127
Média	24,360
Desvio Padrão	2,727
R² Ajustado	0,764
MAPE	0,039
RMSE	1,530
MAD	1,094

O ajuste do modelo à série pode ser observado no gráfico 10.

Gráfico 10 – Ajuste do modelo SARIMA na amostra.

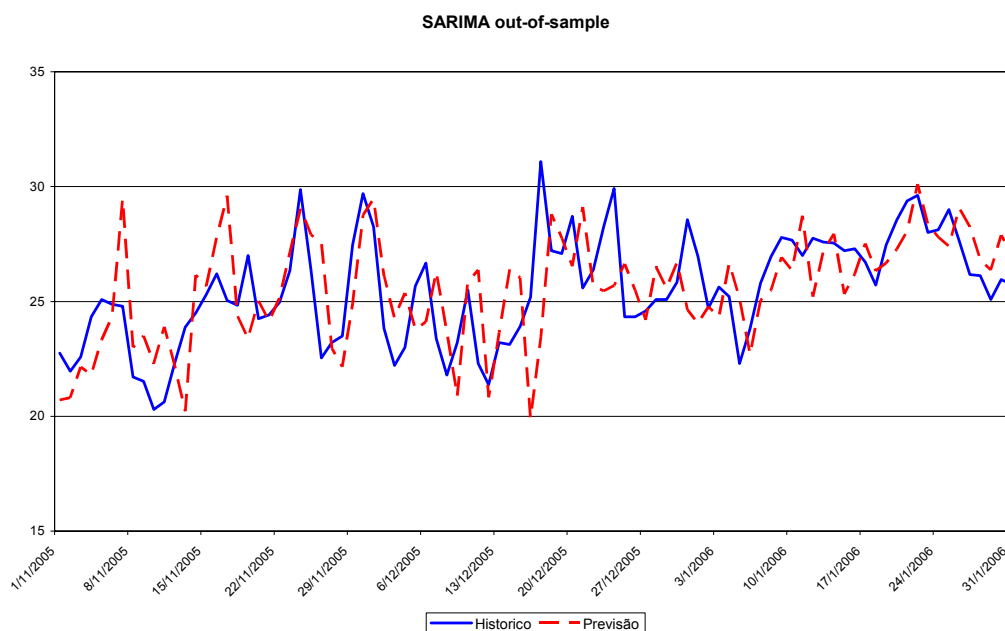


Pela inspeção gráfica e pela análise das estatísticas do modelo podemos perceber que o modelo apresentou um bom ajuste aos dados na amostra e que todos os parâmetros estimados foram bastante significativos para o modelo. No entanto, fora da amostra, o ajuste não foi tão bom como podemos ver pelas estatísticas no Quadro 6 e pelo ajuste no Gráfico 11.

Quadro 6 – Estatísticas do ajuste do modelo SARIMA fora da amostra.

Estatísticas SARIMA - Out of Sample	
Observações	92
Média	25,515
Desvio Padrão	2,347
MAPE	0,068
RMSE	2,204
MAD	1,741

Gráfico 11 – Ajuste do modelo SARIMA fora da amostra.



PUC-Rio - Certificação Digital Nº 0410264/CA

6.3


Modelo pela Transformação de Fourier

No desenvolvimento do modelo de regressão, onde utilizou-se a transformação de Fourier para capturar adequadamente a volatilidade sazonal e os termos GARCH para captar o que restou da volatilidade padrão persistente, foram estimados 13 parâmetros. A especificação do melhor modelo obtido apresenta um termo constante, um termo autorregressivo, 8 coeficientes para capturar a sazonalidade (referentes aos senos e cossenos de 2π , 4π , 6π e 8π utilizados no domínio da frequência.) e três parâmetros referentes a equação da variância.

Utilizou-se como plataforma computacional para a estimação do modelo o software econométrico E-views.

O modelo aparenta capturar bem as variações e a sazonalidade da série, como pode ser observado pelo ajuste do modelo na amostra no gráfico 12 e pelas estatísticas no quadro 7. Assim como no modelo de Holt-Winters a tendência não se mostrou significativa para o modelo.

Gráfico 12 – Ajuste do modelo de Fourier na amostra.



Quadro 7 – Estatísticas do modelo de Fourier na amostra.

Estatísticas Fourier - In Sample	
Observações	1.128
Média	24,360
Desvio Padrão	2,727
R ² Ajustado	0,793
MAPE	0,031
RMSE	1,239
MAD	0,704

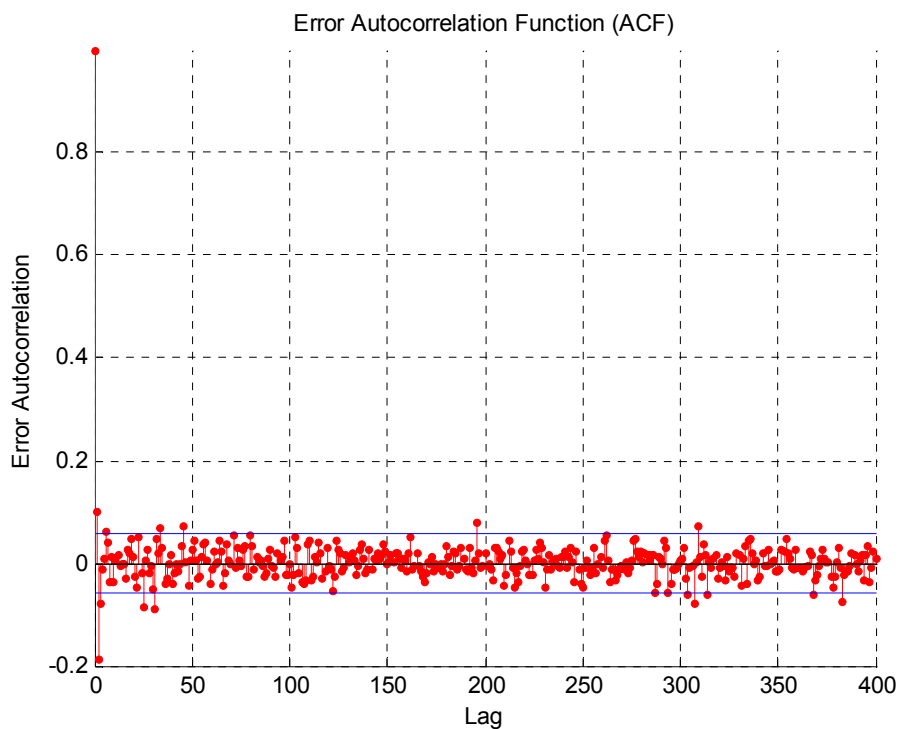
Verificou-se um bom ajuste do modelo aos dados na amostra. Este modelo contém os componentes de sazonalidade e ciclo, sendo este representado por uma função degrau com ciclos de 365 dias. A captura dos componentes cíclicos de

curto-prazo é feita pela utilização de um *lag* autorregressivo. Aproxima-se a componente de volatilidade sazonal usando a série de Fourier e o componente cíclico da variância usando um processo GARCH. Os coeficientes do modelo são apresentados no Quadro 8 e a autocorrelação dos resíduos do modelo no Gráfico 13. A identificação da necessidade de se utilizar 4 harmônicas e do modelo para a variância GARCH(1,1) foi verificada a partir da análise espectral e da estatística de Durbin-Watson, respectivamente.

Quadro 8 – Coeficientes do modelo de Fourier.

Fourier			
Termo	Coeficiente	Desv. Pad.	Signif.
C(1)	7,251	0,629	0,000
C(2)	0,683	0,082	0,000
C(3)	0,354	0,073	0,000
C(4)	-0,057	0,057	0,031
C(5)	-0,056	0,063	0,038
C(6)	-0,021	0,064	0,045
C(7)	-0,032	0,055	0,056
C(8)	0,084	0,056	0,132
C(9)	0,019	0,063	0,059
C(10)	0,703	0,026	0,000
Equação da Variância			
C	0,435	0,099	0,000
ARCH(1)	0,271	0,051	0,000
GARCH(1)	0,570	0,066	0,000

Gráfico 13 – Função de autocorrelação dos resíduos do modelo.




Na análise fora da amostra o modelo também apresentou um bom ajuste e baixo MAPE, como podemos perceber pelo Quadro 9 e pelo Gráfico 14.

Quadro 9 – Estatísticas do modelo de Fourier fora da amostra.

Estatísticas Fourier - Out of Sample	
Observações	92
Média	25,515
Desvio Padrão	2,347
MAPE	0,048
RMSE	1,688
MAD	1,233

Gráfico 14 – Ajuste do modelo de Fourier fora da amostra.



6.4.

Comparação entre os modelos

Após a análise das três metodologias escolhidas para a construção da série temporal de temperatura média pode-se perceber que o modelo que apresentou os melhores ajustes dentro e fora da amostra foi o modelo de regressão com a transformação de Fourier. Como pode-se perceber pelos Quadros 10 e 11.

Quadro 10 – Comparação das estatísticas dos modelos na amostra.

Comparação dos Modelos - In Sample			
	Holt-Winters	SARIMA(1,1,1)(1,1,1)	Transf. Fourier
Observações	1.127		
Média	24,360		
Desvio Padrão	2,727		
R2 Ajustado	0,655	0,764	0,793
MAPE	0,048	0,039	0,031
RMSE	1,600	1,530	1,239
MAD	1,155	1,094	0,704

Quadro 11 – Comparação das estatísticas dos modelos fora da amostra.

Comparação dos Modelos - Out of Sample			
	Holt-Winters	SARIMA(1,1,1)(1,1,1)	Transf. Fourier
Observações	92		
Média	25,515		
Desvio Padrão	2,347		
MAPE	0,055	0,068	0,048
RMSE	1,805	2,204	1,688
MAD	1,395	1,741	1,233

Entre os três modelos, o de Holt-Winters obteve o pior ajuste na amostra, como era esperado devido a sua estrutura demasiadamente simples. No entanto conseguiu resultados melhores que o modelo SARIMA fora da amostra, onde reside o foco principal deste estudo. Já o modelo SARIMA, estimado pela metodologia de Box & Jenkins, obteve o pior ajuste fora da amostra, mesmo tendo conseguido um bom ajuste aos dados da amostra.

O modelo pela transformação de Fourier obteve os melhores ajustes dentro e fora da amostra, como esperava-se devido a maior complexidade do modelo. O modelo obteve um ajuste similar e em alguns casos um pouco inferior aos modelos utilizados para a precificação de derivativos climáticos pesquisados nos artigos sobre o assunto. Entretanto cabe ressaltar que este estudo contou com pouco mais de três anos de observações devido a extrema dificuldade de se obter históricos de dados no Brasil, enquanto que em outros países nos quais são realizados estudos similares são utilizados de 5 a 30 anos de observações.

Com a escolha do melhor modelo feita, parte-se agora para a aplicação das previsões feitas pelo modelo da Transformação de Fourier no índice de Cooling Degree Days e a comparação deste com os dados reais, como pode ser visto no Quadro 12 e no Gráfico 15. O valor do CDD mensal foi obtido pelo somatório dos CDD diários de cada mês, como explicado na metodologia.

Percebe-se que o erro foi bem pequeno na previsão para os meses de novembro de 2005 e de janeiro de 2006 e para o mês de dezembro de 2005 o erro ficou próximo do que era esperado dada as estatísticas prévias do modelo. Isto demonstra o bom ajuste e o potencial de aproveitamento deste modelo para compor a precificação dos derivativos climáticos.

Quadro 12 – Comparação da previsão do CDD Mensal.

Comparação da Previsão do CDD Mensal			
	Série Original	Transf. Fourier	Erro
<i>novembro-05</i>	192.26	194.30	1.063%
<i>dezembro-05</i>	226.63	236.71	4.449%
<i>janeiro-06</i>	272.45	273.57	0.412%

Gráfico 15 – Comparação da previsão do CDD Mensal.

