

Previsão de precipitação e temperatura em Santa Maria por meio de um modelo estatístico

Adriano Mendonça Souza¹, Roberta Georgen²,
Simone Erotildes Teleginski Ferraz³

¹Departamento de Estatística, ²Curso de Especialização em Estatística e Modelagem Quantitativa, ³Departamento de Física/CCNE
Universidade Federal de Santa Maria, RS
e-mail: amsouza@smaail.ufsm.br

Abstract

The ability of forecasting the meteorological variable characteristics have been a goal in several studies for a long time. Many methods were and have been used in the elaboration of climate forecasting, and they have been made by dynamic and statistic models. At this research the characteristics of temperature and precipitation series will be analyzed in the central region of Rio Grande do Sul and, a statistical model will be proposed by the use of using the Box & Jenkins methodology. For the precipitation series the used data were the ones accumulated in the month and, for the temperature series the used data were the month average, from January 1970 to December 2006. The models suggested were *SARIMA* (0,0,0)(0,1,1)₁₂ to represent the precipitation and *SARIMA* (1,0,0)(0,1,1)₁₂ to the temperature. The models proposed were able to show the temperature and precipitation behaviors and will be useful for future decisions.

Keywords: Precipitation, Temperature, Central Region, Monthly Forecasting, Box-Jenkins Methodology, Climate.

Resumo

A habilidade de prever as características futuras das variáveis meteorológicas tem sido a meta de muitos estudos ao longo do tempo e vários métodos foram e têm sido utilizados na elaboração de previsões climáticas, as quais são realizadas com modelos dinâmicos e estatísticos. Nesta pesquisa será realizada uma análise das características das séries de precipitação e temperatura da região central do Rio Grande do Sul e será proposto um modelo de previsão estatística, utilizando a metodologia Box & Jenkins. Para as séries de precipitação utilizou-se o acumulado do mês e a média mensal para temperatura, do período de janeiro de 1970 a dezembro

de 2006. Os modelos encontrados foram um $SARIMA (0,0,0)(0,1,1)_{12}$ para a série precipitação e um $SARIMA (1,0,0)(0,1,1)_{12}$ para a série Temperatura. Os modelos propostos foram capazes de refletir a realidade e serão úteis para futuras tomadas de decisões.

Palavras chave: Precipitação, Temperatura, Região central, Previsão mensal, Metodologia Box – Jenkins, Clima

1. Introdução

Um dos fatores causadores das variações na temperatura são os fenômenos climáticos. Villarroel et al. (2006) observou que sobre a costa oeste da América do Sul extratropical houve uma mudança no regime da temperatura após a metade dos anos 70, associada como a troca de fase negativo-positiva da Oscilação Decadal do Pacífico.

O El Niño é outro indicador da tendência da temperatura causando efeito tanto regional como global (Halpert e Ropelewski, 1992).

Pequenas mudanças nas condições médias da atmosfera podem levar a grande mudança na frequência de eventos extremos. Estudos da temperatura máxima e mínima da Argentina mostram a ocorrência de uma importante diminuição da amplitude térmica anual e também uma tendência positiva nos valores da temperatura mínima e na quantidade de dias frios (Rusticucci e Barrucand, 2004; Long e Muller, 2006) (Silveira e Gan, 2006 apud).

A habilidade de prever as características futuras das variáveis meteorológicas tem sido a meta de muitos estudos ao longo do tempo e vários métodos foram e têm sido utilizados na elaboração de previsões climáticas. Feitas com um adequado grau de precisão, estas previsões proporcionariam aos tomadores de decisão e governos a possibilidade de antecipar e planejar futuras ações dirigidas a setores de atividades socioeconômicas e à sociedade como um todo (Marques *et al.*, 2006).

Previsões climáticas têm sido realizadas com modelos dinâmicos e estatísticos. Feitas com um adequado grau de precisão, estas previsões proporcionariam aos tomadores de decisão e governos a possibilidade de antecipar e planejar futuras ações dirigidas a setores de atividades socioeconômicas e à sociedade como um todo (Marques *et al.*, 2006).

Os modelos dinâmicos são representações matemáticas dos processos físicos que visam simular as distribuições de umidade e energia sobre todo o globo, esses modelos são denominados “Modelos de Circulação Geral da Atmosfera” os quais, têm sido desenvolvidos desde a década de 1950, passando a ser explorados como ferramentas para previsão do clima na década de 1980 (Guetter, 1998).

Os modelos estatísticos de previsão climatológica estabelecem rela-

ções estatisticamente significativas entre variáveis meteorológicas locais em áreas continentais, com preditores locais e remotos. (Marques *et al*, 2006).

O Rio Grande do Sul é uma região preponderantemente agropecuária e situa-se numa região de clima subtropical, com grandes variações de temperatura e precipitação anuais. Deste modo, é importante entender como se comporta tanto a precipitação quanto a temperatura nesta região, de maneira a conhecê-la e prevê-la mais adequadamente.

Nesta pesquisa será realizada uma análise descritiva das características das séries de precipitação e temperatura da região central do Rio Grande do Sul. Além disso, será proposto um modelo de previsão estatística para estes dois parâmetros, utilizando a metodologia Box & Jenkins.

2. Dados e metodologia

2.1 Dados

A série de dados utilizada neste estudo é oriunda da rodada climática de controle de um modelo global acoplado de previsão gentilmente cedido pelo “British Atmospheric Data Centre – BADC”, conforme mostra a Figura 1. Maiores informações a respeito do modelo podem ser encontradas em <http://badc.nerc.ac.uk/data/hadcm3-control/>.

Para as séries de dados utilizou-se o acumulado do mês para precipitação e a média mensal para temperatura, do período de janeiro de 1970 a dezembro de 2006.

A área central está localizada geograficamente em uma região de depressão central. É constituído de uma zona agrícola de uso intensivo no verão e florestas remanescentes com formações arbóreas densa. Os principais municípios que compõem esta região são: Porto Alegre, Novo Hamburgo, Caxias do Sul, Santa Maria, Santa Cruz do Sul, Bento Gonçalves e Tapes. Sua principal atividade produtora é o plantio de arroz, fumo, frutas e a pesca.

2.2 Metodologia

Para descrever as variáveis precipitação e temperatura da região central do Rio Grande do Sul foi utilizada, neste trabalho, a modelagem por meio de séries temporais, utilizando-se a metodologia desenvolvida por Box & Jenkins. Inicialmente, realizou-se uma estatística descritiva e a seguir calculou-se a função densidade espectral, para ambas as variáveis. A estatística descritiva tem por objetivo descrever e organizar as informações de um conjunto de dados. Neste trabalho calculou-se a média, a moda, o desvio padrão e o coeficiente de variação.

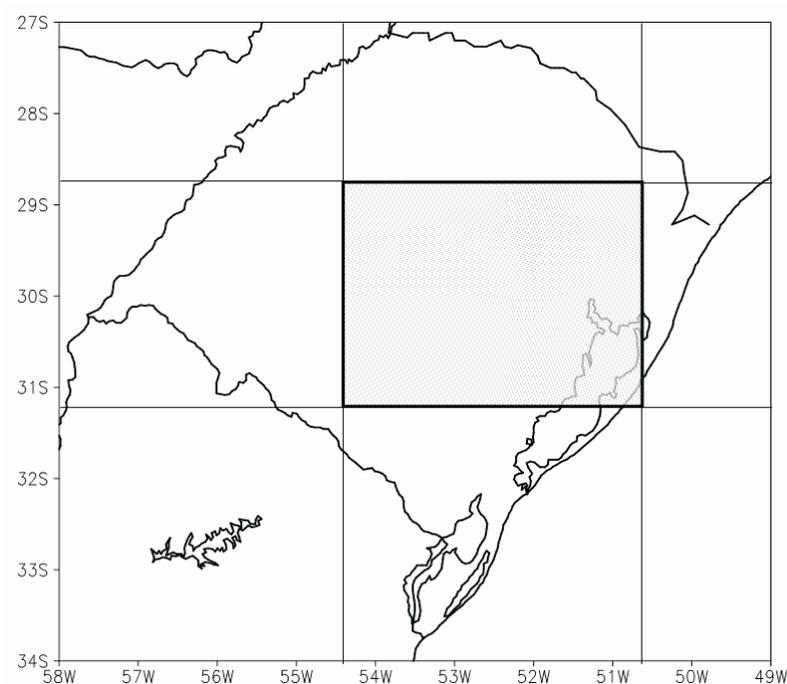


Figura 1. A área hachurada corresponde a região Central do Rio Grande do Sul.

A função densidade espectral de potências foi calculada e é útil para detectar periodicidades numa série temporal, ou seja, a presença de ciclos ou oscilações e suas frequências. Uma das maneiras de se calcular a densidade espectral de potências consiste em usar o Teorema de Wiener Khinchin, (Jenkins e Watts, 1968).

Após a descrição inicial dos dados o passo seguinte é a modelagem por meio da metodologia Box & Jenkins. Esta tem por objetivo analisar o mecanismo gerador da série temporal, descobrir periodicidades relevantes nos dados, descrever o seu comportamento e fazer previsões de valores futuros da série, em curto prazo ou em longo prazo, neste caso irá se usar a metodologia Box e Jenkins (Box *et al*, 1976, 1994).

Uma série temporal possui três componentes: tendência, sazonalidade e ruído branco ou erro aleatório.

Para tal, serão utilizados os seguintes testes: teste de seqüências, teste do sinal, teste baseado no coeficiente de correlação e o teste de Mann – Kendall (para tendência; Sneyers,1975, Goossens e Berger, 1986). Teste de Kruskal-Wallis, de Friedman e o teste F (para sazonalidade) (Morettin e

Toloi (1987, 2004).

O ruído branco ou erro aleatório compreende a variabilidade intrínseca aos dados e não pode ser modelado, isto é, é tudo aquilo que não é explicado pelas outras componentes da série. Um erro é chamado de ruído branco quando possui distribuição normal, sendo a média de seus componentes zero e a variância constante, os quais são não-correlacionados, indicando assim, que o modelo elaborado conseguiu explicar o máximo da série de dados (Souza, 2006).

A metodologia Box e Jenkins se baseia na construção de um ciclo iterativo. Os estágios do ciclo são: especificação, identificação, estimação, verificação e previsão.

Esta análise é composta de modelos ARIMA, que são modelos estatísticos lineares para análise de séries temporais. Esses modelos são mais sofisticados por usarem a correlação entre as observações. A notação utilizada para designar o modelo ARIMA é $ARIMA(p, d, q)$, em que p é o número de termos auto-regressivos, d é o número de diferenciações para que a série torne-se estacionária e q , é o número de termos de médias móveis. Os termos p , d e q são todos números inteiros maiores ou iguais a zero.

Um modelo auto-regressivo de ordem p , $AR(p)$ é escrito em função de seus valores passados e do ruído branco.

A identificação do modelo será feita através da análise gráfica da Função de Autocorrelação (FAC) e da Função Autocorrelação Parcial (FACP), sendo que é através desta última que podemos identificar a ordem do modelo, conforme a Figura 2.

A FAC decai exponencialmente, alternando ou não de sinal, e a FACP apresenta um corte rápido no *lag* significativo, indicando a ordem p do modelo.

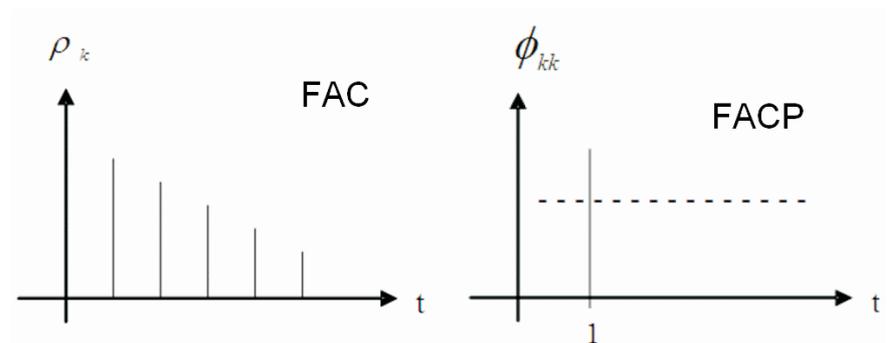


Figura 2. Comportamento da FAC e FACP de um modelo $AR(1)$.

O modelo de médias móveis é definido como a combinação do ruído branco e_t , no período presente e no período passado. Indica-se o modelo de médias móveis por $MA(q)$, em que q indica a ordem do modelo. Pela análise gráfica da FAC e da FACP é feita a identificação do modelo e é a FAC que fornece a ordem do modelo, conforme a Figura 3.

A FAC apresenta um corte rápido no *lag* significativo, indicando a ordem q do modelo e a função de autocorrelação parcial decai exponencialmente, se todos os parâmetros forem positivos.

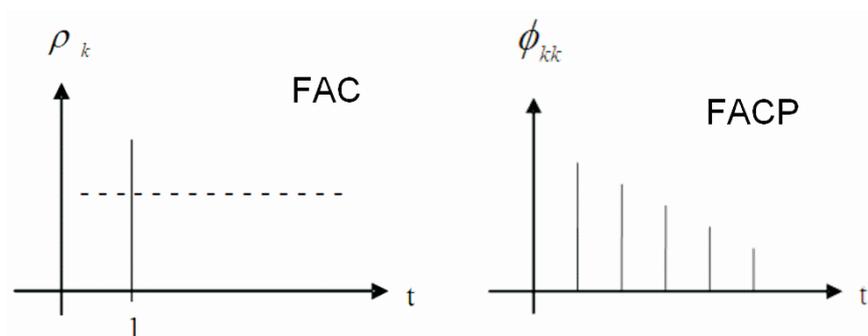


Figura 3. Comportamento da FAC e FACP de um modelo $MA(1)$.

Os modelos sazonais são uma combinação dos modelos *ARIMA* mais a sazonalidade, representado, por *SARIMA* (auto-regressivo integrado sazonal de médias móveis). Esses modelos apresentam uma parte não-sazonal com parâmetros p, d, q , e uma parte sazonal com parâmetros P, D, Q .

Os estágios do ciclo iterativo do método Box e Jenkins são:

- **Identificação do modelo:** nesta fase é pesquisada qual a classe de modelos é adequada ao estudo. As ferramentas mais utilizadas para identificar os parâmetros são a FAC e a FACP.

- **Estimação dos parâmetros:** os métodos utilizados são: por máxima verossimilhança e por mínimos quadrados.

- **Verificação:** existe a possibilidade de encontrarmos vários modelos concorrentes à série temporal, em que somente um deve ser o escolhido. Por isso é necessário estabelecer critérios de decisão, os mais utilizados são: *Akaike Information Criterion* – AIC, e *Schwartz Bayesian Criterion* – SBC.

O critério AIC (Akaike, 1974), estabelece que o modelo ótimo para uma série temporal é aquele que minimiza o AIC. Já o critério SBC (Schwartz, 1978), vem a ser um refinamento do critério AIC, desenvolvido justamente para resolver o problema encontrado nele.

- **Previsão:** obtido o modelo ajustado e, conseqüentemente as estimativas dos parâmetros, parte-se para a utilização do modelo em previsão.

3. Resultados e discussões

A dispersão de um conjunto de dados indica o quanto a série varia em torno de seu valor médio, para tal utilizou-se o coeficiente de variação de Pearson. Quando o valor do coeficiente de variabilidade for menor que 50%, a dispersão dos dados em torno da média aritmética será significativa, ou seja, mais representativa será a média aritmética.

Na região central, o coeficiente de variação (dispersão) de Pearson para a temperatura é significativo, revelando, assim, que para esta variável a média é significativa. Para a precipitação o mesmo não acontece, o coeficiente de variação é não-significativo. Esse resultado era esperado, pois séries médias de temperatura têm muito menor variabilidade do que séries de precipitação, o que é indicado pelo desvio padrão. Conforme mostra o Coeficiente de Variação de Pearson (CVP), a média da série precipitação é pouco representativa, em contrapartida a média da série temperatura a média é representativa, refletindo bem as estações que ocorrem na região, conforme mostrado na Tabela 1.

Tabela 1. Medidas descritivas

Estatísticas	Precipitação (mm)	Temperatura (°C)
Média	82,29	17,39
Moda	68,60	12,20

Como visto anteriormente a análise espectral tem por objetivo mostrar freqüências significativas na série em estudo.

Algumas freqüências são normalmente encontradas quando são analisados dados meteorológicos, são elas: pico anual (freqüência de 1 ano) ou semi-anual (pico de 6 meses). Outras comumente encontradas são aquelas em escala bem rápida (2 a 10 dias) relacionadas a eventos como ondas de leste ou frente frias, sendo este último muito importante na região de estudo.

Freqüências mais lentas também muitas vezes aparecem em dados meteorológicos, por exemplo, aquelas relacionadas com fenômenos El Niño cujo período de atuação pode variar de 2 a 7 anos. O estado do Rio Grande do Sul tem a sua precipitação e temperatura fortemente alterada por eventos como este, então se espera que os resultados mostrem o sinal do El Niño em seu espectro.

Além destas podem aparecer freqüências relacionadas a outros fenômenos, como oscilações na escala intra-sazonal (20 a 90 dias) ou escalas temporais muito lentas (10 a 30 anos) (Ferraz, 2000).

Nas análises aqui realizadas foram consideradas duas janelas temporais: 24 meses (para maximizar as freqüências existentes entre 1 mês e 2 anos) e 10 anos. Sendo esta última aplicada a dados filtrados com um filtro passa banda de 15 meses. Isto é, serão retidas apenas freqüências entre 15 meses e 10 anos.

Com um “lag” temporal de 24 meses, o cálculo foi feito apenas com os dados mensais, ou seja, 12 valores por ano.

Pela Figura 4, observa-se que os principais ciclos encontrados para a precipitação são de 12 meses (ciclo anual) e 5 a 3 meses (relacionado a variabilidade intrasazonal). Para a temperatura o pico mais significativo é o ciclo anual.

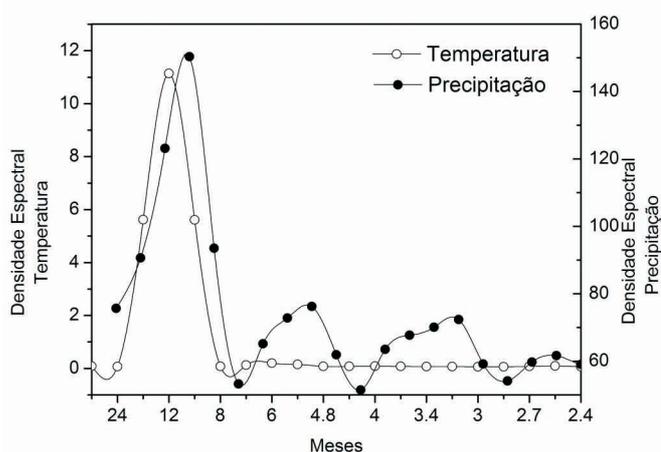


Figura 4. Densidade espectral para precipitação (•) e temperatura (○) com “lag” de 24 meses.

A precipitação do Rio Grande do Sul é fortemente afetada pelo El Niño (Grimm et al, 1998). Sem os ciclos menores que um ano sobressai essa variabilidade, visto que o ciclo relacionado a este evento é o mais intenso (Figura 5) seguido do ciclo de dois anos (quasi bienal). Para a temperatura, os picos significativos são de 6,7 anos (possivelmente relacionado ao El Niño) e 1,5 anos (quase bienal).

Objetivando verificar a existência de tendência na série foi aplicado o Teste do Sinal (Cox-Stuart). Considerando um nível de significância $\alpha = 5\%$, encontra-se $p = 0,000$. Como $p < \alpha$, rejeita-se a hipótese nula, logo a tendência é significativa na série.

O teste não-paramétrico de Kruskal-Wallis, também foi realizado para examinar se existe sazonalidade na série. Para $\alpha = 5\%$, temos $p = 0,2124$, $p > \alpha$, se aceita a hipótese nula, logo a sazonalidade anual não é significativa na série.

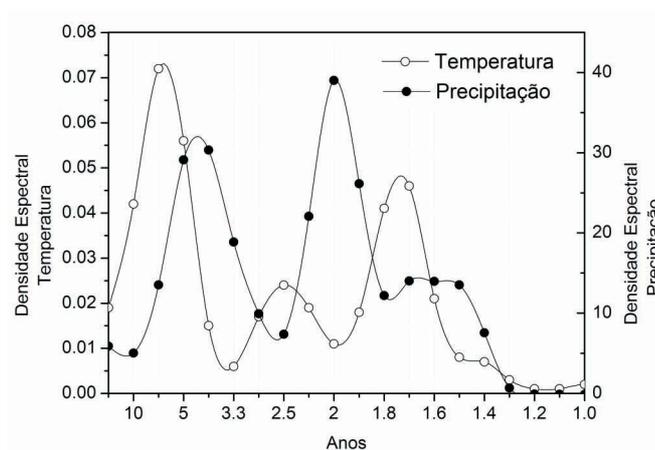


Figura 5. Densidade espectral para precipitação (°) e temperatura (°) com “lag” de 120 meses

O teste de Mann Kendall foi utilizado para verificar o sinal da tendência (S), para $S > 0$ tendência positiva e para $S < 0$ tendência negativa.

Na Tabela 2 observa-se que no verão a tendência da precipitação é positiva, mas no resto do ano é negativa.

Tabela 2. Teste de Mann Kendall para a precipitação.

Estação	S (precipitação)
Verão	20
Outono	-98
Inverno	-140
Primavera	-155

Desse modo os modelos encontrados para a precipitação estão descritos na Tabela 3, sendo: ϕ_n : a estimativa dos parâmetros e E: erro

padrão, vale lembrar que para todos os modelos os parâmetros foram significativos com $p = 0,0000$.

Tabela 3. Modelos SARIMA significativos para a precipitação.

Modelos	Parâmetros	E	AIC	SBC
(1,0,1)(0,1,1) ₁₂	$\phi_1 = +0,7469$	0,1647		
	$\theta_1 = +0,7033$	1,1734	2212,88	2225,09
	$\Theta_1 = +0,8509$	0,0247		
(0,0,0)(0,1,1) ₁₂	$\Theta_1 = +0,8543$	0,0241	2210,73	2214,79
(0,1,1)(0,1,1) ₁₂	$\theta_1 = +0,8887$	0,0233		
	$\Theta_1 = +0,8348$	0,0265	2237,84	2245,98
(1,1,2)(0,1,1) ₁₂	$\phi_1 = -0,9736$	0,0178		
	$\theta_1 = -0,1171$	0,0245		
	$\theta_2 = +0,8675$	0,0237	5932,26	5948,53
	$\Theta_1 = +0,8229$	0,0276		
(2,0,2)(0,1,1) ₁₂	$\phi_1 = +1,3655$	0,1906		
	$\phi_2 = -0,6726$	0,1516		
	$\theta_1 = +1,3836$	0,1655	2210,94	2229,28
	$\theta_2 = -0,7514$	0,1253		
	$\Theta_1 = +0,8523$	0,0252		

O modelo mais adequado é um $SARIMA(0,0,0)(0,1,1)_{12}$, identificado assim pelo menor AIC e SBC.

Escrevendo o modelo encontrado, temos que a precipitação pode ser representada por:

$$(1 - B)Z_t = (1 - 0,8534B^{12})e_t$$

Identificando o melhor modelo, pode se realizar as previsões da série. Na Tabela 4 é apresentada a previsão para o ano de 2007. As duas últimas colunas correspondem ao limite inferior e superior a um nível de 95% (respectivamente), estimados pelo modelo.

Na Figura 6 pode-se observar graficamente o valor da previsão comparado ao valor real para os meses de janeiro a dezembro de 2007. O

modelo captou somente a componente sazonal de médias móveis, ou seja, estimou o parâmetro apenas pelo erro, o que pode ser observado no detrimento das previsões. O mês de julho apresentou valor real fora do limite inferior de confiabilidade calculado pelo modelo.

Tabela 4. Previsão da Precipitação para o ano de 2007

Meses	Previsão	Valor Real	Inferior	Superior
Jan/07	86,11	108,54	25,42	291,76
Fev/07	91,15	39,19	26,90	308,84
Mar/07	67,32	138,33	19,87	228,10
Abr/07	57,93	32,28	17,10	196,27
Mai/07	52,49	59,62	15,49	177,86
Jun/07	40,70	14,64	12,01	137,91
Jul/07	33,95	9,50	10,02	115,04
Ago/07	50,55	85,10	14,92	171,28
Set/07	62,36	131,17	18,41	211,29
Out/07	80,65	124,55	23,80	273,27
Nov/07	87,71	51,23	25,89	297,18
Dez/07	101,01	143,70	29,81	342,24

Por conseguinte analisa-se a variável temperatura. Com o cálculo teste do Sinal (Cox-Stuart), considerando um nível de significância $\alpha = 5\%$, encontra-se $p = 0,000$. Como $p < \alpha$, rejeita-se a hipótese nula, logo a tendência é significativa na série.

Pelo teste não-paramétrico de Kruskal-Wallis, para $\alpha = 5\%$, tem-se $p = 1,000$, $p > \alpha$, aceita-se a hipótese nula, logo a sazonalidade anual não é significativa na série.

Na variável temperatura observa-se comportamento contrário, no verão tem-se tendência negativa e no outono, no inverno e na primavera a tendência é positiva, segundo o teste de Mann Kendall apresentado na Tabela 5.

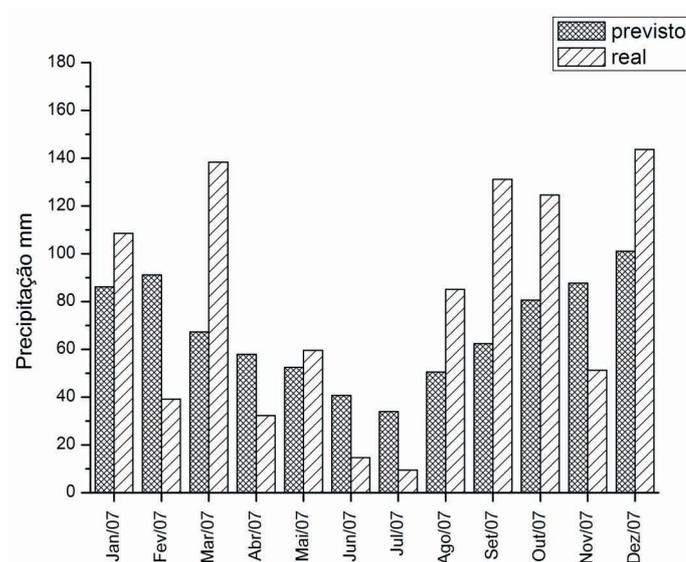


Figura 6. Previsão da precipitação para o ano de 2007.

Tabela 5 .Teste de Mann Kendall para a temperatura.

Estação	S (precipitação)
Verão	-46
Outono	7
Inverno	198
Primavera	112

Na Tabela 6, observa-se os modelos encontrados para a temperatura, em que o modelo mais adequado é um $SARIMA (1,0,0) (0,1,1)_{12}$, identificado assim pelo menor AIC e SBC.

A expressão do modelo encontrado, para a temperatura é representado por:

$$(1 - B)(1 - 0,1984B)Z_t = (1 - 0,8492B^{12})e_t$$

Baseado neste modelo foi feita a previsão para o ano de 2007, conforme mostra a Tabela 7.

Tabela 6 . Modelos SARIMA significativos para a temperatura.

Modelos	Parâmetros	E	AIC	SBC
(1,1,1)(0,1,1) ₁₂	$\phi_1 = +0,1854$	0,0487	746,62	758,81
	$\theta_1 = +0,9751$	0,0093		
	$\Theta_1 = +0,8572$	0,0244		
(0,0,1)(0,1,1) ₁₂	$\phi_1 = -0,1921$	0,0468	741,86	750,00
	$\Theta_1 = +0,8475$	0,0239		
(1,0,0)(0,1,1) ₁₂	$\theta_1 = +0,1984$	0,0476	741,14	749,27
	$\Theta_1 = +0,8492$	0,0238		
(0,1,2)(0,1,1) ₁₂	$\theta_1 = 0,7922$	0,0472	746,96	759,16
	$\theta_2 = +0,1768$	0,0469		
	$\Theta_1 = +0,8574$	0,0245		
(0,1,1)(0,1,1) ₁₂	$\theta_1 = +0,9660$	0,0139	758,98	767,11
	$\Theta_1 = +0,8575$	0,0244		

Tabela 7. Previsão da Temperatura para o ano de 2007

Meses	Previsão	Valor Real	Inferior	Superior
Jan/07	24,03	24,74	19,23	30,01
Fev/07	23,96	25,95	19,10	30,06
Mar/07	21,91	22,50	17,46	27,50
Abr/07	18,13	17,67	14,45	22,75
Mai/07	13,24	17,87	10,55	16,61
Jun/07	10,74	13,15	8,56	13,48
Jul/07	9,82	7,48	7,83	12,32
Ago/07	12,70	11,16	10,12	15,93
Set/07	14,98	14,23	11,93	18,79
Out/07	17,31	16,29	13,79	21,72
Nov/07	20,68	17,94	16,48	25,95
Dez/07	22,71	21,44	18,10	28,50

Na Figura 7, observa-se o gráfico das previsões da temperatura para os meses de janeiro a dezembro de 2007.

No caso da temperatura o modelo captou a parte autoregressiva da série o que resultou numa previsão melhor do que no caso da precipitação.

Esta região situa-se no centro do Estado do Rio Grande do Sul, com diversos tipos de culturas, portanto as previsões encontradas poderão ser favoráveis para os agricultores, pois as estimativas foram executadas por meio de uma ferramenta muito criteriosa.

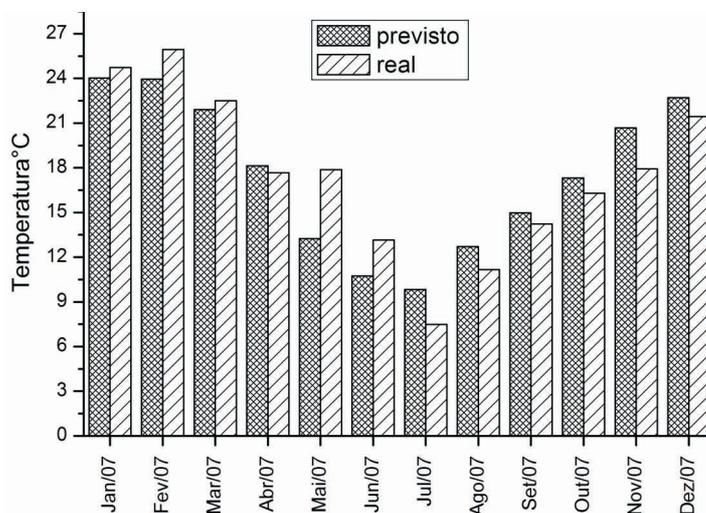


Figura 7. Previsão da precipitação para o ano de 2007.

4. Conclusão

A análise descritiva mostrou que a média é representativa para os dados de temperatura, pois esses dados apresentam pouca variabilidade, logo há homogeneidade nos dados. O contrário acontece para os dados da precipitação. Isto sugere que um modelo levando em conta a média apresentará melhores resultados para a temperatura do que para a precipitação.

O teste de Mann Kendall mostrou que no verão a tendência é positiva para a precipitação e negativa para a temperatura. No outono, no inverno e na primavera a tendência é negativa para a precipitação e é positiva para a temperatura, nestas mesmas estações do ano.

Nesta pesquisa será realizada uma análise das características das séries de precipitação e temperatura da região central do Rio Grande do Sul

e será proposto um modelo de previsão estatística, utilizando a metodologia Box & Jenkins.

Sugerindo que o melhor modelo encontrado para a precipitação foi ineficiente na detecção da maior parte da variabilidade. Uma possível solução seria utilizar modelos com memória longa, chamados *ARFIMA*. Estes são modelos em que às funções de autocorrelações da série original indicam não estacionariedade, com decaimento lento, cuja análise necessita de uma diferença fracionária. Em exemplo de uso deste tipo de modelo na análise da aparente tendência crescente em temperaturas globais devido ao efeito estufa (Seater, 1993).

5. Bibliografia

BOX, G. E. P.; TIAO, G. C. *Comparison of forecast and actuality*. Applied Statistica, p. 195 – 200, 1976.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. *Time Series Analysis: Forecasting and Control*. Third Edition. Englewood: Prentice Hall, 1994.

FERRAZ, S. E. T. *Oscilações intrasazonais no sul e sudeste do Brasil durante o verão*. Dissertação (Mestrado em Meteorologia) - Instituto Astronômico e Geofísico. São Paulo: Universidade de São Paulo, 2000.

GOOSSENS, C.; BERGER, A. *Annual and seasonal climatic variations over the northern hemisphere and Europe during the last century*. Annales Geophysicae, Berlin, v. 4, n. B4, p. 385-400, 1986.

GRIMM, A.M.; FERRAZ, S.E.T.; GOMES, J. *Precipitation anomalies in Southern Brazil associated with El Niño and La Niña events*. Journal of Climate, Boston, v. 11, p. 2863-2880, 1998.

GUETTER, A. K. *Associação entre a temperatura mínima no Paraná e o Niño-3*. CBMET, 10, Brasília, 1998.

HALPERT, M. S.; ROPELEWSKI, C. F. *Surface temperature patterns associated with the Southern Oscillation*. Journal of Climate, Boston, v. 5, p. 577-593, 1992.

JENKINS, G. M.; WATTS, D. G. *Spectral Analysis and its applications*. Holden-Day, p. 525, 1968.

LONG, M.E.F.; MULLER, G. V. *Annual and Monthly Trends in Fronts Days in the West Pampa*. 8th International Conference on Southern Hemisphere Meteorology and Oceanography, Foz do Iguaçu, 2006, p. 249-253.

- MARQUES, J. R.; DINIZ, G.; ASSIS, S. V.; ARAUJO, S. M. B.; SALDANHA, R. *Desenvolvimento e implementação de um modelo estatístico de previsão climatológica de temperaturas máxima para regiões do estado do Rio Grande do Sul*. In: XIV Congresso Brasileiro de Meteorologia, 2006, Florianópolis. XIV Congresso Brasileiro de Meteorologia. Rio de Janeiro: Sociedade Brasileira de Meteorologia, 2006.
- MORETTIN, P. A. ; TOLOI, C. M. C. *Previsão de Séries Temporais*. 2ª edição, São Paulo: Atual, 1987.
- MORETTIN, P. A. ; TOLOI, C. M. C. *Análise de Séries Temporais*. 1ª edição, São Paulo: E. Blücher, 2004.
- RUSTICUCCI, M.,; BARRUCAND, M. *Changes in Temperature extremes over Argentina*. *Journal of Climate*, Boston, v. 17, p. 269-284, 2004.
- SEATER, J. J. *World Temperature-Trend Uncertainties and Their Implications for Economic Policy*. *Journal of Business and Economic Statistics*, v. 11, p. 265-277, 1993.
- SNEYERS, R. *On the Statistical Analysis of Series of Observations*, Technical Note, 143, WMO n° 415, p. 189, 1975.
- SILVEIRA, P. V.; GAN A. *Estudo de tendência das temperaturas mínimas na região sul do Brasil*. XIV Congresso Brasileiro de Meteorologia – CBMET, Florianópolis, 2006.
- SOUZA, F. M. *Modelos Box e Jenkins Aplicados a Demanda de Leitos Hospitalares* Monografia (Especialização em Estatística e Modelagem Quantitativa) – Departamento de Estatística. Santa Maria: Universidade Federal de Santa Maria, 2006.
- UK Meteorological Office, Hadley Centre. HadCM3 Control Run Model Data, [Internet]. British Atmospheric Data Centre, 2006, *Date of citation*. Available from <http://badc.nerc.ac.uk/data/hadcm3-control>. Acesso em 20 mar. 2007.
- VILLARROEL C. P., ROSENBLUTH B., ACEITUNO P. *Climate change along the extratropical west coast of South America (Chile): Daily max/min temperatures*. 8th International Conference on Southern Hemisphere Meteorology and Oceanography, Foz do Iguaçu, 2006, p. 487-489.

Submetido em: 03/11/2008

Aceito em: 18/05/2009