

ROZIANE SOBREIRA DOS SANTOS

**HOMOGENEIDADE E RECONSTRUÇÃO DE SÉRIES CLIMATOLÓGICAS
PARA LOCALIDADES NO ESTADO DE MINAS GERAIS**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Meteorologia Agrícola, para obtenção do título de *Doctor Scientiae*.

VIÇOSA
MINAS GERAIS – BRASIL
2012

**Ficha catalográfica preparada pela Seção de Catalogação e
Classificação da Biblioteca Central da UFV**

T

S237h
2012

Santos, Roziane Sobreira dos, 1981-
Homogeneidade e reconstrução de séries climatológicas
para localidades no estado de Minas Gerais / Roziane Sobreira
dos Santos. – Viçosa, MG, 2012.
xvi, 82f. : il. (algumas col.) ; 29cm.

Orientador: Gilberto Chohaku Sedyama.
Tese (doutorado) - Universidade Federal de Viçosa.
Referências bibliográficas: f. 74-82.

1. Meteorologia agrícola. 2. Climatologia agrícola - Modelos
matemáticos. 3. Análise espacial (Estatística). 4. Análise de
séries temporais. I. Universidade Federal de Viçosa. II. Título.

CDD 22. ed. 630.2515

ROZIANE SOBREIRA DOS SANTOS

**HOMOGENEIDADE E RECONSTRUÇÃO DE SÉRIES CLIMATOLÓGICAS
PARA LOCALIDADES NO ESTADO DE MINAS GERAIS**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Meteorologia Agrícola, para obtenção do título de *Doctor Scientiae*.

APROVADA: 24 de fevereiro de 2012.

Welliam Chaves Monteiro da Silva

José Maria Nogueira da Costa

Brauliro Gonçalves Leal

Fernando Falco Pruski
(Coorientador)

Gilberto Chohaku Sedyama
(Orientador)

A Deus
A minha mãe (in memorian)
Ao meu esposo Robson

DEDICO

AGRADECIMENTOS

A Deus.

Ao meu amado esposo Robson, por todo amor e carinho, pelo apoio nos momentos mais difíceis, por toda a dedicação, estímulo, por sua infinita paciência mesmo nas horas mais difíceis e pela valiosa colaboração na realização deste trabalho com preciosas contribuições.

Aos meus queridos sogros Regina e Sinézio por todo carinho, amizade e auxílio.

Ao professor Gilberto Chohaku Sedyama pelos valiosos ensinamentos, pela amizade e pela confiança depositada ao longo desses quatro anos, através de seus ensinamentos e palavras de apoio.

Ao professor Fernando Falco Pruski pelas valiosas sugestões e amizade.

Aos professores Brauliro Gonçalves Leal, José Maria Nogueira da Costa e Nerilson Terra Santos pelas sugestões e discussões construtivas que se delinearam durante a qualificação.

Ao Dr. Welliam Chaves Monteiro da Silva sempre disposto a ajudar.

Aos demais professores do programa pós-graduação em Meteorologia Agrícola pelos ensinamentos.

Ao Gabriel Medeiros Abrahão, sempre disposto a ajudar e compartilhar idéias, muitas vezes me ensinando.

À Universidade Federal de Viçosa pela oportunidade de realização desse curso.

Ao Departamento de Matemática e Estatística da Universidade Federal de Rondônia – Ji-Paraná. Em especial ao professor Dilson Henrique Ramos Evangelista, um grande amigo sempre ajudando e permitindo que eu pudesse me dedicar a este trabalho.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão da bolsa e financiamento.

Ao Instituto Nacional de Meteorologia (INMET) pelos dados meteorológicos.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes) pela concessão da bolsa.

Aos colegas da pós-graduação em Meteorologia Agrícola pelo apoio e incentivo durante todo o curso, em especial aos mais próximos que contribuíram muito.

Aos meus colegas de sala pela convivência harmoniosa. Agradeço em especial o Leônidas sempre disposto a ajudar.

As minhas queridas amigas Christiane Enoy, Cristiane Evangelista e Leydimere Janny que muito me ajudaram e incentivaram.

A todos os colegas de Viçosa que torceram muito por mim.

Aos meus amigos de Ji-Paraná, eu não irei citar nomes para não me esquecer e deixar alguém de fora, mas vocês são muito especiais.

Aos meus irmãos, cunhadas e cunhados, primos e amigos que mesmo longe sempre estão me apoiando e incentivando.

A Graça, secretária da pós-graduação em Meteorologia Agrícola, sempre disposta a nos ajudar, independente do dia e hora.

Aos meus vizinhos Aparecida e Ademar pela amizade, carinho e dedicação.

Aos meus amados sobrinhos Andreza, Guilherme Augusto, Thiago e Sávio que sempre me propiciam momentos alegres e descontraídos.

A todos os funcionários e técnicos do Departamento de Engenharia Agrícola pela presteza.

A todos que, de alguma forma, contribuíram para a realização deste trabalho.

BIOGRAFIA

Roziane Sobreira dos Santos, filha de Rosevelte Sobreira dos Santos e Luzia de Abreu Santos, nasceu no dia 16 de setembro de 1981, em Alegre, Espírito Santo.

Em setembro de 2005, graduou-se em Estatística pela Universidade Federal do Espírito Santo (UFES), em Vitória, Espírito Santo.

Em outubro de 2006, ingressou no Programa de Pós-Graduação em nível de Mestrado, em Meteorologia Agrícola na Universidade Federal de Viçosa, concluindo-o em julho de 2008.

Em agosto de 2008, iniciou o Programa de Pós-Graduação em Meteorologia Agrícola, em nível de Doutorado, na Universidade Federal de Viçosa, submetendo-se à defesa de tese em 24 de fevereiro de 2012.

Durante o período de março de 2009 a agosto de 2009, exerceu o cargo de Professor Substituto no Departamento de Estatística da Universidade Federal de Viçosa.

Em maio de 2009, foi aprovada no concurso para provimento de professor de ensino superior, na área de Estatística, pela Universidade Federal de Rondônia - UNIR, Campus Ji-Paraná, tomando posse em setembro de 2009 atuando até o presente momento como professora Assistente desta universidade.

SUMÁRIO

LISTA DE ABREVEATURAS E SÍMBOLOS	VIII
LISTA DE FIGURAS	IX
LISTA DE TABELAS.....	XII
RESUMO.....	XIII
ABSTRACT	XV
1. INTRODUÇÃO.....	1
2. REVISÃO DE LITERATURA.....	4
2.1. Homogeneidade e tendência em séries de dados climatológicos	4
2.2. Preenchimento (reconstrução) de falhas de séries climáticas	8
2.3. Séries temporais	11
2.4. Modelagem geoestatística espaço-temporal	14
3. MATERIAL E MÉTODOS	16
3.1. Testes homogeneidade e tendência em séries de dados climatológicos	21
3.2. Metodologia de Box-Jenkins	25
3.3. Modelo Geoestatístico Espaço-Tempo	28
3.4. Desempenho estatístico dos modelos	30

4. RESULTADOS E DISCUSSÃO	33
4.1. Homogeneidade	33
4.2. Tendência.....	40
4.3. Metodologia de Box-Jenkins	49
4.4. Modelo Geoestatístico Espaço-Tempo	57
5. CONCLUSÕES.....	72
6. REFERÊNCIA BIBLIOGRÁFICA	74

LISTA DE ABREVEATURAS E SÍMBOLOS

ANA	Agência Nacional de Águas
ARIMA	Autorregressivo Integrado Médias Móveis
d	Índice de concordância de Willmott
FAC	Função de autocorrelação
FACP	Função de autocorrelação parcial
INMET	Instituto Nacional de Meteorologia
MAE	Erro absoluto médio
MBE	Viés médio
Prec	Precipitação
r^2	Coeficiente de determinação
RMSE	Raiz do erro quadrático médio
SARIMA	Autorregressivo Integrado Médias Móveis Sazonal
SNHT	Teste de Homogeneidade Normal Padrão
Tmax	Temperatura Máxima
Tmin	Temperatura Mínima

LISTA DE FIGURAS

Figura 1 – Distribuição geográfica das estações.....	17
Figura 2 – Diagrama de barras dos dados.....	18
Figura 3 – Porcentagem de classificação das séries mensais de temperatura máxima do ar (A) e de temperatura mínima do ar (B).	36
Figura 4 – Mês e ano de mudança significativa no comportamento da temperatura máxima e mínima do ar na estação de Uberaba.....	37
Figura 5 – Distribuição do número de mudanças significativas por ano para temperatura máxima e temperatura mínima do ar.	38
Figura 6 – Distribuição do número de mudanças significativas por mês para temperatura máxima e temperatura mínima do ar.	39
Figura 7 – Distribuição mensal dos valores de Z do teste de Mann-Kendall para a temperatura mínima do ar.....	41
Figura 8 – Distribuição mensal dos valores de Z do teste de Mann-Kendall para a temperatura máxima do ar.....	42
Figura 9 – Distribuição mensal dos valores de Z do teste de Mann-Kendall para a precipitação.	43
Figura 10 – Distribuição temporal e tendência para a temperatura média máxima anual na estação de Uberaba.....	47
Figura 11 – Distribuição temporal das temperaturas máxima e mínima do ar.	50

Figura 12 – Função de autocorrelação da série original (direita) e diferenciada (esquerda) para a temperatura máxima do ar.....	51
Figura 13 – Função de autocorrelação da série original (direita) e diferenciada (esquerda) para a temperatura mínima do ar.	52
Figura 14 – Comportamento da temperatura observada e modelada pela metodologia de Box-Jenkins na estação de Espinosa.	54
Figura 15 – Diagnóstico para o modelo SARIMA(1,0,1)(0,1,1) ₁₂ para temperatura mínima do ar na estação de Espinosa.	56
Figura 16 – Comportamento da temperatura do ar observada e modelada pelo modelo espaço-tempo na estação de Araçuaí.	59
Figura 17 – Comportamento da temperatura do ar observada e modelada pelo modelo espaço-tempo na estação de Arinos.	59
Figura 18 – Comportamento da temperatura do ar observada e modelada pelo modelo espaço-tempo na estação de Espinosa.	60
Figura 19 – Comportamento da temperatura do ar observada e modelada pelo modelo espaço-tempo na estação de Januária.	60
Figura 20 – Comportamento da temperatura do ar observada e modelada pelo modelo espaço-tempo na estação de Montes Claros.	61
Figura 21 – Comportamento da temperatura do ar observada e modelada pelo modelo espaço-tempo na estação de Salinas.	61
Figura 22 – Distribuição da precipitação observada e modelada pelo modelo espaço-tempo.	62
Figura 23 – Distribuição da precipitação observada e modelada pelo modelo espaço-tempo.	63
Figura 24 – Comparação entre temperatura máxima do ar observada e prevista pelo modelo espaço-tempo (esquerda) e pela metodologia de Box-Jenkins (direita) para as estações de Araçuaí (A), Arinos (B) e Espinosa (C).	67
Figura 25 – Comparação entre temperatura máxima do ar observada e prevista pelo modelo espaço-tempo (esquerda) e pela metodologia de Box-Jenkins (direita) para as estações de Januária (A), Montes Claros (B) e Salinas (C).	68
Figura 26 – Comparação entre temperatura mínima do ar observada e prevista pelo modelo espaço-tempo (esquerda) e pela metodologia de Box-Jenkins (direita) para as estações de Araçuaí (A), Arinos (B) e Espinosa (C).	69

Figura 27 – Comparação entre temperatura mínima do ar observada e prevista pelo modelo espaço-tempo (esquerda) e pela metodologia de Box-Jenkins (direita) para as estações de Januária (A), Montes Claros (B) e Salinas (C).....	70
---	----

LISTA DE TABELAS

Tabela 1 – Estações utilizadas na análise de homogeneidade e tendência.	19
Tabela 2 – Estações utilizadas no modelo geoestatístico espaço-tempo.....	20
Tabela 3 – Estações utilizadas no ajuste da metodologia de Box-Jenkins...	20
Tabela 4 – Classificação mensal das séries de temperatura máxima do ar.	34
Tabela 5 – Classificação mensal das séries de temperatura mínima do ar..	35
Tabela 6 – Valor p dos coeficientes de regressão para temperatura máxima do ar	44
Tabela 7 – Valor p dos coeficientes de regressão para temperatura mínima do ar	45
Tabela 8 – Valor p dos coeficientes de regressão para precipitação	46
Tabela 9 – Modelos de Box-Jenkins ajustados em cada estação	53
Tabela 10 – Medidas de desempenho da metodologia Box-Jenkins para temperatura máxima e mínima do ar	54
Tabela 11 – Medidas de desempenho do modelo geoestatístico espaço-tempo para temperatura máxima do ar	58
Tabela 12 – Medidas de desempenho do modelo geoestatístico espaço-tempo para temperatura mínima do ar	58
Tabela 13 – Medidas de desempenho do modelo geoestatístico espaço-tempo precipitação	65

RESUMO

SANTOS, Roziane Sobreira dos, D.Sc., Universidade Federal de Viçosa, fevereiro de 2012. **Homogeneidade e reconstrução de séries climatológicas para localidades no estado de Minas Gerais.** Orientador: Gilberto Chohaku Sediama. Coorientador: Fernando Falco Pruski.

Os dados climáticos são de extrema importância nas diversas atividades realizadas pelo homem fornecendo informações importantes do ambiente atmosférico e os impactos que ocorrem nele. Portanto há necessidade de informações meteorológicas confiáveis, pois uma falha na série temporal pode comprometer a análise e a interpretação dos dados. Os dados climáticos, para serem usados com segurança, devem ser estatisticamente homogêneos, uma vez que a não-homogeneidade de uma série temporal conduz a uma interpretação errônea das condições do clima a ser estudado. A falta de dados meteorológicos nas séries de dados históricos para as condições brasileiras é expressiva, tanto pela baixa densidade de estações, como pelas falhas existentes, pois nem sempre os registros disponíveis são contínuos para longos períodos de observações. Com esse trabalho objetivou-se: analisar metodologias para avaliar a homogeneidade, a tendência e o preenchimento de falhas em séries de dados de temperatura máxima e mínima do ar e da precipitação em Minas Gerais. A análise de homogeneidade foi feita por meio de três testes de identificação de pontos

de descontinuidade: teste de Homogeneidade Normal Padrão (SNHT) para um único ponto, teste de Pettitt e teste de Buishand. Na análise de tendência foram utilizados os testes de Mann-Kendall e análise de regressão. Para preenchimento de falhas utilizou-se duas metodologias: os modelos SARIMA proposto por Box-Jenkins, que utilizam os dados da própria estação com dados faltantes, e o modelo geoestatístico espaço-tempo, que considera as estações vizinhas, ponderando tanto a dependência espacial como temporal dos dados. Na análise de homogeneidade, 73% das séries de temperatura máxima do ar e 71% das séries de temperatura mínima do ar, foram consideradas homogêneas. As mudanças estatisticamente significativas ocorreram na década de 1990, principalmente em torno do ano de 1997. A maior parte das tendências observadas é de aumento, especialmente na temperatura mínima do ar. As séries de precipitação não apresentaram tendências significativas. Os modelos SARIMA capturam bem o comportamento padrão das séries temporais, com valores de r^2 variando de 0,47 a 0,68 para temperatura máxima e de 0,85 a 0,90 para temperatura mínima. Os erros associados pelos modelos foram baixos, com raiz do erro quadrático médio em torno de 1°C e viés médio próximo de 0,4°C. O modelo geoestatístico espaço-tempo apresentou resultados melhores do que a metodologia de Box-Jenkins, sendo mais eficiente, com altos valores de r^2 e do índice de concordância de Willmott e erros médios bem próximos de zero. Inclusive em séries de precipitação as previsões foram bem ajustadas. O menor valor de r^2 encontrado explica 70% da variabilidade dos dados de precipitação. Para a temperatura máxima o menor valor de r^2 foi de 82%, muito superior ao modelo de Box-Jenkins. Comparando as duas metodologias, o modelo espaço-temporal está mais próximo da identidade, apresentando menor dispersão em torno da reta estimada e maior coeficiente de determinação.

ABSTRACT

SANTOS, Roziane Sobreira dos, D.Sc., Universidade Federal de Viçosa, february, 2012. **Homogeneity and climatological series reconstruction for some localities in the state of Minas Gerais.** Advisor: Gilberto Chohaku Sedyama. Co-advisor: Fernando Falco Pruski.

Climatic data is extremely important in the various activities undertaken by man, providing much information concerning the atmospheric environment and the impacts on it. Therefore there is a need for reliable weather information, because a failure in the time series can compromise analysis and data interpretation. To be used safely, weather data must be statistically homogeneous, since the non-homogeneity of a series leads to an erroneous interpretation of the weather conditions to be studied. The lack of historical weather data is significant, both due to the lack of weather stations and the existing gaps, as the available records are not always continuous for long periods of observations. This work aimed to analyze methodologies to evaluate the homogeneity and trend, as well as gap filling data series of maximum and minimum temperatures of air and rainfall in Minas Gerais. The homogeneity analysis was performed by three tests for the identification of discontinuity points in time series: Standard Normal Homogeneity Test (SNHT) to a single point test, Pettitt test and Buishand test. In trend analysis the Mann-Kendall and regression analysis were used. To fill gaps, two

methodologies were used: the SARIMA models proposed by Box-Jenkins that uses the station's own data with gaps, and a space-time geostatistical model that considers the neighboring stations and the series with gaps, considering both the spatial and temporal dependence of the data. In the homogeneity analysis, 73% of maximum air temperature series and 71% of minimum air temperature series were considered homogeneous. The statistically significant changes occurred in the 1990s, especially around 1997. Most trends are increasing, especially in minimum air temperature. The precipitation series showed no significant trends. The SARIMA models capture well the behavior pattern of the series, with r^2 values among 0.47 to 0.68 in maximum temperature and 0.85 to 0.90 for minimum temperature. The errors associated with the models were low, with a root mean square error of about 1 ° C and bias of around 0.4 ° C. The space-time geostatistical model showed better results than the Box-Jenkins methodology, being more efficient, with high values of r^2 and the Willmott's index of agreement and mean errors very close to zero. Even in a precipitation series the forecasts were well adjusted. The lowest value of r^2 found explains 70% of the precipitation data variability. For maximum temperature the smallest value of r^2 is 82%, much higher than the Box-Jenkins' model. Comparing the two methods, the space-time is model are closer to the identity, presenting a lower dispersion around the estimated straight line and coefficient of determination greater.

1. INTRODUÇÃO

A informação climática é de grande importância nas diversas atividades realizadas pelo homem, como o gerenciamento de recursos hídricos, proteção aos riscos de inundação, modelagem da erosão; estudos agrometeorológicos, otimização da produção agropecuária, estudos climáticos relacionados a fenômenos atmosféricos e às mudanças climáticas, dentre outras aplicações. Os dados climáticos fornecem muitas informações sobre o ambiente atmosférico e os impactos que ocorrem nele. Assim, a identificação de alterações nos registros meteorológicos é imprescindível para diversos estudos que utilizam as séries meteorológicas históricas.

Para garantir a confiabilidade de muitos estudos climáticos, especialmente dos que analisam a variabilidade do clima, são necessários dados confiáveis e homogêneos, tendo em vista que os resultados das análises, com dados não homogêneos, podem induzir a conclusões contraditórias e errôneas.

Além disso, a disponibilidade de dados meteorológicos, com séries históricas contínuas, sem falhas, é um dos principais problemas para o desenvolvimento de estudos ambientais, hidrológicos e de variabilidade climática. Igualmente, a dificuldade na obtenção de dados meteorológicos, com séries temporais longas e confiáveis é um grande desafio aos mais

variados estudos. Falhas na série temporal podem comprometer a análise e a interpretação dos dados.

Os dados climáticos, para serem usados com segurança, devem ser estatisticamente homogêneos e contínuos, uma vez que a não-homogeneidade de uma série temporal pode conduzir a uma interpretação errônea das condições do clima a ser estudado. Contudo, diante da extensão territorial e da diversidade fisiográfica e ambiental, há carência de estudos sobre homogeneidade e tendência dos elementos do clima no Brasil.

Uma série numérica de um elemento meteorológico, ordenada cronologicamente, é dita “homogênea” se as variações são causadas exclusivamente pelas condições do tempo (MARTÍNEZ et al., 2011; LONGOBARDI; VILLANI; 2010; PANDŽIĆ; LIKSO, 2010). A presença de heterogeneidades e, ou, descontinuidades nas séries temporais climatológicas podem afetar a caracterização da variabilidade climática da região em estudo. É essencial, portanto, focar estudos em séries de dados climáticos consistentes, completas e homogêneas. As heterogeneidades podem ser alterações causadas, por exemplo, pelo crescimento de vegetação ou pela urbanização na proximidade das estações, ou por mudança na localização, manutenção nos instrumentos de medida e, até mesmo, de hábitos de observação (AGUILAR et al., 2003).

Não é tarefa simples constatar a não-homogeneidade de uma série, principalmente porque as dificuldades variam de um elemento meteorológico para outro. Além disso, não é possível decidir se uma série é homogênea, dispondo de observações de um único local e utilizando séries com dados faltantes.

Begert et al. (2005) ressaltam a importância da confiabilidade dos dados nas análises de variação da temperatura do ar e precipitação para a atual discussão sobre as mudanças climáticas.

Somando a relevância desses elementos climáticos às atividades humanas, torna-se evidente a necessidade de estudos de consistência, homogeneidade e preenchimento de falhas em séries climáticas.

Nos últimos 30 anos, diferentes grupos de pesquisadores tem se esforçado em produzir um banco de dados com alta qualidade para a temperatura em diferentes escalas de tempo (BRUNET et al., 2006).

Sendo assim, com esse trabalho objetivou-se: analisar metodologias para avaliar a homogeneidade, a tendência e o preenchimento de falhas em séries de dados de temperatura máxima e mínima do ar e de precipitação em Minas Gerais. Pretende-se melhorar o conhecimento sobre as séries de dados climáticos no Estado fornecendo subsídios para futuros trabalhos científicos com abordagens mais consistentes e confiáveis sobre o tema.

2. REVISÃO DE LITERATURA

2.1. Homogeneidade e tendência em séries de dados climatológicos

Os elementos climáticos, como a temperatura do ar e a precipitação, que possuem alta variabilidade tanto no tempo como no espaço, necessitam de uma base de dados homogênea para que as análises climáticas, em longo prazo, sejam mais precisas (LONGOBARDI; VILLANI, 2010).

As séries de elementos climáticos são consideradas homogêneas se as variações ocorrem somente em função das condições do clima (MARTÍNEZ et al., 2011; LONGOBARDI; VILLANI; 2010; PANDŽIĆ; LIKSO, 2010). Entretanto, muitos fatores não climáticos afetam a variação desses elementos, tornando os dados pouco representativos da variação do clima, reduzindo a qualidade e comprometendo a homogeneidade das séries climáticas (BRUNET et al., 2006;. AUER et al., 2005; AGUILAR et al., 2003; PETERSON et al., 1998).

Pesquisadores como Brunet et al. (2006); Auer et al. (2005); Caussinus e Mestre (2004); Aguilar et al. (2003) e Peterson et al. (1998) destacam que uma parte das mudanças observadas tem origem não climática. Esse tipo de mudança é chamada de heterogeneidade, e uma série temporal com heterogeneidade é dita ser não-homogênea (DOMONKOS, 2011).

Tanto as mudanças abruptas como a tendência gradual nos dados causam heterogeneidades nas séries climáticas. As não-homogeneidades podem ser alterações causadas, por exemplo, pelo crescimento de vegetação ou pela urbanização na proximidade das estações; ou então por mudanças na localização da estação ou pela manutenção precária nos instrumentos de medida e, até mesmo, pelos hábitos de observação (RIENZNER; GANDOLFI, 2011; BEAULIEU et al., 2010; PANDŽIĆ; LIKSO, 2010; COSTA; SOARES, 2009b; BRUNET et al., 2006; CAUSSINUS; MESTRE, 2004; AGUILAR et al., 2003).

Pandžić e Likso (2010) ressaltam que mudanças graduais artificiais no local e ambiente de observação causam tendência gradual na temperatura do ar, enquanto a transferência do local de observação geralmente provoca uma mudança abrupta expressiva na temperatura média do ar em comparação com a média de períodos mais longos antes da realocação.

Muitos testes estatísticos são usados para averiguar a homogeneidade em séries climáticas. Estes testes podem ser classificados em dois grupos: testes de homogeneidade absolutos e relativos (PANDŽIĆ; LIKSO, 2010; COSTA; SOARES, 2009b). Os testes absolutos são aplicados em uma única estação. Os testes relativos são procedimentos que utilizam os dados de uma estação vizinha (chamada de estação de referência), que é assumida ser homogênea e que exhibe as mesmas variações naturais de tempo e clima da estação a ser testada (chamada de estação candidata) (PANDŽIĆ; LIKSO, 2010; COSTA; SOARES, 2009b).

Segundo Pandžić e Likso (2010), os testes absolutos impossibilitam fazer uma distinção entre heterogeneidade e uma variação regional de clima. Nos testes relativos, a série de referência é usada para separar as mudanças reais do clima e para destacar as mudanças artificiais na série candidata, que não ocorrem na série de referência (PANDŽIĆ; LIKSO, 2010). As séries de referência são utilizadas para identificar os efeitos das descontinuidades de uma determinada estação das mudanças regionais (BERGET et al., 2005).

Costa e Soares (2009b); Reeves et al. (2007); DeGaetano (2006); Ducré-Robitaille et al. (2003) e Peterson et al. (1998) apresentam uma

revisão de diferentes testes estatísticos de homogeneidade e Aguilar et al. (2003) fornecem um guia para homogeneização de dados climáticos.

Entre os vários testes estatísticos empregados para verificar a homogeneidade, três testes absolutos têm sido utilizados em quase todos os estudos. São eles: teste de homogeneidade normal padrão (SNHT, *Standard Normal Homogeneity Test*) para um único ponto (ALEXANDERSSON; MOBERG, 1997), teste de Pettitt (PETTITT, 1979) e teste de Buishand (BUISHAND, 1982). Os testes estabelecem como hipótese nula, que a variável é independente e identicamente distribuída (iid). Sob a hipótese alternativa, assumem um desvio na média. O SNHT é mais sensível em detectar descontinuidades no início e no final da série, enquanto os testes de Pettitt e Buishand são mais sensíveis a heterogeneidades localizadas no meio da série (MARTÍNEZ et al., 2010; COSTA; SOARES, 2009a).

Begert et al. (2005) destacam a importância do uso combinado de diferentes métodos estatísticos, para se ter resultados mais confiáveis. Toreti et al. (2011) evidenciam que a comparação de vários testes de detecção de pontos de mudanças é uma boa estratégia, principalmente quando não se tem disponível todas as informações históricas da estação (metadado).

O metadado é usado para encontrar heterogeneidades que ocorrem em várias estações na mesma região climática em torno da mesma data (BEGERT et al., 2005).

Os metadados são muito úteis para avaliar a qualidade de uma série e para identificar possíveis erros, mas, frequentemente não são disponíveis nas bases de dados de clima (VICENTE-SERRANO et al., 2010). Eles fornecem informações sobre mudanças na localização, no ambiente, nos instrumentos, nas práticas de observações, na manutenção e calibração dos instrumentos, etc. Os metadados completos são necessários para garantir que o usuário final não tenha qualquer dúvida sobre as condições em que os dados são registrados, coletados e transmitidos, de forma que o usuário possa extrair conclusões precisas a partir de sua análise (SAHIN; CIGIZOLU, 2010).

Para Costa e Soares (2009a) o uso de abordagens de testes absolutos, sem informações de metadados, torna difícil determinar se as mudanças ou a falta de mudanças na série temporal da estação são

resultados de heterogeneidades, ou simplesmente de mudanças no clima regional.

Martínez et al. (2010) destacam que, se o objetivo é aceitar ou rejeitar a homogeneidade de uma série climática para análises adicionais, um teste SNHT absoluto, juntamente com os testes de Buishand e de Pettitt, seria o procedimento recomendado.

Quando uma variável aleatória exhibe uma mudança gradual ao longo do tempo, essa mudança é denominada tendência (LONGOBARDI; VILLANI, 2010).

Com relação aos testes para detectar tendência em uma série temporal, observa-se na literatura a aplicação dos testes de regressão e Mann-Kendall (MANN, 1945; KENDALL, 1975), conjuntamente. Rodrigo e Trigo (2007) apontam que mais informações podem ser obtidas com a combinação destas duas técnicas.

Martínez et al. (2010) destacam que a estimativa de tendência por regressão linear pode não ser muito robusta quando a série temporal possui irregularidades, sugerindo assim, que o teste t seja complementado com o teste de Kendall. Önöz e Bayazit (2003) mostram que o teste t é menos poderoso do que o teste de Mann-Kendall quando a distribuição de probabilidade é assimétrica, mas, em aplicações práticas, ambos os testes podem ser usados conjuntamente, apresentando resultados similares.

Em diferentes locais, as séries de temperatura do ar têm apresentado tendências. Blain (2010b), utilizando testes estatísticos paramétricos e não-paramétricos, verificou consideráveis elevações nas séries anuais de temperatura mínima do ar no estado de São Paulo. Silva (2004) encontrou tendência de aumento nas temperaturas média, máxima e mínima do ar no nordeste do Brasil. Santos et al. (2010) também encontraram tendências crescentes nas séries temporais de temperatura média do ar no Nordeste do Brasil, tanto para a situação climática atual (1961-2007) como para os cenários de 2050 e 2100.

Minuzzi (2010) identificou tendência de aumento entre os anos de 1988 a 1991 para a temperatura mínima do ar e de tendência de decréscimo na temperatura máxima do ar entre 1995 a 1998 em Santa Catarina. Minuzzi

et al. (2010) verificaram descontinuidades na década de 1990 em séries de temperatura máxima e mínima do ar no estado de Minas Gerais.

Martínez et al. (2010), analisando séries diárias de temperatura máxima e mínima do ar no Noroeste da Catalonia, Espanha, verificaram tendência de aumento anual de 0,5°C por década em ambas as séries diárias. Longobardi e Villani (2010) encontraram tendência significativa de variação em séries anuais de precipitação em 97% das estações analisadas em duas regiões no sul da Itália.

Analisando os totais mensais de precipitação pluvial no Estado de São Paulo, Blain (2009, 2010a) não encontrou fortes indícios de tendências de variações climáticas. Porém, apesar desses resultados, muitos estudos realizados, em diversos locais evidenciam potenciais tendências de variação em séries de precipitação (LONGOBARDI; VILLANI, 2010; MOURATO et al., 2010; VICENTE-SERRANO et al., 2010; BLAIN et al., 2009; COSTA; SOARES, 2009a; SANTOS et al., 2009). Por outro lado, em escala regional, as alterações no clima podem ser muito divergentes e nem sempre acompanham a tendência global. No entanto, Blain (2010a), aplicando o teste de Mann-Kendall sazonal em séries de precipitação, identificou tendências de variação em algumas localidades no estado de São Paulo em meses distintos.

2.2. Preenchimento (reconstrução) de falhas de séries climáticas

As falhas em dados climáticos podem ocorrer devido às mais variadas fontes, como falhas no equipamento de medição, na transmissão dos dados, deterioração dos instrumentos ou ausência de informações.

De modo geral, a reconstrução ou preenchimento de falhas de dados climáticos não é feita de forma padronizada, sendo realizada utilizando diferentes técnicas e, muitas vezes, sem computar o erro associado.

Vicente-Serrano et al. (2010) utilizaram dados de estações localizadas a uma pequena distância do local desejado para preencher falhas em dados de precipitação. Contudo, eles destacam que esse procedimento pode gerar heterogeneidade na série reconstruída. Eles também enfatizam que na

literatura não existe um critério geral para a seleção das estações adequadas para reconstrução.

Na literatura internacional, as reconstruções de séries de dados climáticos, geralmente, são feitas utilizando séries muito longas, com mais de 100 anos de dados e, muitas vezes, não objetivam aplicações diretas desses dados em trabalhos práticos. As reconstruções são realizadas com base, principalmente, em dados de paleoclimatologia, chamados de registros proxy (CHEN et al., 2011, LI et al., 2010; STORCH et al., 2009), como núcleos de gelo, anéis de árvores, corais e sedimentos de lagos e oceano. Existem outros métodos estatísticos, como os bayesianos, mas que são computacionalmente pesados e ainda não estão totalmente implementados nos softwares.

Métodos de recuperação de registros com falhas têm sido amplamente desenvolvidos. Estes processos têm por base, em regra geral, a comparação com séries obtidas em regiões com as mesmas características climáticas e, ou, a utilização da própria série para completar registros com falhas. Monbet et al. (2007) destacam o uso dessas duas abordagens na reconstrução de dados faltantes.

Staudt et al. (2007) destacam que o primeiro tipo de informação disponível para preencher as lacunas em dados climáticos é a informação contida na própria série a ser preenchida. Porém, os dados de estações próximas são mais eficientes para suprir a falta de dados devido à possível correlação entre essas séries (STAUDT et al., 2007). Leivas et al. (2006) recomendam que para o preenchimento das falhas nas séries históricas sejam selecionadas as estações meteorológicas da mesma região climática e altitude semelhante, caracterizando-a como climaticamente homogênea.

Para Monbet et al. (2007) a escolha da técnica de preenchimento de falhas depende de sua precisão em descrever as características do fenômeno e da facilidade de uso.

De acordo com Oliveira et al. (2010), vários métodos podem ser utilizados no preenchimento de falhas de dados meteorológicos, incluindo a utilização de médias de dados observados (normais climatológicas) ou dados sintéticos obtidos de geradores de dados.

No Brasil, verificou-se diversos métodos sendo empregados no preenchimento de falhas de séries climáticas de temperatura e precipitação.

Pruski et al. (2004), ao analisarem as variações espaciais da precipitação média anual na Bacia do São Francisco, utilizaram o método da ponderação regional com base em regressões lineares, para o preenchimento de falhas em séries pluviométricas, adotando como critério mínimo a obtenção de coeficiente de determinação superior a 0,7 e a existência de pelo menos oito pares de eventos entre as estações para a realização da regressão. Outros autores também utilizam o método da ponderação regional para o preenchimento de falhas em dados de precipitação (CASTRO et al., 2010; SILVA et al., 2010).

Lúcio et al. (2010) utilizaram as normais climatológicas para preencher séries trimestrais de precipitação. Santos et al. (2008) empregam a análise de agrupamento para definir regiões homogêneas e proceder o preenchimento de falhas em dados de precipitação.

Jácomo (2011) estudou o regime pluviométrico no oeste do Estado de São Paulo e utilizou a média aritmética dos valores de precipitação pluvial de três ou quatro estações mais próximas à estação com falta de informação para preencher as falhas, ressaltando que esse preenchimento foi feito de acordo com o comportamento dos dados nessas estações.

Oliveira et al. (2010), comparando as metodologias de ponderação regional (PR), regressão linear (RM) e potencial (RP) múltiplas, ponderação regional e vetor regional (VR), para o preenchimento de falhas em séries históricas de precipitação pluvial anual, verificaram que o método da regressão linear múltipla apresentou os melhores resultados. Existem muitos outros métodos sendo utilizados, contudo, esses estudos não apresentam nenhum cálculo de erro associado aos procedimentos de preenchimento de falhas.

Algumas pesquisas têm apontado que estimativas feitas utilizando técnicas de geoestatística são melhores do que os métodos convencionais. Carrera-Hernández e Gaskin (2007), Kyriakidis et al. (2004) e Teegavarapu e Chandramouli (2005) mostram que as técnicas de krigagem fornecem com sucesso estimativas de registro faltantes de precipitação.

Segundo Goovaerts (2000), em locais com baixa densidade de pontos de coleta de precipitação, a interpolação geoestatística supera técnicas, como o inverso da distância ao quadrado e o polígono de Thiessen, que ignoram o padrão de dependência espacial que normalmente é observado para os dados de precipitação. O erro quadrático médio da previsão feita por krigagem chega a ser metade do erro produzido usando o inverso da distância ao quadrado. Ele também verificou que para estimar precipitação a krigagem ordinária é mais precisa do que os modelos de regressão linear.

2.3. Séries temporais

Um conjunto de observações mensuradas sequencialmente no tempo é denominado uma série temporal. Uma das principais características da série temporal é o fato das observações coletadas serem correlacionadas no tempo. As metodologias de análises de séries temporais são destinadas a explicar essa correlação e as principais características dos dados usando modelos estatísticos (COWPERTWAIT; METCALFE, 2009).

Para realçar as propriedades de uma série temporal, a série é decomposta em três componentes: tendência, sazonalidade e ruído branco ou erro aleatório. A tendência é o efeito em longo prazo na média, a sazonalidade são os efeitos ligados as variações sazonais (semanal, mensal, anual, etc), essa componente se repete a cada intervalo fixo s , o ruído branco ou erro aleatório é a parte não explicada, que se espera ser puramente aleatória e compreende a variabilidade intrínseca aos dados e que não pode ser modelado, ou seja, é tudo aquilo que não é explicado pelas outras componentes da série (SOUZA et al., 2009).

Em geral, existe uma correspondência entre o comportamento de observações anteriores em relação às observações seguintes, esta associação é denominada autocorrelação. Tais condições podem ser analisadas por meio da função de autocorrelação (FAC), que medem o grau de dependência entre os valores de uma série temporal em diferentes períodos, e pela função de autocorrelação parcial (FACP), que pode ser

definida como a sequência de correlações de determinados termos de uma série temporal e os elementos da série mais recente (LÚCIO et al., 2010).

Em análises de séries temporais, o conceito de estacionariedade é fundamental. Uma série temporal é dita ser estacionária quando o comportamento da série não se altera com o passar do tempo. Isto é, quando suas propriedades estatísticas (média, variância e covariância) são invariantes no tempo e a autocorrelação depende apenas da defasagem. Dessa forma, a série é considerada fracamente estacionária, condição necessária para análises práticas de séries temporais.

A principal técnica de análise de séries temporais é a metodologia desenvolvida por Box e Jenkins (1976). A metodologia de Box-Jenkins é apropriada para fazer simulação, previsão e reconstrução (MONBET et al., 2007).

Diferentemente das outras técnicas estatísticas em que as observações devem ser independentes, os modelos propostos por Box e Jenkins, denominados ARMA (autorregressivo média móvel), consideram a correlação serial entre as observações. Contudo, necessitam que a série temporal seja estacionária (BOX et al., 1994). Os dados reais, frequentemente, não são estacionários. Assim, é necessário a diferenciação da série original para torná-la estacionária. Dessa forma, o modelo torna-se autorregressivo integrado média móvel (ARIMA).

Em algumas séries temporais ainda existem mudanças sazonais ou periódicas. Esse tipo de série é analisada por meio dos modelos sazonais autorregressivo integrado média móvel (SARIMA), nos quais, além da diferenciação simples, é aplicada uma diferenciação sazonal nas observações originais para tornar a série estacionária.

O modelo SARIMA é denominado por: $SARIMA(p,d,q) \times (P,D,Q)_S$, em que p é o número de termos autoregressivos, d é o número de diferenciações para que a série torne-se estacionária e q é o número de termos de médias móveis, P e Q são os parâmetros autorregressivos sazonais e média móvel, respectivamente; D é o número de diferenciações sazonais e S representa o período sazonal.

A verificação da estacionariedade da série é feita por inspeção visual dos gráficos da série original e das funções de autocorrelação e

autocorrelação parcial e por testes estatísticos. As funções de autocorrelação (FAC) e autocorrelação parcial (FACP) permitem identificar as defasagens em que a correlação dos dados é significativa, identificando assim, os parâmetros do modelo. A adequacidade do modelo é verificada testando os resíduos, que devem satisfazer testes padrão para um ruído branco (CUNHA; SOARES, 1999). Segundo Souza et al. (2009), um erro é chamado de ruído branco quando possui distribuição normal, sendo a média de seus componentes zero, a variância constante e os componentes não-correlacionados, indicando, assim, que o modelo elaborado conseguiu explicar o máximo da série de dados.

A análise de séries temporais pode ser dividida em três etapas: identificação dos parâmetros do modelo, estimação e diagnóstico desses parâmetros e previsão de observações futuras. Os gráficos da FAC e FACP são utilizados para identificar os parâmetros do modelo (BOX et al., 1994). O exame das funções FAC e FACP fornece uma base para analisar o comportamento da série temporal sob a dependência no tempo e também irá sugerir os parâmetros adequados ao modelo.

Os modelos ARIMA de Box-Jenkins são amplamente utilizados nas mais diversas áreas e também estão implementados em muitos softwares. Em estudos de séries de elementos climatológicos como a temperatura e a precipitação, os modelos de séries temporais de Box-Jenkins são empregados com os mais diversos objetivos. Almeida et al. (2011) comparam os modelos de séries temporais com modelos de geoestatística para dados de precipitação, obtendo resultados muitos similares entre as duas metodologias. Silva et al. (2008) ajustaram um modelo SARIMA para fazer previsões de temperatura média mensal no município de Uberlândia, MG, com bons resultados.

Souza et al. (2009), ajustaram os modelos SARIMA $(0,0,0)(0,1,1)_{12}$ para a série precipitação e SARIMA $(1,0,0)(0,1,1)_{12}$ para a série temperatura em Santa Maria, RS. Os autores verificaram que os modelos foram capazes de refletir a realidade das séries, contudo o melhor modelo encontrado para a precipitação foi ineficiente na detecção da maior parte da variabilidade, sugerindo assim outras abordagens para os dados de precipitação.

Alguns autores utilizam os modelos de séries temporais de Box-Jenkins para o preenchimento de falhas. Dentre eles cita-se o trabalho de Aquino et al. (2008), que utilizaram a metodologia de Box-Jenkins para preencher falhas mensais de erosividade de chuva em Lavras, MG.

2.4. Modelagem geoestatística espaço-temporal

A maioria dos processos ambientais são caracterizados por sua variabilidade no tempo e no espaço. As técnicas estatísticas tradicionais não descrevem os processos que evoluem no tempo e no espaço simultaneamente.

As técnicas de geoestatística vêm sendo empregadas para caracterizar as incertezas de fenômenos físicos espaço-temporal. Os modelos geoestatísticos espaço-temporais fornecem uma estrutura probabilística para análise de dados e previsões que consideram conjuntamente a dependência espacial e temporal entre as observações (KYRIAKIDIS; JOURNAL, 1999).

Para Huang et al. (2007), um dos principais objetivos da análise geoestatística é a estimação e modelagem da correlação de processos espaço-temporais. Além disso, muito esforço tem sido empregado para conseguir uma estrutura de covariância espaço-tempo válida (HUANG et al., 2007).

Kyriakidis e Journal (1999) apresentam uma revisão mais abrangente sobre modelos geoestatísticos espaço-tempo, mostrando diferentes abordagens na modelagem espaço-temporal.

Segundo De Iaco et al. (2011), para modelar e prever dados espaço-temporais são necessárias abordagens geoestatísticas multivariadas. Porém, recentemente, essas abordagens têm sido combinadas com análise multivariada clássica, como análise canônica, para detectar interações entre dois grupos de variáveis espaço-temporais (De Iaco, 2011).

O uso de modelos espaço-temporais tem aumentado. Isso se deve ao fato que nas mais variadas áreas de conhecimento as variáveis são medidas

em diferentes localidades e para vários intervalos de tempo. Contudo, ainda há uma grande dificuldade na aplicação desses modelos, pois os mesmos não se encontram disponíveis nos softwares (Bicalho, 2008).

Na literatura, diversos estudos têm utilizado diferentes modelos espaço-tempo para analisar variáveis meteorológicas (SIGRIST et al., 2011; DURÃO et al., 2010; COSTA et al., 2008).

3. MATERIAL E MÉTODOS

Nesse estudo, foram utilizadas séries mensais de temperaturas máximas e mínimas do ar e de precipitação de algumas estações meteorológicas de superfície convencional, pertencentes à rede de estações do Instituto Nacional de Meteorologia (INMET), no estado de Minas Gerais. Do total de estações estudadas, 88% têm 20 anos de dados recentes (1990-2010) observados e registrados. A Figura 1 apresenta a distribuição geográfica das estações estudadas.

Para a análise de homogeneidade e tendência, as séries de dados foram separadas por mês e foram utilizadas todas as estações que tinham dados contínuos. A Figura 2 apresenta o diagrama de barras do número de dados presentes nas séries por ano.

As séries utilizadas nesse estudo são muito variáveis em termos de tamanho da série e quantidade e duração das falhas (Figura 2). Além disso, observou-se uma tendência de ocorrerem falhas nos mesmos períodos nas estações próximas.

A Tabela 1 apresenta as estações que foram utilizadas nas análises de homogeneidade e tendência, juntamente com o período de dados disponível para análise.




Figura 1 – Distribuição geográfica das estações.

Para construir o modelo geoestatístico espaço-tempo é necessário um conjunto de estações espacialmente correlacionadas, pertencentes a uma mesma região climática e possuir alta densidade. Dessa forma, para a aplicação do modelo geoestatístico espaço-tempo as estações pertencentes à região Noroeste, Norte e Jequitinhonha foram selecionadas (Tabela 2).

As estações utilizadas no modelo geoestatístico espaço-temporal foram selecionadas baseadas nas regiões climaticamente homogêneas definidas por Aspiazu et al. (1990) e coeficiente de correlação significativo entre as estações.

As análises de temperatura máxima e mínima do ar foram realizadas para o período de abril de 2008 a maio de 2010 e para a precipitação no período de janeiro de 2007 a dezembro de 2008. A Tabela 2 apresenta a distribuição geográfica das estações utilizadas no modelo geoestatístico espaço-temporal.

Estação	1986	1987	1988	1989	1990	1991	1992	1993	1994	1995	1996	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010
Aimorés	100	100	97	100	100	100	100	100	100	100	100	99	99	100	100	100	100	100	100	100	100	100	81	100	84
Araquai	0	100	100	92	92	100	95	94	99	100	100	91	100	92	100	100	99	100	100	100	100	100	100	100	82
Araxá	90	100	100	100	100	100	100	99	100	97	99	100	100	100	92	95	100	100	100	100	100	100	100	100	84
Arinos	94	100	96	100	67	100	100	100	100	100	100	100	75	100	92	100	100	99	100	100	100	100	100	100	84
Belo Horizonte	100	0	100	98	100	100	100	100	100	100	100	100	100	100	100	100	99	100	100	100	100	100	100	100	84
Capinópolis	100	0	0	0	100	100	0	100	96	100	100	100	100	100	100	100	99	100	100	100	100	100	100	100	84
Carbonita	100	100	0	100	3	50	0	100	100	100	100	100	99	99	100	100	100	100	99	99	100	100	100	100	67
Diamantina	0	100	100	0	97	95	98	96	99	99	99	97	100	100	100	100	100	92	100	100	100	99	99	99	83
Espinosa	100	100	0	0	0	100	100	100	100	100	98	100	73	100	95	100	99	100	100	99	100	100	100	89	66
Formoso	100	99	0	0	0	0	0	83	100	100	100	100	75	91	92	92	100	92	92	92	92	92	92	92	76
Frutal	0	0	0	0	0	8	100	100	99	100	99	100	100	100	100	100	99	99	98	99	100	99	76	53	84
Janaúba	100	100	0	0	0	8	100	99	100	100	100	100	67	100	92	100	99	99	59	96	100	100	99	99	84
Januária	0	0	99	17	87	86	100	91	91	91	100	92	75	100	100	100	100	93	100	100	100	100	100	92	81
João Pinheiro	100	0	69	0	100	90	0	83	88	86	46	91	51	92	92	100	99	100	99	99	100	100	100	99	84
Juiz de Fora	0	98	0	98	0	83	58	100	100	100	99	99	98	98	87	96	92	98	100	100	83	99	100	98	82
Juramento	0	100	100	0	0	92	100	100	100	100	100	99	100	100	92	100	25	94	100	100	93	97	100	100	44
Mocimbo	100	100	100	0	0	100	100	100	92	100	100	100	33	100	100	100	99	99	100	87	93	97	90	96	82
Monte Azul	100	0	0	0	100	92	99	99	99	100	100	99	74	92	99	100	100	100	100	100	100	100	16	81	80
Montes Claros	0	0	0	91	0	96	100	98	100	100	100	100	90	100	100	100	100	100	100	100	100	100	100	100	84
Paracatu	0	0	0	100	100	100	0	100	100	100	100	100	100	100	100	100	100	100	100	99	100	100	100	100	84
Patos de Minas	100	0	0	0	0	100	100	100	100	99	100	100	100	100	92	100	100	100	98	97	100	100	100	100	84
Pedra Azul	0	0	100	100	0	100	100	92	94	93	100	96	75	96	100	100	100	100	100	100	100	96	100	100	84
Pirapora	0	0	0	100	99	100	100	100	100	100	100	96	82	100	100	100	100	100	100	100	100	100	100	100	84
Pompéu	100	0	0	99	95	96	100	100	100	100	100	100	100	95	92	100	100	100	100	100	100	100	100	100	84
Salinas	0	100	0	0	0	100	100	100	99	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	84
São Lourenço	91	100	0	100	100	92	99	91	86	92	100	100	100	100	100	100	99	99	100	97	100	100	96	95	84
Sete Lagoas	100	0	0	0	0	0	0	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	84
Uberaba	0	0	0	100	100	100	100	100	100	100	100	100	100	100	100	100	99	99	99	95	99	99	96	99	84
Unai	92	92	100	100	0	100	100	100	100	100	100	100	75	99	100	100	99	100	100	100	100	100	100	100	84
Viçosa	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	99	100	84

Legenda

O valor em cada célula indica a porcentagem de dados presentes para cada ano.

As cores indicam, visualmente, a faixa de porcentagem de dados presentes para cada ano



Figura 2 – Diagrama de barras dos dados.

Tabela 1 – Estações utilizadas na análise de homogeneidade e tendência

Estação	Período de Análise Homogeneidade e Tendência		
	Temperatura Máxima	Temperatura Mínima	Precipitação
Aimorés	1986-2010	1986-2010	1986-2010
Araçuaí	1990-2010	1990-2010	1990-2010
Araxá	DF	1989-2010	1989-2010
Arinos	1991-2010	1991-2010	1991-2010
Belo Horizonte	1989-2010	1989-2010	1989-2010
Capinópolis	1993-2010	1993-2010	1993-2010
Carbonita	1993-2010	1993-2010	1993-2010
Diamantina	1990-2010	1990-2010	1990-2010
Espinosa	1991-2010	1991-2010	1991-2010
Frutal	1992-2007	1992-2007	1992-2007
Janaúba	1992-2010	DF	1992-2010
Juiz de Fora	1993-2010	1993-2010	1993-2010
Montes Claros	1990-2010	1990-2010	1990-2010
Paracatu	1993-2010	1993-2010	1993-2010
Patos de Minas	1991-2010	1991-2010	1991-2010
Pedra Azul	DF	1991-2010	1991-2010
Pirapora	1989-2010	1989-2010	1989-2010
Pompéu	1989-2010	1989-2010	1989-2010
Salinas	1991-2010	1991-2010	1991-2010
São Lourenço	1989-2010	1989-2010	1989-2010
Sete Lagoas	1993-2010	1993-2010	1993-2010
Uberaba	1989-2010	1989-2010	1989-2010
Unaí	1991-2010	1991-2010	1991-2010
Viçosa	1968-2010	1968-2010	1968-2010

DF = Dados Faltantes

O preenchimento de falhas utilizando a metodologia de séries temporais de Box-Jenkins utiliza a própria série da estação para suprir a falta de dados. Como a metodologia é adequada à previsão futura, para o preenchimento da falha é necessário ter uma série temporal contínua num período anterior a falha para aplicação e ajuste dos modelos.

Para fins de comparação com o modelo geoestatístico espaço-tempo, foram utilizadas as mesma estações empregadas no modelo geoestatístico

espaço-temporal que possuíam um bom número de dados sem falhas (Tabela 3).

Tabela 2 – Estações utilizadas no modelo geoestatístico espaço-tempo

Estação	Latitude (°C)	Longitude (°C)	Altitude (m)
Araçuaí	-16,83	-42,05	289,0
Arinos	-15,90	-46,05	519,0
Espinosa	-14,91	-42,85	569,6
Formoso	-14,93	-46,25	840,0
Janaúba	-15,78	-43,30	516,0
Januária	-15,45	-44,00	473,7
João Pinheiro	-17,70	-46,16	760,4
Juramento	-16,78	-43,71	650,0
Mocimbo	-15,09	-44,02	452,0
Monte Azul	-15,16	-42,87	603,6
Montes Claros	-16,68	-43,83	646,3
Paracatu	-17,23	-46,88	712,0
Pedra Azul	-16,00	-41,28	648,9
Pirapora	-17,35	-44,91	505,2
Salinas	-16,16	-42,30	471,3
Unaí	-16,36	-46,55	460,0

Tabela 3 – Estações utilizadas no ajuste da metodologia de Box-Jenkins

Estações	Período Ajuste	Período de Verificação
Araçuaí	2000 a 2008	2009 e 2010
Arinos	2001 a 2008	2009 e 2010
Espinosa	1991 a 07/1998	11/1998 a 11/1999
Januária	1999 a 2008	2009 e 2010
Montes Claros	1991 a 2008	2009 e 2010
Salinas	1991 a 2008	2009 e 2010

Não foi possível obter nenhuma informação sobre o histórico de cada estação (metadado), mudanças na localização, condições de mediações, etc. Do mesmo modo, não foi possível fazer análises de consistência e nem aplicar testes relativos nos dados ou avaliar os modelos em algumas estações, devido à grande quantidade de falhas presentes nos dados.

3.1. Testes homogeneidade e tendência em séries de dados climatológicos

Em todas as séries mensais de temperatura máxima e mínima do ar e precipitação das estações, foram aplicados os seguintes testes: teste de Homogeneidade Normal Padrão (SNHT, Standard Normal Homogeneity Test) para um único ponto (ALEXANDERSSON; MOBERG, 1997; ALEXANDERSSON, 1986), teste de Pettitt (PETTITT, 1979) e teste de Buishand (BUISHAND, 1982), que permitem identificar o ano de ocorrência de descontinuidade (mudança abrupta na média) nas séries temporais.

Estes testes foram selecionados por serem amplamente utilizados para testar a homogeneidade em séries climatológicas. Domonkos (2006) avalia que ainda existem algumas dúvidas sobre a eficiência dos testes e não é possível selecionar um método com boa capacidade de detecção de não homogeneidade, sendo importante o uso combinado dos testes de homogeneidade.

Seja Y_i o i ésimo elemento de uma série temporal meteorológica em um total de n . Na sua forma mais simples, a estatística do teste SNHT é o valor máximo da função $T(k)$, em que:

$$T(k) = k(\bar{z}_1)^2 + (n - k)(\bar{z}_2)^2 \quad (1)$$

em que $\bar{z}_1$ e $\bar{z}_2$ são as médias aritméticas de Z_i de 1 a k e de $k+1$ até n anos da série padronizada (Z_i), respectivamente.

O valor de k , que corresponde ao valor máximo de $T(k)$, é o ano mais provável da mudança. Se o valor de $T(k)$ está acima de certo nível crítico, rejeita-se a hipótese de nulidade de homogeneidade ao nível de significância correspondente.

O teste de Pettitt é um teste não-paramétrico, ou seja, não é necessário especificar uma distribuição de probabilidade. Sua formulação matemática é baseada no número de ordem correspondente à ordenação crescente dos valores ou elementos da série. A estatística do teste é definida para cada ponto da série, sendo obtida por:

$$U_k = 2 \sum_{i=1}^k O_i - k(n+1) \quad (2)$$

em que n , total de elementos da série; $k=1, 2, (n-1)$ e O_i , ordem da i ésima observação, quando os valores da série $Y_1, \dots, Y_n$ são ordenados em ordem crescente.

O valor de k , que corresponde ao máximo em valor absoluto de U_i , é estimado como o ano onde ocorre a mudança.

Assim, a estatística $K(t)$ do teste de Pettitt será:

$$K(t) = \max_{1 \leq k \leq n} |U_k| \quad (3)$$

O teste Buishand é definido por:

$$S_k = \sum_{i=1}^k (Y_i - \bar{Y}) \quad (4)$$

em que, Y é a série em teste e $\bar{Y}$ é a média aritmética da série; $k= 1, 2, \dots, n$.

Se não existe mudança significativa na média, o termo S_k irá flutuar em torno de zero.

A estatística Q do teste Buishand é dada por:

$$Q = \max_{1 \leq k \leq n} |S_k| \quad (5)$$

Se há uma ruptura ou mudança na série no ano k , então S_k tem um máximo (deslocamento negativo) ou um mínimo (deslocamento positivo) nas proximidades do ano $k = K$.

Para efeito de classificação das séries testadas quanto à homogeneidade, utilizou-se o critério proposto por Wijngaard et al. (2003), empregado também por Morauto et al. (2010), Sahin e Cigizoglu (2010) e Costa e Soares (2009a). As séries foram agrupadas em três classes distintas, tendo-se por base o número de testes de homogeneidade que rejeitam a hipótese de nulidade para um nível de significância de 5%.

Classe 1 (U): úteis (série homogênea) - quando nenhum teste rejeita a hipótese de nulidade;

Classe 2 (D): duvidosas - quando um ou dois testes rejeitam a hipótese de nulidade;

Classe 3 (NH): séries não homogêneas - quando todos os testes rejeitam a hipótese de nulidade.

Esta classificação confere credibilidade ao uso de séries de dados climáticos em estudos de variabilidade, tendência e extremos climáticos. Assim, considera-se que nas séries classificadas como 'úteis' não foi detectado nenhum sinal evidente de não homogeneidade e, ou, descontinuidade, e as séries podem ser usadas em estudos de tendência e de variabilidade climática. Logo, os estudos baseados na utilização de séries rotuladas como 'duvidosas' devem ser interpretados com cautela, uma vez que os resultados de alguns dos testes indicam a presença de não homogeneidades.

Os valores críticos das estatísticas de teste para os níveis de significância de 1% e 5%, em função do número n de elementos da série investigada, podem ser obtidos em Buishand (1982); Jarusková (1994); Alexandersson e Moberg (1997); Wijngaard et al. (2003) e Sahin e Cigizoglu (2010).

Como o período de dados disponíveis possui muitas falhas, não foi possível proceder à análise de testes de homogeneidade relativos devido à falta simultânea de dados em estações próximas e ao tamanho das séries contínuas.

Para analisar e identificar tendência nos dados meteorológicos foram utilizados os testes da regressão e o teste de Mann-Kendall.

A análise de regressão pode ser utilizada para indicar alterações climáticas por meio do teste de significância do coeficiente de regressão (coeficiente angular). O teste considera a regressão linear entre a variável aleatória Y (série meteorológica) e o tempo (X). O teste paramétrico t avalia se o coeficiente de regressão b é significativamente diferente de zero, o que indica a presença de uma tendência linear (LONGOBARDI; VILLANI, 2010).

A tendência é obtida por uma regressão linear simples, dada por:

$$Y = a + bX \quad (6)$$

em que X é o tempo e Y é série meteorológica.

Os parâmetros a e b são determinados pelo método dos mínimos quadrados. O teste consiste em determinar o intervalo de confiança do coeficiente b, sendo que se este intervalo não inclui o valor zero, a tendência é significativa. O sinal do coeficiente de regressão irá indicar se a tendência é positiva ou negativa.

A estatística de teste do coeficiente de regressão é dada por:

$$t = \frac{\hat{\beta}}{s / \sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}} \quad (7)$$

em que $\hat{\beta}$, valor estimado do coeficiente de regressão e s, é o desvio padrão estimado dos erros.

t tem distribuição t de Student com n-2 graus de liberdade.

A hipótese nula de que não existe tendência ($H_0: \beta = 0$) é rejeitada quando o valor absoluto de t calculado pela equação 7 é maior do que o valor absoluto tabelado $t_{\alpha/2}$. O teste t avalia se o coeficiente angular da regressão linear é significativamente diferente de zero, indicando a presença de uma tendência linear. Nesse caso, o coeficiente angular dessa regressão representa a mudança na série histórica.

O teste de Mann-Kendall (MANN, 1945; KENDALL, 1975) considera que, na hipótese de estabilidade de uma série temporal, a sucessão de valores ocorre de forma independente e a distribuição de probabilidade deve permanecer sempre a mesma (série aleatória). Considerando uma série temporal de Y_i de n termos ($1 \leq i \leq n$); a estatística de teste é dada por:

$$S = \sum_{j=i+1}^n \text{ sinal}(Y_j - Y_i) \quad (8)$$

em que $\text{senal}(x) = 1$ para $x > 0$; $\text{senal}(x) = 0$ para $x = 0$; $\text{senal}(x) = -1$ para $x < 0$.

Para séries com grande número de termos (n), sob a hipótese nula (H_0) de ausência de tendência, S apresenta uma distribuição normal com média zero e variância:

$$\text{Var}(S) = n(n-1)(2n-5)/18 \quad (9)$$

Testando a significância estatística de S para a hipótese nula usando um teste bilateral, esta pode ser rejeitada para grandes valores da estatística Z , que é dada por:

$$Z = \begin{cases} S - 1/\text{Var}(S) & \text{se } S > 0 \\ 0 & \text{se } S = 0 \\ S + 1/\text{Var}(S) & \text{se } S < 0 \end{cases} \quad (10)$$

Com base na análise da estatística Z é tomada a decisão de aceitar ou rejeitar H_0 , ou seja, pode-se confirmar a hipótese de estabilidade dos dados ou rejeitá-la a favor da hipótese alternativa (de existência de tendência nos dados). O sinal da estatística Z indica se a tendência é crescente ($Z > 0$) ou decrescente ($Z < 0$). Em um teste bilateral para tendência, H_0 deve ser aceita se $|Z| \leq Z_{\alpha/2}$, em que o valor de $Z_{\alpha/2}$ é obtido da tabela normal padrão.

3.2. Metodologia de Box-Jenkins

A metodologia de Box-Jenkins (1976) é a principal técnica de previsão de séries temporais. Ela se baseia, em resumo, na identificação de um modelo para descrever o comportamento da série, cujos modelos matemáticos visam captar a correlação seriada ou autocorrelação entre os valores da série temporal e, com base nesse comportamento, realizar previsões futuras.

A metodologia de Box-Jenkins é fundamentada na modelagem da estrutura de autocorrelação entre as observações da série temporal. Dessa forma, o modelo ajustado captura a dinâmica dos dados observados na série passada para realizar previsões em curto prazo. Como a metodologia é adequada à previsão futura, para o preenchimento das falhas é necessário ter uma série temporal contínua num período anterior à falha para aplicação e ajuste do modelo.

Os modelos ajustados pela metodologia de Box-Jenkins são denominados ARIMA (***Autoregressive Integrated Moving Average***, termo em Inglês). O termo autorregressivo corresponde à defasagem da série transformada (isto é, série estacionária obtida por diferenciação) e as médias móveis as defasagens dos erros aleatórios. O termo "integrado" refere-se ao processo de diferenciação da série original para torná-la estacionária. O modelo tem duas formas gerais: o ARIMA (p,d,q) e o ARIMA sazonal multiplicativo (p,d,q) $\times$ (P,D,Q); em que p e q são os parâmetros não sazonais autorregressivos e média móveis, P e Q são os parâmetros sazonais autorregressivos e média móveis, d e D são as diferenciações não sazonal e sazonal, respectivamente.

A metodologia tem como premissa básica de que a série temporal seja gerada por um processo estocástico, cuja natureza pode ser representada por meio de um modelo. Um processo estocástico temporal envolve sempre uma variação de uma função no tempo. Segundo Serrano et al. (2004), a diferença fundamental entre um processo estocástico e uma variável aleatória é exatamente a determinação de estrutura de dependência ou correlação. Os processos estocásticos temporais podem ser considerados funções que variam no tempo, mas que têm uma intensidade que varia de forma aleatória.

Para estabelecer um modelo é necessário que a série seja estacionária. Para aplicações práticas, é suficiente que as séries sejam fracamente estacionárias, isto é, a média e variância devem se manter constantes ao longo do tempo e a função de autocorrelação depender apenas da defasagem entre os instantes de tempo.

As funções de autocorrelação (FAC) e autocorrelação parcial (FACP) são essenciais na metodologia de Box-Jenkins. A FAC indica o grau de

dependência temporal existente, medindo o quanto os pares ordenados de observações estão relacionados. Os parâmetros associados ao modelo autorregressivo integrado a médias móveis (ARIMA) são selecionados através da análise das características da função de autocorrelação (FAC) e da função de autocorrelação parcial (FACP).

As séries temporais meteorológicas possuem um componente sazonal significativo, pois a dependência do passado tendem a ocorrer mais fortemente em múltiplos de 12. Assim, é introduzido um componente sazonal à metodologia Box-Jenkins, o qual é denominado SARIMA. O modelo SARIMA é estruturado da seguinte forma:

$$\Phi_P(B^S) \varphi_p(B) (1-B)^d (1-B^S)^D Y_t = \Theta_Q(B^S) \theta_q(B) e_t \quad (11)$$

em que $\Phi_P(B^S) = 1 - \Phi_1 B^S - \Phi_2 B^{2S} - \dots - \Phi_P B^{PS}$, representa o polinômio sazonal autorregressivo de ordem P; $\varphi_p(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p$, representa polinômio autorregressivo de ordem p; $\Theta_Q(B^S) = 1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_Q B^{QS}$, representa polinômio sazonal de médias móveis de ordem Q; $\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$, representa o polinômio de médias móveis de ordem q; B, operador de retardo, tal que $B^S Y_t = Y_{t-S}$; d, número de diferenças simples necessárias para retirar a tendência; D, número de diferenças sazonal necessárias para retirar a sazonalidade da série; Y_t , série dados original e e_t , resíduo aleatório.

Para a construção do modelo, Box et al. (2008) e Box e Jenkins (1976) indicam três etapas de um processo iterativo, que são: identificação, estimação e diagnóstico dos parâmetros.

Em um modelo adequado, os resíduos devem ser aleatórios e não correlacionados, isto é, independentes e identicamente distribuídos, com média zero e variância constante (série estacionária).

Os modelos de séries temporais são adequados para previsão de dados futuros, baseados na distribuição passada da série temporal. Sendo assim, para a aplicação dessas metodologias para o preenchimento de falhas é necessário que a falha seja considerada um evento no tempo futuro e que antes da falha tenha uma série histórica contínua para construção do modelo.

3.3. Modelo Geoestatístico Espaço-Tempo

As técnicas de geoestatística foram desenvolvidas para predição em dados de mineração e vem sendo extensivamente utilizadas para modelar a dependência espaço-tempo (GETHING et al., 2008; KYRIAKIDIS; JOURNEL, 1999).

Gething et al. (2008) destacam que no paradigma geoestatístico espaço-tempo, o valor de um atributo de interesse z em qualquer localização no espaço u_0 no instante de tempo t_0 é modelado como uma realização da variável aleatória espaço temporal, $Z(u_0, t_0)$.

Seja $Z(u, t)$ uma variável aleatória observada em n localizações $u_1, u_2, \dots, u_n$ e em cada localização tenha uma série temporal de T tempos distintos. Dessa forma, $Z(u_\alpha, t_i)$ com $\alpha = 1, 2, \dots, n$; $i = 1, 2, \dots, T$ é um conjunto de variáveis aleatórias espaço-tempo.

Para fazer previsões da variável aleatória $Z(\cdot)$ para localizações não amostradas u em um determinado tempo t , foi utilizado o modelo geoestatístico espaço-tempo proposto por Høst et al. (1995) e adaptado por Kyriakidis e Journel (1999). Nesse modelo $Z(u, t)$ é decomposto em:

$$Z(u, t) = M_1(u) + R_2(t) + S(u, t)R(u, t) = M_1(u) + R_2(t) + S(u)S(t)R(u, t) \quad (12)$$

em que $M_1(u)$, componente puramente espacial que representa a variação média espacial; $R_2(t)$, componente de séries temporais com média zero que funciona como uma correção temporal de $M_1(u)$; $R(u, t)$, resíduo espaço-temporal com média zero e variância um e $S(u, t)$, componente espaço-temporal que modela o desvio padrão da variável aleatória $Z(\cdot)$, sendo decomposta em um produto puramente espacial $S(u)$ e um componente puramente temporal $S(t)$.

As previsões da variável aleatória $Z(\cdot)$ são feitas para uma localização fixa (u_0) para toda a série temporal (t), dada por:

$$\hat{Z}(u_0, t) = \hat{M}_1(u_0) + \hat{R}_2(t) + \hat{S}(u_0)\hat{S}(t)\hat{R}(u_0, t) \quad (13)$$

Bicalho (2008); Ribeiro e Mingoti (2007) e Kyriakidis e Journel (1999) apresentam as seguintes equações para o cálculo das estimativas:

$M_1(\mathbf{u})$ é estimada como a média aritmética temporal dos valores observados em t tempos em cada localização α .

$$M_1(u_\alpha) = \frac{1}{T} \sum_{i=1}^T Z(u_\alpha, t_i) \quad (14)$$

$$\hat{M}_1(u_0) = \sum_{\alpha=1}^n \lambda(u_\alpha) M_1(u_\alpha) \quad (15)$$

em que $\lambda(u_\alpha)$ são os pesos atribuídos por krigagem a $\hat{M}_1(u_0)$, que são obtidos por krigagem dos dados de $M_1(u_\alpha)$.

O estimador $\hat{R}_2$, a cada instante de tempo t_i , são calculados pela combinação de pesos lineares:

$$\hat{R}_2 = \sum_{\alpha=1}^n \lambda(u_\alpha) [Z(u_\alpha, t_i) - \hat{M}_1(u_\alpha)] \quad i = 1, \dots, T \quad (16)$$

As estimativas dos componentes $S_1(u)$, $S_2(t)$ e $R(u, t)$ nas estações estudadas u_α , $\alpha = 1, 2, \dots, n$ são obtidas por:

$$\hat{S}_1^2(u_\alpha) = \frac{1}{T} \sum_{i=1}^T [Z(u_\alpha, t_i) - \hat{M}_1(u_\alpha) - \hat{R}_2(t_i)]^2 \quad (17)$$

$$\hat{S}_2^2(t_i) = \frac{1}{w^2} \sum_{\alpha=1}^n \lambda(u_\alpha) [Z(u_\alpha, t_i) - \hat{M}_1(u_\alpha) - \hat{R}_2(t_i)]^2 \quad (18)$$

$$\hat{R}(u_\alpha, t_i) = \frac{[Z(u_\alpha, t_i) - \hat{M}_1(u_\alpha) - \hat{R}_2(t_i)]}{\hat{S}_1(u_\alpha) \hat{S}_2(t_i)} \quad (19)$$

$$w^2 = \sum_{\alpha=1}^n \lambda(u_\alpha) [\hat{S}_1^2(u_\alpha)] \quad (20)$$

O modelo espaço-tempo proposto por Høst et al. (1995) é uma extensão de um modelo geoestatístico e que inclui a componente temporal, ou seja, incorpora-se na predição espacial a informação dos vizinhos ao

longo do tempo, e, conseqüentemente este modelo é incapaz de prever observações em tempos não amostrados (Bicalho, 2008).

O modelo escolhido não é necessariamente o melhor, mas por ser de fácil utilização e estar disponível no software R, pode ser empregado por qualquer usuário com conhecimentos de geoestatística. A implementação deste modelo foi desenvolvida por Ribeiro e Mingoti (2006 e 2007) no software R a partir da versão 2.2.0. De Iaco et al. (2010) enfatizam que a falta de software, ainda é, o principal problema quando se analisa dados espaço-temporais multivariados.

Bicalho (2008) destaca que as metodologias de Høst et al. (1995) e de Kyriakidis e Journel (1999), embora muito mencionadas na literatura, não foram implementadas em trabalhos práticos publicados.

O modelo geoestatístico espaço-temporal proposto somente permite previsão de Z para uma localidade s_0 nos tempos que foram avaliados na amostra. Logo, para estimar Z em uma localidade qualquer em um determinado tempo t , é necessário que se tenha informações da vizinhança deste ponto a ser predito no mesmo instante de tempo t , pois, caso contrário, esta previsão não pode ser feita. Dessa forma, a estação com dados faltantes a ser preenchida é retirada da base de dados para gerar o modelo.

3.4. Desempenho estatístico dos modelos

Para averiguar a adequabilidade dos modelos de Box-Jenkins e espaço-tempo, em cada série analisada, alguns períodos foram deixados de fora do ajuste do modelo para teste de verificação. Segundo Monbet et al. (2007), um modelo pode ser avaliado comparando as estatísticas da série histórica observada com as estatísticas correspondentes do modelo e comparações gráficas, mas esta última não permite medir a qualidade do ajuste do modelo. Desta forma, os dados observados foram comparados com as previsões do modelo; utilizando as seguintes medidas estatísticas: coeficiente de determinação (r^2), raiz do erro quadrático médio (RMSE, sigla

em inglês), o erro absoluto médio (MAE, sigla em inglês), viés médio (MBE, sigla em inglês) e o índice de concordância (d) de Willmott (1982).

O coeficiente de determinação (r^2) descreve a proporção da variância do modelo em relação à variância total dos dados observados que pode ser explicada pelo modelo. Os valores de r^2 variam de 0 a 1, sendo que quanto mais próximo de 1 melhor é o ajuste, isto é, mais preciso é o modelo. O coeficiente de determinação é calculado por:

$$r^2 = \frac{\left(\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P}) \right)^2}{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2} \quad (21)$$

em que O_i , valores observados. As barras referem-se às médias dessas variáveis e P_i , valores previsto (estimados) pelo modelo;

O RMSE, MAE e MBE são medidas de erros usados para representar as diferenças médias entre os valores preditos pelo modelo (P) e os valores observados (O). O RMSE fornece uma informação em relação à dispersão dos dados, ou seja, o grau de espalhamento obtido na correlação entre os valores preditos e os observados. O MAE representa o erro máximo, sendo menos sensível a valores extremos. O MBE informa o quanto os valores preditos superestimam ou subestimam os valores observados. O RMSE, o MAE e o MBE são calculados, respectivamente, por:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (22)$$

$$MAE = \frac{\sum_{i=1}^n |P_i - O_i|}{n} \quad (23)$$

$$MBE = \frac{\sum_{i=1}^n (P_i - O_i)}{n} \quad (24)$$

em que n , é o número de observações.

O índice de concordância de Willmott (d) mede o grau em que os valores preditos (P) se aproximam dos observados (O). Este índice varia de 0 a 1, sendo que, 0 indica nenhuma concordância e 1, uma concordância perfeita. O índice (d) é dado por:

$$d = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (|P_i - \bar{O}| + |O_i - \bar{O}|)^2} \quad (25)$$

As análises foram realizadas utilizando os seguintes softwares: R, Excel 2007, Minitab, e Statistica 8.

4. RESULTADOS E DISCUSSÃO

4.1. Homogeneidade

Os testes de homogeneidade (Tabelas 4 e 5) mostram que 73% das séries mensais de temperatura máxima do ar foram consideradas homogêneas, ao nível de 5%, pelos três testes analisados e foram classificadas como úteis, 8% classificadas como duvidosa e 12% das séries foram detectadas por mais de dois testes como tendo uma mudança significativa na média, sendo assim, foram classificadas como não-homogêneas (Figura 3A). Para as séries mensais de temperatura mínima do ar, a classificação foi muito similar, com 71%, 8% e 16% classificadas como úteis, duvidosas e não-homogêneas, respectivamente (Figura 3B).

Tabela 4 – Classificação mensal das séries de temperatura máxima do ar

ESTAÇÕES	Janeiro	Fevereiro	Março	Abril	Mai	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro	Anual
Aimorés	U	U	U	U	U	U	U	NH 1996*	U	U	U	U	U
Araçuaí	U	U	U	U	U	U	DF	D 1992*	U	U	U	U	DF
Araxá	DF	DF	DF	DF	DF	DF	DF	DF	DF	DF	DF	DF	DF
Arinos	U	U	U	U	U	U	U	DF	DF	DF	U	U	DF
Belo Horizonte	U	U	U	U	U	U	U	NH 92/93**	U	D 1999*	U	U	U
Capinópolis	NH 99/02**	D 97/99*	NH 1998**	NH 2002**	NH 99/00**	D 96/00*	NH 96/99*	NH 96/98**	D 1998*	D 00/02*	NH 1997**	NH 96/99**	NH 96/99**
Carbonita	U	U	U	U	U	U	U	U	U	U	U	U	U
Diamantina	U	DF	U	U	U	U	DF	NH 92/93*	U	U	U	U	DF
Espinosa	U	U	U	U	U	U	U	DF	DF	DF	U	U	DF
Frutal	U	U	U	U	U	U	U	D 1993*	U	U	U	U	U
Janaúba	D 1992**	D 1992*	U	U	U	U	U	DF	DF	DF	DF	D 1992*	DF
Juiz de Fora	U	U	NH 2000*	NH 2000*	NH 1999**	NH 1999**	U	U	U	U	U	U	NH 99/00*
Montes Claros	D 1992*	U	U	U	U	U	U	U	U	U	U	U	U
Paracatu	U	U	U	U	U	U	U	U	NH 1999*	U	U	U	NH 2003**
Patos de Minas	U	U	U	DF	U	U	U	U	U	U	U	U	D 1992**
Pedra Azul	DF	DF	DF	DF	DF	DF	DF	DF	DF	DF	DF	DF	DF
Pirapora	U	U	U	U	U	U	U	D 1991*	U	U	U	U	U
Pompéu	U	U	U	U	D 1998*	NH 1998*	U	NH 93/01**	U	U	U	U	NH 92/94*
Salinas	U	U	U	U	U	U	U	U	U	U	U	U	U
São Lourenço	DF	U	U	D 2002*	NH 95/98**	U	U	U	U	U	D 1997*	NH 1997**	DF
Sete Lagoas	U	U	U	U	U	U	U	U	U	U	U	U	U
Uberaba	D 1997*	NH 93/97*	NH 97/00**	NH 1997**	NH 99/01**	NH 1997**	NH 97/05**	NH 1993*	NH 93/02*	D 1993*	U	NH 1996*	NH 1997**
Unaí	U	D 1993*	U	U	U	D 1997*	U	DF	DF	DF	U	U	DF
Viçosa	U	U	U	NH 1985**	U	U	D 1992*	NH 1994**	NH 1992 **	D 76/92*	U	U	NH 1992**

U: Úteis

D: Duvidosas

NH: Não-Homogênea

DF: Dados Faltantes

* Significativo a 5%

** Significativo a 1%

Tabela 5 – Classificação mensal das séries de temperatura mínima do ar

ESTAÇÕES	Janeiro	Fevereiro	Março	Abril	Maio	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro	Anual
Aimorés	D 1993*	U	U	U	U	U	U	U	U	U	U	U	U
Araçuaí	U	U	U	U	U	U	DF	U	U	D 1992*	U	U	DF
Araxá	U	U	U	U	U	U	U	U	U	U	U	U	D 1993*
Arinos	D 1997*	NH 1997*	D 2004*	U	U	U	U	DF	DF	DF	U	U	DF
Belo Horizonte	U	U	U	U	U	U	D 1989*	U	U	U	U	U	NH 96*/97**
Capinópolis	U	U	U	U	U	U	U	U	U	U	U	U	U
Carbonita	U	D 2003*	U	NH 2003*	U	U	U	U	U	U	U	U	U
Diamantina	D 1993*	U	U	U	U	U	DF	U	U	NH 91/03/04*	U	U	DF
Espinosa	U	U	U	U	U	U	D 2002*	DF	DF	DF	U	U	DF
Frutal	U	U	U	NH 2000*	U	U	U	U	U	U	U	U	U
Juíz de Fora	U	U	U	U	U	U	U	U	U	U	U	U	U
Montes Claros	U	U	U	U	U	U	U	U	U	NH 2003*	NH 2002*	U	D 2000*
Paracatu	NH 2005*	U	U	U	U	U	U	U	U	U	U	NH 2003*	NH 2005*
Patos de Minas	U	U	U	DF	NH 1995*	U	U	U	U	U	U	U	DF
Pedra Azul	DF	NH 95/97**	NH 1994*	U	U	U	U	DF	DF	DF	NH 94/95**	NH 94/95**	DF
Pirapora	NH 93/94/ 01**	D 1997*	U	U	U	U	U	U	D 1995*	NH 2003*	U	D 1992*	NH 1997*
Pompéu	D 1994*	U	NH 1997*	U	U	NH 1997*	D 1998*	NH 1997*	NH 1996*	NH 1999*	NH 2000**	NH 92/96**	NH 1997**
Salinas	U	D 2003*	U	U	U	U	U	U	U	U	U	U	U
São Lourenço	DF	U	U	D 2002*	NH 95/98**	U	U	U	U	U	D 1997*	NH 1997**	DF
Sete Lagoas	U	U	U	U	U	U	U	U	U	D 2003*	U	U	D 1997*
Uberaba	NH 1996**	NH 1997**	NH 1997**	NH 2000**	U	D 1997*	D 1997*	U	NH 1996**	NH 96/97**	NH 1999**	NH 2001**	NH 1997*
Unaí	U	U	U	U	U	U	U	U	DF	DF	U	U	DF
Viçosa	NH 79/84**	NH 1982**	NH 1980**	NH 82/86**	NH 73/78**	U	D 1989*	U	U	NH 81/03*	NH 1999**	NH 78/94 95	NH 79/81**

U: Úteis

D: Duvidosas

NH: Não-Homogênea

DF: Dados Faltantes

* Significativo a 5%

** Significativo a 1%




Figura 3 – Porcentagem de classificação das séries mensais de temperatura máxima do ar (A) e de temperatura mínima do ar (B).

Em todas as análises, os três testes apresentaram uma concordância na detecção do ano de mudança (descontinuidade) nas séries. Quando dois dos três testes detectaram mudança no mesmo ano, este foi considerado como o ano de ruptura. Existem apenas algumas séries para as quais os três testes indicaram diferentes anos, sendo que, em geral, as discrepâncias ocorreram em anos próximos. Martínez et al. (2010) também, verificaram essa concordância entre os testes estudando a média anual diária de temperaturas máximas e mínimas em Catalonia, Espanha.

De maneira geral, não existe uma relação clara entre as mudanças significativas encontradas para a temperatura máxima e mínima do ar em uma determinada estação. Por outro lado, algumas estações como Uberaba corresponde a uma exceção, com o ano de 1997 sendo o principal ano de mudança na média para os meses de fevereiro, março, junho e julho, tanto para a temperatura máxima como para a temperatura mínima (Figura 4).




Figura 4 – Mês e ano de mudança significativa no comportamento da temperatura máxima e mínima do ar na estação de Uberaba.

Para a estação de Capinópolis, situada na mesma região geográfica de Uberaba, em todos os meses foram detectadas mudanças significativas entre o fim da década de 1990 e início de 2000 na temperatura máxima do ar (Tabela 4), com destaque para o ano de 1999. Porém, para a temperatura mínima todos os meses foram considerados homogêneos (Tabela 5).

Observou-se que, mesmo em estações vizinhas e altamente correlacionadas, geralmente não existe uma boa concordância entre os pontos significativos de mudança. Contudo, para a temperatura mínima do ar, o ano de 2000 foi significativo no mês de abril para as estações de Frutal e Uberaba e o ano de 2003, no mês de outubro, para as estações Montes Claros e Pirapora (Tabela 5). Já para a temperatura máxima do ar, o ano 1992 foi significativo em janeiro para Janaúba e Montes Claros (Tabela 4). Esses resultados similares, em estações pertencentes à mesma região climática, podem indicar mudanças. No entanto, quando um ponto de descontinuidade é observado somente em uma estação e não detectado pelas outras estações próximas, pode ser um indicativo que esta não homogeneidade seja provocada por fatores não climáticos. Entretanto, para averiguar essas hipóteses é indispensável o conhecimento de todo o histórico de cada estação, o metadado.

Pelo fato de que os conjuntos de dados analisados, neste estudo, não conterem informações de metadados, fazer qualquer inferência definitiva se as não homogeneidades encontradas foram causadas por fatores não

climáticos, tornando-se uma tarefa complicada, sendo difícil justificar com precisão os anos em que ocorreram tais mudanças.

A maioria das mudanças significativas ocorreu entre os anos de 1992 a 1999, com destaque para o ano de 1997, sendo este o ano com maior número de mudanças detectadas, tanto na temperatura máxima quanto na mínima do ar (Figura 5). Minuzzi et al. (2010) analisando a temperatura do ar no período de 1961 a 2004, com 10 estações meteorológicas localizadas no estado de Minas Gerais, verificaram que as mudanças nos extremos da temperatura do ar ocorreram na década de 1990, principalmente, no início (1992) e no final deste período (entre 1997 e 2000). Apesar de não haver uma ferramenta estatística para avaliar as mudanças causadas por procedimentos de observação, instrumentação ou localização da estação, devido à falta de metadados, é muito pouco provável que essas causas ocorram ao mesmo tempo para a maioria das estações. Mas, sem os metadados, não se pode afirmar com segurança.




Figura 5 – Distribuição do número de mudanças significativas por ano para temperatura máxima e temperatura mínima do ar.

Considerando os resultados dos testes, em base mensal, para a temperatura máxima do ar, no mês de agosto, houve um maior número de estações com mudanças significativas, principalmente nos anos de 1992 e 1993. Para a temperatura mínima do ar, em vários meses ocorreram

mudanças. No entanto, no mês de agosto, apenas uma estação (Pompéu), apresentou não-homogeneidade (Figura 6).




Figura 6 – Distribuição do número de mudanças significativas por mês para temperatura máxima e temperatura mínima do ar.

Devido às análises compreenderem um período mais recente, esperava-se que houvesse pouca não homogeneidade. Pois, em anos mais recentes, espera-se que a confiabilidade dos dados seja maior.

As análises de homogeneidade realizadas nos totais mensais de precipitação, não indicaram mudanças significativas na média das séries. Cabe ressaltar, que o teste de Pettitt não é muito adequado aos dados de precipitação, pois, em sua formulação ele considera as ordens (ranks) e como nos meses de inverno chove menos, com muitos valores iguais a zero nos dados de precipitação, essas ordens não são bem representadas. Além disso, o teste SHNT é indicado para dados com distribuição normal, o que não ocorre em dados de precipitação.

4.2. Tendência

Os resultados mensais do teste de Mann-Kendall e teste t para o coeficiente de regressão são apresentados nas Figuras 7, 8 e 9 e nas Tabelas 6, 7 e 8 para cada estação. Verifica-se uma boa concordância entre os testes na detecção de tendência.

De maneira geral, as séries de temperatura mínima do ar apresentaram mais tendência do que a temperatura máxima do ar. Blain (2011), também, verificou esse padrão ao analisar séries mensais de temperatura máxima e mínima do ar em seis localidades no estado de São Paulo. Observou-se, mais tendências de aumento do que de decréscimo, enquanto que, para a temperatura máxima do ar, o mês de agosto apresentou o maior índice de tendência significativa. Para a temperatura mínima do ar, não houve tendência nesse mês, com outubro sendo o mês mais sujeito a tendências na temperatura mínima do ar. Para os dois elementos climáticos, setembro configurou-se como o mês com o menor número de tendência significativa.

Para a estação de Uberaba, considerada em muitos trabalhos como referência, os testes indicaram o maior número de meses com tendência de aumento (Figuras 7 e 8 e Tabelas 6 e 7). Nas séries de temperatura máxima do ar, em todos os meses foi observada tendência. Na análise do coeficiente de regressão, constatou-se que, a tendência anual representa em média um aumento de 1,068 °C por década para a temperatura máxima do ar (Figura 10), sendo que no mês de setembro, verificou-se um maior aumento, da ordem de 1,7 °C por década. Com relação à temperatura mínima do ar, apenas os meses de maio, junho e agosto não apresentaram tendência significativa de aumento. Mas nos meses em foi significativa, para a temperatura mínima do ar, essa tendência não chega a ultrapassar 1,0 °C por década, com exceção dos meses de setembro e outubro, nos quais se verificou um aumento de 1,2 e 1,3 °C por década, respectivamente.




Figura 7 – Distribuição mensal dos valores de Z do teste de Mann-Kendall para a temperatura mínima do ar.






Figura 8 – Distribuição mensal dos valores de Z do teste de Mann-Kendall para a temperatura máxima do ar.




Figura 9 – Distribuição mensal dos valores de Z do teste de Mann-Kendall para a precipitação.

Tabela 6 – Valor p dos coeficientes de regressão para temperatura máxima do ar

Estação	Janeiro	Fevereiro	Março	Abril	Mai	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro	Anual
Aimorés	0,777	0,887	0,653	0,890	0,662	0,127	0,249	0,008**	0,125	0,066	0,437	0,044*	0,088
Araçuaí	0,327	0,478	0,841	0,829	0,936	0,523	0,910	0,011*	0,336	0,046*	0,444	0,782	0,329
Arinos	0,112	0,203	0,395	0,753	0,610	0,792	0,197	0,136	0,063	0,174	0,173	0,197	0,046*
Belo Horizonte	0,696	0,711	0,819	0,633	0,893	0,363	0,047*	0,002**	0,554	0,044*	0,761	0,987	0,095
Capinópolis	0,000**	0,020*	0,002**	0,000**	0,001**	0,028*	0,041*	0,014*	0,109	0,012*	0,003**	0,003**	0,000**
Carbonita	0,904	0,988	0,951	0,508	0,340	0,617	0,617	0,389	0,764	0,465	0,719	0,695	0,529
Diamantina	0,256	0,059	0,528	0,966	0,070	0,659	0,014*	0,017*	0,110	0,093	0,766	0,429	0,024*
Espinosa	0,534	0,729	0,475	0,487	0,435	0,496	0,586	0,157	0,439	0,582	0,464	0,445	0,670
Janaúba	0,115	0,377	0,521	0,620	0,643	0,539	0,388	0,125	0,314	0,139	0,463	0,364	0,194
Juiz de Fora	0,670	0,523	0,016*	0,028*	0,001**	0,181	0,470	0,185	0,224	0,338	0,455	0,448	0,013*
Montes Claros	0,478	0,792	0,435	0,335	0,991	0,540	0,592	0,182	0,785	0,072	0,365	0,053	0,366
Paracatu	0,316	0,578	0,694	0,621	0,910	0,636	0,494	0,131	0,303	0,866	0,961	0,318	0,271
Patos de Minas	0,172	0,309	0,321	0,556	0,503	0,668	0,715	0,438	0,220	0,207	0,563	0,634	0,055
Pirapora	0,749	0,592	0,764	0,132	0,547	0,746	0,301	0,084	0,145	0,221	0,427	0,467	0,321
Pompeu	0,269	0,146	0,213	0,527	0,022*	0,047*	0,028*	0,000**	0,032*	0,054	0,447	0,216	0,002**
Salinas	0,199	0,617	0,882	0,548	0,493	0,768	0,743	0,100	0,382	0,279	0,343	0,386	0,473
São Lourenço	DF	0,236	0,365	0,006**	0,001**	0,069	0,376	0,925	0,428	0,880	0,033*	0,001**	0,029*
Sete Lagoas	0,602	0,780	0,788	0,596	0,201	0,343	0,739	0,451	0,875	0,742	0,666	0,368	0,927
Uberaba	0,024*	0,002**	0,002**	0,005**	0,000**	0,002**	0,000**	0,001**	0,005**	0,032*	0,031*	0,005**	0,000**
Unai	0,075	0,193	0,445	0,834	0,306	0,367	0,116	0,021*	0,065	0,427	0,178	0,348	0,032*
Viçosa	0,882	0,265	0,610	0,005**	0,656	0,594	0,044*	0,035*	0,011*	0,002**	0,353	0,249	0,003**

DF: Dados Faltantes

* Significativo a 5%

** Significativo a 1%

Tabela 7 – Valor p dos coeficientes de regressão para temperatura mínima do ar

Estação	Janeiro	Fevereiro	Março	Abril	Mai	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro	Anual
Aimorés	0,182	0,914	0,152	0,680	0,082	0,343	0,674	0,506	0,428	0,673	0,418	0,646	0,800
Araçuaí	0,089	0,247	0,429	0,423	0,535	0,917	0,742	0,579	0,704	0,019*	0,383	0,911	0,278
Araxá	0,052	0,295	0,263	0,555	0,839	0,739	0,435	0,741	0,477	0,093	0,486	0,561	0,100
Arinos	0,198	0,014*	0,017*	0,733	0,749	0,729	0,285	0,299	0,916	0,090	0,059	0,090	0,002**
Belo Horizonte	0,351	0,191	0,134	0,551	0,860	0,156	0,036*	0,069	0,470	0,024*	0,281	0,089	0,000**
Capinópolis	0,802	0,748	0,404	0,731	0,297	0,478	0,410	0,979	0,634	0,985	0,777	0,420	0,674
Carbonita	0,053	0,113	0,173	0,262	0,861	0,279	0,498	0,434	0,288	0,463	0,170	0,458	0,154
Diamantina	0,227	0,316	0,259	0,866	0,791	0,435	0,423	0,235	0,168	0,001**	0,129	0,736	0,055
Espinosa	0,222	0,979	0,617	0,638	0,153	0,667	0,226	0,272	0,470	0,081	0,452	0,477	0,846
Juiz de Fora	0,409	0,945	0,242	0,285	0,881	0,609	0,658	0,448	0,266	0,219	0,391	0,747	0,389
Montes Claros	0,114	0,043*	0,041*	0,078	0,792	0,914	0,699	0,476	0,819	0,001**	0,018*	0,215	0,003*
Paracatu	0,400	0,377	0,264	0,205	0,153	0,768	0,511	0,664	0,199	0,733	0,618	0,066	0,223
Patos de Minas	0,704	0,177	0,456	0,116	0,015*	0,038*	0,214	0,176	0,410	0,633	0,756	0,462	0,031*
Pedra Azul	DF	0,005**	0,064	0,151	0,477	0,715	0,685	0,160	0,657	0,073	0,011*	0,034*	0,02*
Pirapora	0,000**	0,029*	0,119	0,782	0,882	0,800	0,157	0,812	0,088	0,017*	0,05*	0,076	0,001**
Pompeu	0,055	0,527	0,090	0,345	0,682	0,098	0,080	0,056	0,027*	0,005**	0,018*	0,019*	0,001**
Salinas	0,432	0,083	0,410	0,424	0,689	0,773	0,988	0,741	0,847	0,343	0,742	0,908	0,430
São Lourenço	DF	0,089	0,183	0,240	0,805	0,434	0,830	0,899	0,681	0,923	0,712	0,875	DF
Sete Lagoas	0,154	0,478	0,273	0,228	0,850	0,257	0,977	0,703	0,754	0,102	0,098	0,836	0,148
Uberaba	0,000**	0,000**	0,000**	0,026*	0,413	0,075	0,009**	0,080	0,001**	0,001**	0,001**	0,000**	0,000**
Unai	0,293	0,400	0,263	0,547	0,902	0,317	0,109	0,432	0,651	0,706	0,452	0,719	0,02*
Viçosa	0,000**	0,000**	0,000**	0,000**	0,011*	0,049*	0,009**	0,307	0,022*	0,001**	0,002**	0,000**	0,000**

DF: Dados Faltantes

* Significativo a 5%

** Significativo a 1%

Tabela 8 – Valor p dos coeficientes de regressão para precipitação

Estação	Janeiro	Fevereiro	Março	Abril	Maior	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro	Anual
Aimorés	0,731	0,253	0,488	0,081	0,699	0,969	0,885	0,015*	0,945	0,826	0,410	0,578	0,291
Araçuaí	0,089	0,247	0,429	0,423	0,535	0,917	0,742	0,579	0,704	0,019*	0,383	0,911	0,278
Araxá	0,940	0,650	0,800	0,177	0,619	0,860	0,756	0,775	0,856	0,878	0,264	0,019*	0,132
Arinos	0,823	0,251	0,832	0,504	0,920	0,505	0,678	0,916	0,584	0,993	0,420	0,045*	0,739
Belo Horizonte	0,549	0,178	0,482	0,849	0,647	0,924	0,452	0,712	0,597	0,398	0,453	0,108	0,134
Capinópolis	0,802	0,748	0,404	0,731	0,297	0,478	0,410	0,979	0,634	0,985	0,777	0,420	0,674
Carbonita	0,889	0,187	0,291	0,831	0,275	0,812	0,474	0,730	0,141	0,211	0,928	0,932	0,457
Diamantina	0,137	0,972	0,762	0,239	0,745	0,441	0,137	0,323	0,769	0,504	0,936	0,274	0,847
Espinosa	0,779	0,155	0,637	0,750	0,855	0,440	0,584	0,680	0,212	0,179	0,838	0,249	0,618
Janaúba	0,276	0,799	0,326	0,344	0,343	0,555	0,655	0,107	0,925	0,970	0,651	0,524	0,929
Juiz de Fora	0,968	0,693	0,124	0,854	0,372	0,765	0,072	0,759	0,641	0,429	0,422	0,011*	0,066
Montes Claros	0,378	0,408	0,446	0,409	0,152	0,208	0,568	0,396	0,711	0,486	0,375	0,316	0,838
Paracatu	0,753	0,449	0,995	0,073	0,061	0,301	0,968	0,633	0,912	0,407	0,152	0,842	0,404
Patos de Minas	0,517	0,922	0,371	0,477	0,981	0,342	0,289	0,747	0,637	0,271	0,969	0,015*	0,939
Pedra Azul	DF	0,602	0,479	0,196	0,281	0,819	0,410	0,979	0,554	0,980	0,724	0,583	0,615
Pirapora	0,581	0,903	0,213	0,556	0,842	0,140	0,081	0,988	0,960	0,658	0,937	0,670	0,963
Pompeu	0,427	0,436	0,926	0,935	0,258	0,224	0,572	0,864	0,458	0,650	0,789	0,917	0,516
Salinas	0,219	0,601	0,869	0,033*	0,564	0,654	0,427	0,649	0,313	0,814	0,677	0,111	0,790
São Lourenço	DF	0,932	0,216	0,154	0,454	0,745	0,842	0,305	0,232	0,398	0,461	0,371	DF
Sete Lagoas	0,704	0,700	0,607	0,802	0,547	0,145	0,468	0,851	0,392	0,224	0,370	0,919	0,745
Uberaba	0,429	0,956	0,646	0,616	0,907	0,653	0,209	0,395	0,762	0,797	0,125	0,039*	0,368
Unai	0,652	0,763	0,387	0,349	0,477	0,123	0,636	0,894	0,924	0,548	0,311	0,591	0,243
Viçosa	0,099	0,661	0,157	0,919	0,721	0,758	0,021	0,286	0,852	0,263	0,954	0,081	0,150

DF: Dados Faltantes

* Significativo a 5%

** Significativo a 1%




Figura 10 – Distribuição temporal e tendência para a temperatura média máxima anual na estação de Uberaba.

Entretanto, estes resultados diferem dos encontrados por Minuzzi et al. (2010), que verificaram na estação Uberaba os menores números de tendências significativas na temperatura máxima do ar no período de 1961 a 2004, e observaram tendência positiva apenas em março, mas somente a partir da década de 1990.

A estação de Viçosa também se destaca com tendência de aumento nas séries de temperatura máxima do ar, nos meses de abril, agosto, setembro e outubro e aumento na temperatura mínima do ar na maioria dos meses, exceto no mês de setembro pelo teste de regressão (Tabelas 6 e 7) e nos meses de junho, agosto e setembro, pelo teste de Mann-Kendall (Figura 8). Esses resultados são semelhantes aos encontrados por Rodrigues et al. (2011), que aplicaram o teste de Mann-Kendall no período 1968 a 2008 em Viçosa. Contudo, em nenhum mês esse aumento excede 0,5 °C por década.

Somente as estações de Capinópolis e São Lourenço apresentaram tendência significativa de decréscimo na temperatura máxima do ar. Para a estação de Patos de Minas, no mês de maio, verificou-se um decréscimo significativo na temperatura mínima do ar pelos testes de Mann-Kendall e

regressão e no mês de junho pelo teste de regressão (Figuras 7 e 8 e Tabelas 6 e 7).

Na estação de São Lourenço observou-se tendência de decréscimo para a temperatura máxima do ar nas séries de abril ($-0,8\text{ }^{\circ}\text{C}$ por década), maio ($-0,8\text{ }^{\circ}\text{C}$ por década), novembro ($-0,9\text{ }^{\circ}\text{C}$ por década) e dezembro ($-1,1\text{ }^{\circ}\text{C}$ por década). Já a estação de Capinópolis, apresentou tendência de decréscimo em todos os meses, exceto setembro (Tabela 6). Em Capinópolis essa queda na temperatura máxima do ar foi maior no mês de outubro, chegando a $-2,1\text{ }^{\circ}\text{C}$ por década, sendo a média geral de todos os meses de $-1,7\text{ }^{\circ}\text{C}$ por década.

Os valores de tendência encontrados por década estão muito elevados, principalmente, quando comparados ao estudo de Minuzzi et al (2010), que verificaram que as tendências de aumento na temperatura máxima em algumas localidades do estado de Minas Gerais, num período de 44 anos, oscilaram entre $1,3^{\circ}\text{C}$ e $3,9^{\circ}\text{C}$. De maneira geral, esses valores são um pouco superiores a alguns resultados encontrados na literatura como os de: Minuzzi (2010) que identificou aumento entre $0,1$ a $0,5\text{ }^{\circ}\text{C}$ por década na temperatura média em Santa Catarina; del Río et al. (2011), que analisando a temperatura média em escala mensal, sazonal e anual na Espanha, observaram um aumento significativo em mais de 60% do país em março, junho, agosto, na primavera e no verão, com os maiores valores de tendência em junho (aumento médio de $0,5\text{ }^{\circ}\text{C}$ por década). Marengo e Camargo (2008) verificaram, no sul do Brasil, em nível anual, que as estações que apresentam tendências positivas e significativas para a temperatura mínima exibem aquecimento variando entre $0,5$ e $0,8\text{ }^{\circ}\text{C}$ por década, enquanto as temperaturas máximas indicam tendências relativamente menor, cerca de $0,4\text{ }^{\circ}\text{C}$ por década para o período de 1960 - 2002. Em nível sazonal, as tendências de temperatura máxima variam de $0,4$ a $0,9\text{ }^{\circ}\text{C}$ por década durante o verão para $0,6$ a $0,8\text{ }^{\circ}\text{C}$ por década durante o inverno (MARENGO; CAMARGO, 2008).

Com relação aos totais mensais de precipitação, a maioria das séries não apresentou tendências significativas pelos testes de Mann-Kendall e regressão. Em estudos similares, Blain (2009), analisando dados mensais de

precipitação de oito localidades do Estado de São Paulo, não detectou tendências marcantes nos totais de precipitação pluvial.

Porém, no mês de dezembro, ambos os testes, detectaram tendência de aumento de precipitação nas estações de Araxá, Uberaba e Juiz de Fora. O teste de regressão também apontou tendência de acréscimo em dezembro para as estações de Arinos e Patos de Minas. Nas estações de Paracatu e Aimorés, os testes indicaram a presença de tendência de decréscimo nos meses de maio e agosto, respectivamente. (Figura 9 e Tabela 8).

4.3. Metodologia de Box-Jenkins

As séries de temperatura máxima do ar possuem maior variabilidade em relação às séries de temperatura mínima do ar (Figura 11). As estações de Salinas e Montes Claros possuem séries históricas com períodos mais longos. O comportamento temporal das séries das diferentes estações é muito similar entre si. As flutuações mensais sugerem um comportamento sazonal no padrão temporal das séries de temperatura máxima e mínima do ar, devido à correlação significativa nos coeficientes na distância temporal igual a 12 (Figuras 12 e 13). Essa componente sazonal é comprovada pela análise das funções de autorrelações das séries estudadas (Figuras 12 e 13), com periodicidade anual e ausência do componente de tendência. Monbet et al. (2007) destacam que a componente sazonal geralmente é fácil de se observar em dados meteorológicos, pois dados meteorológicos mensais tendem a serem similares a cada período de 12 meses.

As Figuras 12 e 13 apresentam as funções de autocorrelação das estações, antes e depois da diferenciação sazonal da série (diferenciada a cada observação nas defasagens múltiplas de 12). Verifica-se a suposição de que a série é estacionária após a 1ª diferença sazonal. Pelo teste de Dickey-Fuller aumentado, verificou-se que todas as séries analisadas são estacionárias, não apresentando a componente de tendência.




Figura 11 – Distribuição temporal das temperaturas máxima e mínima do ar.




Figura 12 – Função de autocorrelação da série original (direita) e diferenciada (esquerda) para a temperatura máxima do ar.




Figura 13 – Função de autocorrelação da série original (direita) e diferenciada (esquerda) para a temperatura mínima do ar.

Portanto, após a diferenciação sazonal, um modelo do tipo SARIMA(p, 0, q)x(P,1, Q)₁₂ pode ser ajustado aos dados. A Tabela 9 apresenta os modelos ajustados para cada localidade estudada.

Tabela 9 – Modelos de Box-Jenkins ajustados em cada estação

Estações	Temperatura Máxima	Temperatura Mínima
Araçuaí	SARIMA(1,0,0)(2,1,0) ₁₂	SARIMA(1,0,0)(1,1,1) ₁₂
Arinos	SARIMA(0,0,1)(2,1,1) ₁₂	SARIMA(1,0,2)(1,1,2) ₁₂
Espinosa	SARIMA(1,0,1)(0,1,1) ₁₂	SARIMA(1,0,1)(0,1,1) ₁₂
Januária	SARIMA(1,0,0)(1,1,1) ₁₂	SARIMA(1,0,0)(0,1,2) ₁₂
Montes Claros	SARIMA(1,0,0)(2,1,0) ₁₂	SARIMA(1,0,0)(2,1,0) ₁₂
Salinas	SARIMA(1,0,0)(0,1,1) ₁₂	SARIMA(1,0,0)(0,1,1) ₁₂

A Tabela 10 apresenta as estatísticas de adequacidade dos modelos para as localidades estudadas. Para a temperatura máxima do ar os modelos ajustados apresentaram um desempenho inferior (r^2 variando de 0,47 a 0,68), quando comparados com a temperatura mínima do ar (r^2 de 0,85 a 0,90). Isso ocorre, principalmente, devido à maior variabilidade observada nos dados de temperatura máxima do ar (Figura 11). Essa constatação também é ressaltada por Lúcio et al. (2010), ao afirmarem que os modelos ARIMA permitem extrapolar o comportamento das séries trimestrais de precipitação desde que o processo tenha poucas oscilações.

Os valores de RMSE fornecem uma informação em relação à dispersão dos dados, ou seja, o grau de espalhamento obtido na comparação com os valores estimados. Desta forma, verifica-se que os dados estimados possuem baixa variabilidade, com RMSE em torno de 1°C.

Em todas as localidades, os modelos propostos capturam bem a dinâmica da série observada, com viés médio (MBE) baixo e bom índice de concordância (Tabela 10), indicando uma boa adequação do modelo aos dados observados.

Tabela 10 – Medidas de desempenho da metodologia Box-Jenkins para temperatura máxima e mínima do ar

Estação	Temperatura Máxima				
	r^2	RMSE (°C)	MAE(°C)	MBE(°C)	d
Montes Claros	0,65	1,12	0,81	-0,40	0,70
Salinas	0,68	1,39	1,05	-0,39	0,73
Januária	0,53	1,10	0,88	-0,17	0,69
Arinos	0,60	1,10	0,90	-0,30	0,73
Araçuaí	0,61	1,70	1,20	-1,00	0,62
Espinosa	0,47	1,18	0,93	0,66	0,59

Estação	Temperatura Mínima				
	r^2	RMSE (°C)	MAE(°C)	MBE(°C)	d
Montes Claros	0,89	1,02	0,84	-0,53	0,93
Salinas	0,85	1,04	0,89	-0,37	0,91
Januária	0,85	1,14	0,95	-0,36	0,92
Arinos	0,88	1,00	0,80	-0,10	0,94
Araçuaí	0,87	0,90	0,70	-0,10	0,93
Espinosa	0,90	0,70	0,57	0,31	0,92

Na Figura 14, observa-se o gráfico das previsões da temperatura máxima e mínima do ar da estação de Espinosa. A metodologia de Box-Jenkins foi aplicada para o preenchimento de falhas no ano de 1998, para os meses de agosto, setembro e outubro e para os meses de dezembro de 1999 e janeiro de 2000 para a temperatura máxima do ar. Observa-se que o comportamento do modelo foi muito similar aos dados observados.




Figura 14 – Comportamento da temperatura observada e modelada pela metodologia de Box-Jenkins na estação de Espinosa.

O modelo ajustado é o SARIMA(1,0,1)(0,1,1)₁₂ para as séries de temperatura máxima e mínima do ar na estação de Espinosa (Figura 14). Verifica-se que o modelo está bem ajustado e as previsões, embora em alguns meses estejam ligeiramente acima ou abaixo, apresentam valores bem próximos dos observados e capturam eficientemente a periodicidade e o comportamento padrão da série temporal. Desta forma, a metodologia apresenta boas estimativas para o preenchimento das falhas, mantendo o comportamento médio observado (Figura 14). Nas demais localidades, também verificou-se que os modelos ajustados mantêm o comportamento médio da série observada, indicando que os modelos podem ser utilizados para predição, conforme já avaliado pelas medidas de desempenho (Tabela 10).

Não se recomenda que o preenchimento seja feito para períodos longos, pois a metodologia de Box-Jenkins é mais eficiente em previsões em curto prazo.

Na Figura 15 são apresentados os gráficos de adequacidade dos resíduos do modelo ajustado à série de temperatura mínima do ar para a estação de Espinosa. Pela análise dos resíduos, verifica-se que eles têm média zero e variância constante. Na função de autocorrelação (FAC), observa-se que as autocorrelações não são significativas individualmente, ao nível de 5%, indicando que os resíduos são independentes, o que pode ser confirmado pelos p-valores do teste de Ljung-Box, que são todos maiores do que 0,05 (Figura 15). Assim, não se pode rejeitar a hipótese de independência. Após a checagem dos resíduos, juntamente com as medidas de desempenho (Tabela 10), pode-se confirmar que o modelo se ajusta bem aos dados, implicando que o modelo é adequado.




Figura 15 – Diagnóstico para o modelo SARIMA(1,0,1)(0,1,1)₁₂ para temperatura mínima do ar na estação de Espinosa.

4.4. Modelo Geoestatístico Espaço-Tempo

Os resultados do modelo geoestatístico espaço-tempo descrito por Kyriakidis e Journel (1999) são apresentados para as séries de temperatura máxima e mínima do ar e precipitação. O modelo foi proposto com objetivo de prever as observações de uma estação (que foi considerada sem dados) nos mesmos tempos (períodos) dos dados observados nas estações vizinhas. As estações apresentadas nos gráficos são as mesmas em que foram ajustados os modelos de Box-Jenkins.

As Tabelas 11 e 12 apresentam os resultados das medidas de desempenho do modelo espaço-tempo para as séries mensais de temperatura máxima e mínima do ar. Observa-se um aumento expressivo nos coeficientes de determinação (r^2), principalmente para a temperatura máxima do ar, quando comparado aos valores encontrados para as mesmas estações pela metodologia de Box-Jenkins. Com a metodologia espaço-temporal, considerando o pior ajuste (Pedra Azul) encontrado, ainda assim, o modelo consegue explicar 82% da variabilidade observada na estação (Tabela 11). Pelas estatísticas RMSE, MAE e MBE, verifica-se que o modelo proposto é muito eficiente para o preenchimento de falhas, sendo que, em média, para o conjunto das estações estudadas, o erro é muito baixo. A estação de Salinas apresentou os maiores erros, tanto em média (MBE), quanto em relação à dispersão dos dados, com RMSE de 0,9 °C para a temperatura mínima do ar e 0,8 °C para a temperatura máxima do ar (Tabela 11).

Tabela 11 – Medidas de desempenho do modelo geoestatístico espaço-tempo para temperatura máxima do ar

Estação	r^2	RMSE (°C)	MAE (°C)	MBE (°C)	d
Araçuaí	0,95	0,56	0,46	-0,31	0,98
Arinos	0,98	0,41	0,35	-0,25	0,99
Espinosa	0,92	0,49	0,36	0,09	0,98
Formoso	0,85	1,24	1,05	1,04	0,87
Janaúba	0,88	1,44	1,33	-1,31	0,84
Januária	0,89	0,70	0,57	0,42	0,96
João Pinheiro	0,97	0,94	0,90	0,90	0,92
Juramento	0,96	1,06	1,00	1,00	0,90
Mocambinho	0,94	0,86	0,80	-0,75	0,94
Monte Azul	0,95	0,45	0,37	-0,05	0,98
Montes Claros	0,97	0,28	0,23	0,02	0,99
Paracatu	0,96	0,95	0,89	0,89	0,92
Pedra Azul	0,82	0,99	0,87	0,00	0,94
Pirapora	0,97	0,75	0,69	-0,68	0,95
Salinas	0,93	0,75	0,58	0,35	0,96
Unaí	0,98	0,57	0,51	-0,50	0,97

Tabela 12 – Medidas de desempenho do modelo geoestatístico espaço-tempo para temperatura mínima do ar

Estação	r^2	RMSE (°C)	MAE (°C)	MBE (°C)	d
Araçuaí	0,94	0,66	0,51	0,15	0,97
Arinos	0,99	0,70	0,63	-0,63	0,98
Espinosa	0,91	0,76	0,61	-0,18	0,97
Janaúba	0,98	0,78	0,60	-0,58	0,96
Januária	0,98	0,55	0,46	0,32	0,99
João Pinheiro	0,93	1,16	0,94	-0,72	0,92
Juramento	0,98	1,88	1,84	1,84	0,89
Mocambinho	0,97	0,48	0,37	0,05	0,99
Montes Claros	0,99	0,56	0,46	-0,41	0,99
Paracatu	0,99	0,69	0,64	0,64	0,98
Pedra Azul	0,90	1,53	1,36	1,36	0,89
Pirapora	0,99	0,72	0,61	-0,49	0,98
Salinas	0,97	0,85	0,69	0,67	0,97
Unaí	0,92	0,82	0,64	-0,16	0,98

O comportamento temporal da temperatura do ar observada e modelada pelo modelo geoestatístico espaço-tempo é apresentado nas Figuras 16 a 21. Observa-se que os valores preditos pelo modelo são muito semelhantes aos valores observados, sendo iguais em alguns dos casos.

Pode-se verificar que as estimativas da temperatura modelada pela metodologia espaço-temporal seguiram o comportamento temporal da série histórica de dados das estações do INMET, ou seja, a metodologia espaço-tempo capturou as variações observadas ao longo da série.




Figura 16 – Comportamento da temperatura do ar observada e modelada pelo modelo espaço-tempo na estação de Araçuaí.




Figura 17 – Comportamento da temperatura do ar observada e modelada pelo modelo espaço-tempo na estação de Arinos.




Figura 18 – Comportamento da temperatura do ar observada e modelada pelo modelo espaço-tempo na estação de Espinosa.




Figura 19 – Comportamento da temperatura do ar observada e modelada pelo modelo espaço-tempo na estação de Januária.




Figura 20 – Comportamento da temperatura do ar observada e modelada pelo modelo espaço-tempo na estação de Montes Claros.




Figura 21 – Comportamento da temperatura do ar observada e modelada pelo modelo espaço-tempo na estação de Salinas.

As Figuras 22 e 23 apresentam os resultados do modelo geoestatístico espaço-tempo utilizado para estimativa dos totais mensais de precipitação, observa-se um ajuste satisfatório, explicando 84% da variabilidade dos dados observados em Januária (coeficiente de correlação de 0,91), estação na qual foi observado o menor valor do coeficiente de determinação. Para as demais estações, as estimativas foram melhores, com a modelo espaço-tempo chegando a explicar 98% da variabilidade dos dados da estação de Salinas (coeficiente de correlação de 0,99), que foi a estação onde obteve-se o melhor coeficiente de determinação ($r^2 = 0,98$).




Figura 22 – Distribuição da precipitação observada e modelada pelo modelo espaço-tempo.




Figura 23 – Distribuição da precipitação observada e modelada pelo modelo espaço-tempo.

Esses resultados foram superiores aos encontrados por Almeida et al. (2011), que utilizando a técnica de geoestatística para ajustar um modelo de série temporal de precipitação para a Bacia do Rio Itapemirim em uma série de precipitação mensal de 1940 a 2006, obtiveram um valor de coeficiente de determinação de 0,40, e os de Mello e Silva (2009), que ajustando modelos lineares de regressão múltipla, baseados nas coordenadas geográficas e altitude, para a precipitação média mensal em diferentes períodos, encontraram valores de R^2 variando de 0,51 a 0,80.

Analizando-se o desempenho estatístico do modelo espaço-tempo utilizado para estimativa da precipitação total mensal observam-se baixos valores dos erros RMSE (maior valor obtido foi de 50,9 mm para a estação de Montes Claros) e MAE (maior valor obtido foi de 29,2 mm também para a estação de Montes Claros). Os menores valores de RMSE e MAE foram obtidos para a estação de Salinas, sendo de 15,3 mm e 9,1 mm, respectivamente. Estes resultados indicam que o método não apresenta grande variabilidade e nem tendência expressiva. Almeida et al., (2011) obtiveram, em suas pesquisas, valores de RMSE e MAE bem superiores aos encontrados neste estudo, sendo estes de 119 mm e 112,67 mm, respectivamente.

Jácomo (2011), utilizando este mesmo modelo geoestatístico espaço-tempo para estimar a precipitação mensal em uma estação localizada no oeste do estado de São Paulo, com um conjunto de dados composto por 105 localidades com 372 tempos distintos, representando os meses de janeiro de 1970 a dezembro de 2000, obteve coeficiente de correlação (r) e erro absoluto médio (MAE) de 0,92 e 22,44 mm, respectivamente.

Para comprovar a eficiência das estimativas do modelo geoestatístico espaço-tempo Jácomo (2011) retirou a estação de coleta mais distante das demais estações e gerou o modelo sem essa estação comparando com os seus valores reais. Os resultados obtidos foram satisfatórios, sendo que, as medidas geradas a partir dessa estimativa apresentaram alta correlação (0,881), baixo MAE (26,11mm) e a normalidade da distribuição dos erros.

Considerando todas as estações avaliadas, os resultados encontrados, para o coeficiente de correlação e erro absoluto médio foram

de 0,92 e 22,56 mm (Tabela 13). Esses resultados são muito semelhantes aos encontrados por Jácomo (2011).

Tabela 13 – Medidas de desempenho do modelo geoestatístico espaço-tempo precipitação

Estação	r^2	RMSE	MAE	MBE	d
Araçuaí	0,91	26,08	17,61	9,59	0,97
Arinos	0,87	40,55	24,21	-0,99	0,96
Espinosa	0,87	36,97	21,30	12,11	0,95
Janaúba	0,75	45,26	26,28	3,99	0,93
Januária	0,84	49,93	27,48	1,55	0,94
João Pinheiro	0,87	59,92	34,58	-27,19	0,94
Juramento	0,90	43,87	25,70	14,32	0,95
Mocambinho	0,92	29,94	18,55	4,42	0,98
Monte Azul	0,89	31,83	17,70	-5,06	0,97
Montes Claros	0,88	50,89	29,17	-17,75	0,93
Paracatu	0,86	46,84	29,04	-8,68	0,96
Pedra Azul	0,70	44,78	30,79	-5,03	0,91
Pirapora	0,85	43,27	22,95	18,11	0,94
Salinas	0,98	15,27	9,10	0,10	0,99
Unaí	0,99	6,12	3,99	-1,64	0,99
Geral	0,85	38,10	22,50	-0,14	0,95

Os baixos valores do MBE encontrados, notadamente de apenas 0,1 mm (Figura 22) para a estação de Salinas, confirmam o bom desempenho estatístico do modelo, ou seja, em média a metodologia é bem coerente com os dados observados. Além disso, os altos valores do índice de concordância de Willmott (d) indicam uma boa concordância dos dados previstos e observados, corroborando a eficácia do modelo.

Apesar de apresentar bons valores de estimação, o modelo obteve estimativas de precipitação negativas para os meses de junho e agosto no ano de 2007 e para os meses de maio, junho, julho e agosto de 2008, para a estação de Arinos. Sabe-se que, pela análise da base de dados original, para estes meses o valor predito deveria ser de 0 mm, pois não foi observada precipitação. Assim, foi imposta uma condicional no algoritmo de cálculo do Software R de maneira que se fosse constatado algum valor negativo de precipitação o mesmo seria substituído por zero. Almeida et al. (2011) destacam que deve ser feita uma análise nos resultados provenientes de modelos de geoestatística, retirando-se os possíveis valores inconsistentes (valores negativos gerados).

A fim de comparar a metodologia de Box-Jenkins com o modelo geoestatístico espaço-tempo, os valores observados para a temperatura máxima e mínima do ar e os valores previstos pelos modelos de Box-Jenkins e espaço-temporal foram plotados num gráfico de dispersão junto com a linha de regressão e analisados pelo teste t a significância do coeficiente de regressão, conforme apresentados nas Figuras 24 a 27.

Verifica-se que em todas as estações a linha de regressão ajustada aos valores observados e os derivados do modelo espaço-tempo estão próximos da identidade, apresentando menor dispersão em torno da reta estimada e coeficientes de determinação maiores.

A linha 1:1 (reta de 45°) é apresentada em cada figura para se ter uma referência de onde o ajuste ideal entre os valores observados e previstos devem estar localizados.

As séries de temperatura máxima do ar, que apresentam maior variabilidade, não são satisfatoriamente preditas pela metodologia de Box-Jenkins, apresentando uma dispersão muito alta em torno da reta estimada (Figuras 24 e 25). Já para o modelo espaço-tempo esta dispersão é particularmente baixa em todas as estações comparadas, evidenciando a eficiência do modelo. Além disso, a porcentagem da variabilidade explicada pelo modelo espaço-tempo é bem maior do que a metodologia Box-Jenkins.

O teste t para o coeficiente de regressão mostrou que todos os coeficientes de regressão ajustados a metodologia de Box-Jenkins são significativamente diferentes de um, ao nível de 5%. Enquanto para a metodologia espaço-temporal, apenas as estações de Arinos e Salinas não foram significativas. Porém, essas estações apresentam baixa dispersão dos dados observados e modelados e bons coeficientes de determinação, indicando um bom ajuste em ambas.

Para a temperatura mínima do ar, que possui menor variabilidade, todos os coeficientes de regressão da metodologia de Box-Jenkins, foram significativos, ao nível de 5%, indicando um ajuste ideal. Nas estações de Araçuaí, Januária e Salinas, os coeficientes diferem estatisticamente da reta ideal, mas ainda assim, apresentam um ajuste satisfatório, conforme apresentam as Figuras 26 e 27




Figura 24 – Comparação entre temperatura máxima do ar observada e prevista pelo modelo espaço-tempo (esquerda) e pela metodologia de Box-Jenkins (direita) para as estações de Araçuaí (A), Arinos (B) e Espinosa (C).




Figura 25 – Comparação entre temperatura máxima do ar observada e prevista pelo modelo espaço-tempo (esquerda) e pela metodologia de Box-Jenkins (direita) para as estações de Januária (A), Montes Claros (B) e Salinas (C).




Figura 26 – Comparação entre temperatura mínima do ar observada e prevista pelo modelo espaço-tempo (esquerda) e pela metodologia de Box-Jenkins (direita) para as estações de Araçuaí (A), Arinos (B) e Espinosa (C).




Figura 27 – Comparação entre temperatura mínima do ar observada e prevista pelo modelo espaço-tempo (esquerda) e pela metodologia de Box-Jenkins (direita) para as estações de Januária (A), Montes Claros (B) e Salinas (C).

Quando são comparados os resultados obtidos neste estudo através das metodologias de Box-Jenkins e a geoestatística espaço-tempo, fica evidente a superioridade da segunda em prever com eficácia os dados faltantes nas séries históricas de temperatura máxima ar, em relação à primeira, principalmente em dados com maior variabilidade.

Provavelmente, deve-se ao fato da metodologia de Box-Jenkins considerar apenas a correlação temporal existente entre os valores da série. Já a metodologia espaço-tempo utiliza um modelo probabilístico associado à localização espacial dos pontos amostrados, possibilitando, desta forma, uma análise da variabilidade entre os valores observados. Assim, não considera apenas a correlação temporal, mas também a espacial.

Segundo Staudt et al. (2007), para dados mensais de temperatura, a metodologia ARIMA de Box-Jenkins tem um baixo potencial preditivo porque, geralmente, o componente ruído, explica de 70 a 90% da variabilidade. Assim, o modelo ARIMA, somente deve ser utilizado para preencher falhas nos dados quando não há dados disponíveis de estações vizinhas (STAUDT et al., 2007).

O modelo geoestatístico espaço-tempo considera a dependência espacial, assim, as estações que serão utilizadas para preencher as falhas deverão estar dentro da mesma região climática e possuir dependência espacial. De acordo com Bicalho (2008), o modelo geoestatístico espaço-tempo proposto por Høst et al. (1995) é uma alternativa prática e acessível na predição de observações espaço-temporais, especialmente nos casos em que a característica de interesse no ponto de predição e nos vizinhos é semelhante. Jácomo (2011) destaca que a utilização de modelos espaço-tempo pode ser útil em bancos de dados que contém dados ausentes, pois a utilização desses modelos, assim como o modelo proposto por Høst et al. (1995), auxilia no preenchimento desses dados com boa precisão.

Não se pode afirmar que as técnicas aqui apresentadas superam as outras técnicas existentes. Entretanto, elas se configuram como boas alternativas para o preenchimento de falhas em séries de dados climáticos, principalmente a proposta espaço-tempo.

5. CONCLUSÕES

- Os testes de homogeneidade apresentaram boa concordância entre si, com a maioria das séries mensais de temperatura do ar sendo classificadas como úteis. As mudanças estatisticamente significativas ocorreram na década de 1990, principalmente em torno do ano 1997.
- Para a temperatura máxima, o mês de agosto apresentou o maior número de estações, em que os testes detectaram não-homogeneidade.
- Não foi possível identificar as causas das não homogeneidades encontradas, tendo em vista que as séries analisadas são, relativamente, muito curtas e sem a disponibilidade de metadados.
- Observaram-se mais tendências positivas nas séries de temperatura mínima do ar do que na temperatura máxima do ar. Algumas estações, como a de Uberaba, apresentaram tendências um pouco elevadas nas séries de temperatura do ar. Apenas três estações apresentaram tendências de decréscimo na temperatura do ar.
- Os testes de homogeneidade não detectaram mudanças significativas nas séries de precipitação. Nos totais mensais de precipitação, a maioria das séries não apresentou tendências significativas.
- A metodologia de séries temporais de Box-Jenkins mostrou-se como uma opção para o preenchimento de falhas de dados de temperatura

do ar, em base mensal, de uma estação, quando não há estações vizinhas dentro da mesma região climaticamente homogênea.

- O modelo geoestatístico espaço-tempo apresentado configura-se como uma ferramenta adequada para o preenchimento de falhas de dados climáticos, podendo ser utilizado também para estimar dados, mesmo em locais onde não há estação disponível, desde que tenham estações ao redor.

- As informações obtidas neste trabalho poderão ser utilizadas para subsidiar novos estudos científicos que necessitem de dados climáticos.

Recomendações

- O modelo espaço-tempo pode ser testado para o preenchimento de falhas em dados diários, além disso, é conveniente utilizá-lo para investigar fenômenos base de dados mais densa, como por exemplo, dados de precipitação da Agência Nacional de Águas (ANA).

- Outras metodologias espaço-temporais, como por exemplo, a geoestatística aliada à abordagem bayesiana devem ser avaliadas para o preenchimento de falhas em dados climáticos. Cita-se também, a necessidade de implementação de rotinas computacionais para a utilização dessas metodologias.

6. REFERÊNCIA BIBLIOGRÁFICA

AGUILAR, E.; AUER, I.; BRUNET, M.; PETERSON, T. C.; WIERINGA, J. GUIDELINES ON CLIMATE METADATA AND HOMOGENIZATION. **World Climate Programme Data and Monitoring WCDMP-No. 53**. WMO-TD No. 1186, WMO, Geneva. 2003.

ALEXANDERSSON H. A homogeneity test applied to precipitation data. **Journal of Climate**. v. 6, p. 661–675. 1986.

ALEXANDERSSON, H.; MOBERG, A. Homogenization of Swedish temperature data. Part I: homogeneity test for linear trends. **International Journal of Climatology**. v. 17, p. 25–34. 1997.

ALMEIDA, A. Q.; RIBEIRO, A.; PAIVA, Y. G.; RASCON, N. J. L.; LIMA, E. P. Geoestatística no estudo de modelagem temporal da precipitação. **Revista Brasileira de Engenharia Agrícola e Ambiental**. v. 15, n. 4, p. 354–358. 2011.

AQUINO, R. F.; AVANZI, J. C.; SILVA, M. L. N.; SÁFADI, T.; CURI, N. Uso de modelos de séries temporais para predição da erosividade mensal, para o município de Lavras, MG. **Revista Brasileira de Agrometeorologia**, v.16, n. 2, p.205-210. 2008.

ASPIAZU, C.; RIBEIRO, G. A.; VIANELLO, R. L. Análise dos componentes principais aplicado na classificação climática do Estado de Minas Gerais. Teste metodológico. **Revista Árvore**, Viçosa, v. 14, p. 1-15, 1990.

AUER, I.; BÖHM, R.; JURKOVIC, A.; ORLIK, A.; POTZMANN, R.; SCHÖNER, W.; UNGERSBÖCK, M.; BRUNETTI, M.; NANNI, T.; MAUGERI, M.;

BRIFFA, K.; JONES, P.; EFTHYMIADIS, D.; MESTRE, O.; MOISSELIN, J-M.; BEGERT, M.; BRAZDIL, R.; BOCHNICEK, O.; CEGNAR, T.; GAJI C-CAPKA, M.; ZANINOVIC, K.; MAJSTOROVIC, Z.; SZALAI, S.; SZENTIMREY, T.; MERCALLI, L. A new instrumental precipitation dataset for the greater alpine region for the period 1800–2002. **International Journal of Climatology**. v. 25, p. 139-166, DOI: 10.1002/joc.1135, 2005.

BEAULIEU, C.; OUARDA, T. B. M.J.; SEIDOU, O. A Bayesian normal homogeneity test for the detection of artificial discontinuities in climatic series. **International Journal of Climatology**, v. 30, p. 2342-2357, DOI: 10.1002/joc.2056, 2010.

BEGERT, M.; SCHLEGEL, T.; KIRCHHOFER, W. Homogeneous temperature and precipitation series of Switzerland from 1864 to 2000. **International Journal of Climatology**. v. 25, p. 65–80, DOI: 10.1002/joc.1118. 2005.

BICALHO, B. C. D. **Modelos Espaço–Temporais: Estudo de Casos**. 2008. 176 p. Dissertação (Mestrado) – Programa de Pós-Graduação em Estatística – Universidade Federal de Minas Gerais.

BLAIN, G. C. Considerações estatísticas relativas a seis séries mensais de temperatura do ar da secretaria de agricultura e abastecimento do estado de São Paulo. **Revista Brasileira de Meteorologia**, v.26, n. 2, p. 279 – 296. 2011.

BLAIN, G. C. Detecção de tendências monótonas em séries mensais de Precipitação pluvial do estado de São Paulo. **Bragantia, Campinas**, v. 69, n. 4, p1027-1033, 2010a.

BLAIN, G. C. Séries anuais de temperatura máxima média do ar no estado de São Paulo: variações e tendências climáticas. **Revista Brasileira de Meteorologia**, v. 25, n. 1, p. 114 - 124, 2010b.

BLAIN, G. C. Considerações estatísticas relativas à oito séries de precipitação pluvial da secretaria de agricultura e abastecimento do estado de São Paulo. **Revista Brasileira de Meteorologia**, v. 24, n. 1, p. 12 - 23. 2009.

BLAIN, G. C.; KAYANO, M. T.; CAMARGO, M. B. P.; LULU, J. Variabilidade amostral das séries mensais de precipitação pluvial em duas regiões do Brasil: Pelotas-RS e Campinas-SP. **Revista Brasileira de Meteorologia**, v.24, n.1, 1-11, 2009.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: Forecasting and Control**. 4th ed. Hoboken, N.J.: John Wiley & Sons, 2008.

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

BOX, G. E. P. AND G. M. JENKINS. **Time Series Analysis: Forecasting and Control**. Holden Day. San Francisco. 576 pp. 1976.

BRUNET, M.; JONES, P. D.; SIGRÓ, J.; SALADIÉ, O.; AGUILAR, E.; MOBERG, A.; DELLA-MARTA, P. M.; LISTER, D.; WALTHER, A.; LÓPEZ, D. Temporal and spatial temperature variability and change over Spain during 1850–2005. **Journal of Geophysical Research**. v. 112, DOI:10.1029/2006JD008249. 2007.

BRUNET, M.; SALADIÉ, O.; JONES, P.; SIGRÓ, J.; AGUILAR, E.; MOBERG, A.; LISTER, D.; WALTHER, A.; LOPEZ, D.; ALMARZA, C. The development of a new dataset of Spanish daily adjusted temperature series (SDATS) (1850–2003). **International Journal of Climatology**. v. 26, p. 1777-1802, DOI: 10.1002/joc.1338. 2006.

BUISHAND, T. A. Some methods for testing the homogeneity of rainfall records. **Journal of Hydrology**. v. 58, p. 11-27. 1982.

CARRERA-HERNÁNDEZ J. J.; GASKIN, S. J. Spatio temporal analysis of daily precipitation and temperature in the Basin of Mexico. **Journal of Hydrology**. v. 336, p. 231-249. doi: 10.1016/j.jhydrol.2006.12.021. 2007.

CASTRO, F. S.; PEZZOPANE, J. E. M.; PEZZOPANE, J. R. M.; CECÍLIO, R. A.; XAVIER, A. C. Zoneamento agroclimático para espécies do gênero *Pinus* no estado do Espírito Santo. **Floresta**, Curitiba, PR, v. 40, n. 1, p. 235-250. 2010.

CAUSSINUS, H.; MESTRE, O. Detection and correction of artificial shifts in climate series. **Applied Statistics**, v. 53, n. 3, p. 405-425, 2004.

CHEN, F.; YUAN, Y.; WEI, W.; WANG, L.; Y, S.; ZHANG, R.; FAN, Z.; SHANG, H.; ZHANG, T.; LI, Y. Tree ring density-based summer temperature reconstruction for Zajsan Lake area, East Kazakhstan. **International Journal of Climatology**. DOI: 10.1002/joc.2327. 2011.

COSTA, A. C.; SOARES, A. Trends in extreme precipitation indices derived from a daily rainfall database for the South of Portugal. **International Journal of Climatology**. v. 29, p. 1956–1975, DOI: 10.1002/joc.1834. 2009a.

COSTA, A. C.; SOARES, A. Homogenization of Climate Data: Review and New Perspectives Using Geostatistics. **Math Geosci (special issue)**. v. 4, p. 291–305, DOI 10.1007/s11004-008-9203-3. 2009b.

COSTA, A. C.; DURÃO, R.; PEREIRA, M. J.; SOARES, A. Using stochastic space-time models to map extreme precipitation in southern Portugal. **Natural Hazards Earth System Sciences**. v. 8, p. 763–773. doi:10.5194/nhess-8-763-2008. 2008.

COWPERTWAIT, P. S.P.; METCALFE, A. V. **Introductory Time Series with R**. Springer Dordrecht Heidelberg London New York. . DOI 10.1007/978-0-387-88698-5. 2009.

CUNHA, C. SOARES, C. G. On the choice of data transformation for modelling time series of significant wave height. **Ocean Engineering**. v. 26 , p. 489–506, 1999.

DE IACO, S. A new space–time multivariate approach for environmental data analysis. **Journal of Applied Statistics** v. 38, n. 11, p. 2471–2483. doi: 10.1080/02664763.2011.559206. 2011.

DE IACO, S.; MAGGIO, S. PALMA, M.; POSA, D. Towards an automatic procedure for modeling multivariate space–time data. **Computers & Geosciences**. In Press, Accepted Manuscript (2011), doi:10.1016/j.cageo.2011.08.008. 2011.

DE IACO, S.; MYERS, D. E.; PALMA, M.; POSA, D. FORTRAN programs for space–time multivariate modeling and prediction. **Computers & Geosciences**. v. 36, p. 636–646. DOI:10.1016/j.cageo.2009.10.004. 2010.

DEGAETANO, A. Attributes of Several Methods for Detecting Discontinuities in Mean Temperature Series. **Journal of Climate**, v. 19, p. 838–853. 2006.

DEL RÍO, S.; HERRERO, L.; PINTO-GOMES, C.; PENAS, A. Spatial analysis of mean temperature trends in Spain over the period 1961–2006. **Global and Planetary Change**. v. 78, p. 65–75. doi:10.1016/j.gloplacha.2011.05.012. 2011.

DOMONKOS, P. Efficiency evaluation for detecting inhomogeneities by objective homogenisation methods. **Theoretical and Applied Climatology**. v. 105, n.3-4, p. 455–46. DOI: 10.1007/s00704-011-0399-7. 2011.

DOMONKOS P. **Testing of homogenisation methods: purposes, tools and problems of implementation**. In: Szalai S (ed) Proceedings of the fifth seminar for homogenization and quality control in climatological databases. Hungarian Meteorological Service, Budapest, pp 126–145, 2006.

DUCRÉ-ROBITAILLE, J-F.; VINCENT, L.; BOULET, G. Comparison of techniques for detection of discontinuities in temperature series. **International Journal of Climatology**. v. 23, p. 1087–1101, DOI: 10.1002/joc.924. 2003.

DURÃO, R. M.; PEREIRA, M. J.; COSTA, A. C.; DELGADO, J. DEL BARRIO, G.; SOARES, A. Spatial-temporal dynamics of precipitation extremes in southern Portugal: a geostatistical assessment study. **International Journal of Climatology**. v. 30, p. 1526–1537. DOI: 10.1002/joc.1999. 2010.

GETHING, P. W.; NOOR, A. M.; GIKANDI, P. W.; HAY, S. I.; NIXON, M. S.; SNOW, R. W.; ATKINSON, P. M. Developing Geostatistical Space–Time Models to Predict Outpatient Treatment Burdens from Incomplete National Data. **Geographical Analysis**. v. 40, p. 167–188. 2008.

GOOVAERTS, P. Geostatistical approaches for incorporating elevation into the spatial interpolation of rainfall. **Journal of Hydrology**. v. 228, p.113–129. doi: 10.1016/S0022-1694(00)00144-X. 2000.

HØST, G., OMRE, H., AND SWITZER, P. **Spatial interpolation errors for monitoring data**. 1995.

HUANG, H. C.; MARTINEZ, F.; MATEU, J.; MONTES, F. Model comparison and selection for stationary space–time models. **Computational Statistics & Data Analysis**. v. 51, p. 4577 – 4596. DOI:10.1016/j.csda.2006.07.038. 2007.

JÁCOMO, C. A. **Modelos geoestatístico espaço-tempo aplicados a dados pluviométricos no oeste do Estado de São Paulo**. 2011. 109 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Ciências Cartográfica - Universidade Estadual Paulista – Faculdade de Ciências e Tecnologia – Campus de Presidente Prudente.

JARUŠKOVÁ D. Change-point detection in meteorological measurement. *Monthly Weather Review*, v. 124, p. 1535–1543. **Journal American Statistical Association**. v. 90, n. 431, p. 853–861. 1994.

KENDALL, M. G. **Rank correlation methods**, London: Charles Griffin. 1975.

KYRIAKIDIS, P. C.; JOURNEL, A. G. Geostatistical Space–Time Models: A Review. **Mathematical Geology**. v. 31, p. 651–84. 1999.

KYRIAKIDIS, P. C.; MILLER, N. L.; KIM, J. A spatial time series framework for simulating daily precipitation at regional scales. **Journal of Hydrology**. v. 297,p. 236-255. doi: 10.1016/j.jhydrol.2004.04.022. 2004.

LEIVAS, J. F.; BERLATO, M. A.; FONTANA, D. C. Risco de deficiência hídrica decendial na metade sul do Estado do Rio Grande do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.10, n.2, p.397-407. 2006.

LI, B.; NYCHKA, D. W.; AMMANN, C. M. The Value of Multiproxy Reconstruction of Past Climate. **Journal of the American Statistical Association**. v. 105 (491), p. 883-895. DOI:10.1198/jasa.2010.ap09379. 2010.

LONGOBARDI, A.; VILLANI, P. Trend analysis of annual and seasonal rainfall time series in the Mediterranean area. **International Journal of Climatology**. v. 30, p. 1538-1546, DOI: 10.1002/joc.2001. 2010.

LÚCIO, P. S.; SILVA, F. D. S.; FORTES, L. T. G.; SANTOS, L. A. R.; FERREIRA, D. B.; SALVADOR, M. A.; BALBINO, H. T.; SARMANHO, G. F.; SANTOS, L. S.C. DOS; LUCAS, E. W. M.; BARABOSA, T. F.; DIAS, P. L. S. Um modelo estocástico combinado de previsão sazonal para a precipitação no Brasil. **Revista Brasileira de Meteorologia**, v.25, n.1, p. 70 – 87. 2010.

MANN, H. B. Non-parametric test against trend. **Econometrika**, v. 13, p. 245-259. 1945.

MARENGO, J. A.; CAMARGO, C. C. Surface air temperature trends in Southern Brazil for 1960–2002. **International Journal of Climatology**. v. 28, p. 893–904. DOI: 10.1002/joc.1584. 2008

MARTÍNEZ, M. D.; SERRA, C.; BURGUEÑO, A.; LANA, X. Short Communication Response to the comments on time trends of daily Maximum and minimum temperatures in Catalonia (NE Spain) for the period 1975–2004. **International Journal of Climatology**. v. 3, p. 153–157, DOI: 10.1002/joc.2073. 2011.

MARTÍNEZ, M. D.; SERRA, C.; BURGUEÑO, A.; LANA, X. Time trends of daily maximum and minimum temperatures in Catalonia (ne Spain) for the period 1975–2004. **International Journal of Climatology**. v 30, p. 267–290, DOI: 10.1002/joc.1884. 2010.

MELLO, C. R.; SILVA, A. M. Modelagem estatística da precipitação mensal e anual e no período seco para o estado de Minas Gerais **Revista Brasileira de Engenharia Agrícola e Ambiental**. v.13, n.1, p.68–74, 2009.

MINUZZI, R. B. Tendências na variabilidade climática de Santa Catarina, Brasil, **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.14, n.12, p.1288–1293, 2010.

MINUZZI, R. B; VIANELLO, R. L.; SEDIYAMA, G. C. Oscilações climáticas em Minas Gerais. **Revista Brasileira de Meteorologia**, v. 25, n. 2, p. 227 - 236, 2010.

MONBET, V.; AILLIOT, P.; PREVOSTO, M. Survey of stochastic models for wind and sea state time series. **Probabilistic Engineering Mechanics**, v. 22, p. 113–126, 2007.

MOURATO, S.; MOREIRA, M.; CORTE-REAL, J. Interannual variability of precipitation distribution patterns in Southern Portugal. **International Journal of Climatology**, v. 30, p. 1784–1794, DOI: 10.1002/joc.2021. 2010.

OLIVEIRA, L. F. C.; FIOREZE, A. P.; MEDEIROS, A. M. M.; SILVA, M. A. S. Comparação de metodologias de preenchimento de falhas de séries históricas de precipitação pluvial anual. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n. 11, p. 1186–1192. 2010.

ÖNÖZ, B.; BAYAZIT, M. The Power of Statistical Tests for Trend Detection. Turkish. **Journal of Engineering & Environmental Sciences**, v.27, p 247-251. 2003.

PANDŽIĆ, K.; LIKSO, T. Homogeneity of average annual air temperature time series for Croatia. **International Journal of Climatology**, v. 30, p. 1215-1225, DOI: 10.1002/joc.1922. 2010.

PETERSON, T. C.; EASTERLING, D. R.; KARL, T. R.; GROISMAN, P.; NICHOLLS, N.; PLUMMER, N.; TOROK, S.; AUER, I.; BÖHM, R.; GULLETT, D.; VINCENT, L.; HEINO, R.; TUOMENVIRTA, H.; MESTRE, O.; SZENTIMREY, T.; SALINGER, J.; FØRLAND, E. J.; HANSEN-BAUER, I.; ALEXANDERSSON, H.; JONES, P.; PARKER, D. Homogeneity adjustments of in situ climate data: a review. **International Journal of Climatology**, v. 18, p. 1493–1517. 1998.

PETTITT, A. N. A non-parametric approach to the change-point problem. **Applied Statistics**, v. 28, n. 2, p. 126-135. 1979.

PRUSKI, F. F.; PEREIRA, S. B.; NOVAES, L. F.; SILVA, D. D.; RAMOS, M. M. Precipitação média anual e vazão específica média de longa duração, na Bacia do São Francisco. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.8, n.2/3, p.247-253. 2004.

REEVES, J.; CHEN, J.; WANG, X. L.; LUND, R.; LU, Q. A. Review and Comparison of Changepoint Detection Techniques for Climate Data. **Journal of Applied Meteorology and Climatology**, v. 46, p. 900-915, DOI: 10.1175/JAM2493.1 900-915. 2007.

RIBEIRO, R. L. F.; MINGOTI, S. A. **Modelo geoestatístico de previsão espaço-temporal: implementação computacional no software R**. In. XXVII encontro nacional de Engenharia de produção. Foz do Iguaçu, PR, Brasil. 2007.

RIBEIRO, R. L. F.; MINGOTI, S. A. **Apresentando um programa computacional em R e Geo-R para análise espaço-temporal via geoestatística**. In. XIII SIMPEP - Bauru, SP, Brasil. 2006.

RIENZNER, M.; GANDOLFI, C. A composite statistical method for the detection of multiple undocumented abrupt changes in the mean value within a time series. **International Journal of Climatology**. v 31, p. 742–755. DOI: 10.1002/joc.2113. 2011.

RODRIGO, F. S.; TRIGO, R. M. Trends in daily rainfall in the Iberian Peninsula from 1951 to 2002. **International Journal of Climatology**. v. 27, p. 513–529. DOI: 10.1002/joc.1409. 2007.

RODRIGUES, J. M.; RODRIGUES, R. A.; JUSTINO, F. B.; COSTA, L. C.; AMORIM, M. C. Efeitos locais e de larga escala na dinâmica climática do município de Viçosa – Minas Gerais. **Sociedade & Natureza**. v. 22, n. 3, p. 593-610. 2010.

SAHIN, S.; CIGIZOGLU, H. K. Homogeneity analysis of Turkish meteorological data set. **Hydrological Processes**. v. 24, p. 981–992, DOI: 10.1002/hyp.7534. 2010.

SANTOS, D. N.; SILVA, V. P. R.; SOUSA, F. A. S.; SILVA, R. A. Estudo de alguns cenários climáticos para o Nordeste do Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental**. v. 14, n.5, p.492–500, 2010.

SANTOS, A. M. DOS; GALVÍNCIO, J. D., MOURA, M. S. B. DE. Homogeneização da precipitação pluviométrica na bacia hidrográfica do rio goiana - PE, com método de análise de agrupamento. **Revista Brasileira de Geografia Física**. v. 01, n.01, p.14-27. 2008.

SERRANO, A. I.; LUCIO, P. S.; SILVA, A. M. Análise dos resíduos associados a três critérios de reconstrução de séries climatológicas. In: jornadas científicas la meteorologia y el clima atlántico, 28, Encuentro Hispano-Luso de Meteorología: La Meteorología y Climatología, **Resumos**. 2004.

SIGRIST, F.; KÜNSCH, H. R.; STAHEL, W. A. An autoregressive spatio-temporal precipitation model. **Procedia Environmental Sciences**. v. 3, p. 2–7. doi:10.1016/j.proenv.2011.02.002. 2011.

SILVA, R. M. DA; SILVA, L. P. E; MONTENEGRO, S. M. G. L.; SANTOS, C. A. G. Análise da variabilidade espaço-temporal e identificação do padrão da precipitação na Bacia do Rio Tapacurá, Pernambuco. **Sociedade & Natureza**, Uberlândia, v. 22, n. 2, p. 357-372. 2010.

SILVA, M. I. S.; GUIMARÃES, E. C.; TAVARES, M. Previsão da temperatura média mensal de Uberlândia, MG, com modelos de séries temporais. **Revista Brasileira de Engenharia Agrícola e Ambiental**. v. 12, n. 5, p.480–485. 2008.

SILVA, V. DE P. R. On climate variability in Northeast of Brazil. **Journal of Arid Environments**, v.58, p.575-596, 2004.

SOUZA, A. M; GEORGEN, R.; FERRAZ, S. E. T. Previsão de precipitação e temperatura em Santa Maria por meio de um modelo estatístico. **Ciência e Natura**. v. 31 (1), p. 49 - 64, 2009.

STAUDT, M.; ESTEBAN-PARRA, M. J.; CASTRO-DÍEZ. Y. Homogenization of long-term monthly Spanish temperature data. **International Journal of Climatology**. v. 27, p. 1809–1823. DOI: 10.1002/joc.1493. 2007.

STORCH, H. V.; ZORITA, E.; GONZÁLEZ-ROUCO, F. Assessment of three temperature reconstruction methods in the virtual reality of a climate simulation. **International Journal of Earth Sciences (Geol Rundsch)**, v. 98, p. 67–82. DOI 10.1007/s00531-008-0349-5. 2009.

TEEGAVARAPU, RAMESH S. V.; CHANDRAMOULI, V. Improved weighting methods, deterministic and stochastic data-driven models for estimation of missing precipitation records. **Journal of Hydrology**. v. 312, p. 191–206. doi: 10.1016/j.jhydrol.2005.02.015. 2005.

TORETI, A.; KUGLITSCH, F. G.; XOPLAKI, E.; DELLA-MARTA, P. M.; AGUILAR, E.; PROHOMF, M.; LUTERBACHERG, J. Short communication: A note on the use of the standard normal homogeneity test to detect inhomogeneities in climatic time series. **International Journal of Climatology**. v. 31, p. 630–632, DOI: 10.1002/joc.2088. 2011.

VICENTE-SERRANO, S. M.; BEGUERÍA, S.; LÓPEZ-MORENO, J. I.; GARCÍA-VERA, M. A.; STEPANEK, P. A complete daily precipitation database for northeast Spain: reconstruction, quality control, and homogeneity. **International Journal of Climatology**. v. 30, p. 1146–1163. DOI: 10.1002/joc.1850. 2010.

WIJNGAARD, J. B.; KLEIN TANK, A. M. G.; KÖNNEN, G. P. Homogeneity of 20th century European daily temperature and precipitation series. **International Journal of Climatology**. v. 23, p. 679-692. DOI: 10.1002/joc.906. 2003.

WILLMOTT, C. J. Some comments on the evaluation of model performance. **Bulletin of the American Meteorological Society**, Lancaster, v.63, n.11, p. 1309–1313. 1982.