

# ANÁLISE DOS RESÍDUOS ASSOCIADOS A TRÊS CRITÉRIOS DE RECONSTRUÇÃO DE SÉRIES CLIMATOLÓGICAS.

## *RESIDUALS ANALYSES ASSOCIATED TO THREE CRITERIONS FOR CLIMATOLOGICAL TIME SERIES RECONSTITUTION.*

**A. I. SERRANO, P. S. LUCIO, A. M. SILVA**

Centro de Geofísica de Évora, R. Romão Ramalho 59, 7000-554 Évora  
[anisaserrano@iol.pt](mailto:anisaserrano@iol.pt), [pslucio@uevora.pt](mailto:pslucio@uevora.pt), [asilva@uevora.pt](mailto:asilva@uevora.pt)

**RESUMO:** O objectivo deste estudo é proceder à reconstrução de séries climatológicas (temperaturas extremas e precipitação mensal acumulada) por interpolação temporal e espacial para prever “*missing values*”. Foram adoptadas três técnicas estatísticas para a reconstrução das séries, baseadas na: (1) normal climatológica; (2) função de autocorrelação; e (3) interpolação espacial: (a) Método Directo (variáveis) *versus* (b) Método Indirecto ou de Gandin (anomalias). Procedeu-se à análise dos resíduo quadrático médio MSR associado a cada uma das técnicas de reconstrução. Estas séries climatológicas de “boa qualidade” passam a ser as nossas séries de referência, as quais podem ser utilizadas em estudos de variações climáticas incluindo a validação de modelos climáticos.

**ABSTRACT:** This paper is addressed to the reconstitution of climatological fields using temporal or spatial interpolation for predicting missing values of climatological series. In this work one adopts three statistical approaches for time series reconstruction, based on the: (1) climatological normal; (2) autocorrelation function; and (3) spatial interpolation: (a) Direct *versus* (b) Indirect. To illustrate the “related reliability”, one analysis the Mean Squared Residuals (MSR) associated with each one of these reconstitution techniques. The results confirm that the northern stations do not present significant spatial correlation, which produces errors of “unacceptable” interpolation; this fact indicates that only temporal reconstitution, methods (1) or (2), must be implicated. The midland and southern stations exhibit good spatial correlation indicating that spatial prediction, method (3), is recommended for the reconstruction of the time series.

**Key words:** *autocorrelation memory; climate variability; mean squared error; missing values; spatial interpolation.*

### 1 - INTRODUÇÃO

Nos últimos anos um dos objectivos da Climatologia baseia-se em estudar a dinâmica da atmosfera por um período de tempo considerado “longo” e suas interacções recíprocas com o homem e o meio ambiente. A análise da variabilidade regional dos parâmetros climáticos recorre a técnicas estatísticas que frequentemente nos fornecem informações acerca do modelo atmosférico global (Capilla et al. 2002). A metodologia estatística pode envolver complexos modelos espaço-temporais que têm aplicações em várias áreas incluindo as ciências atmosféricas. Os resultados da modelação estatística dão indicação da variabilidade climática o que necessita de séries climatológicas de “boa qualidade”. Uma das medidas da boa qualidade das séries refere-se à homogeneidade temporal e espacial das mesmas assim como um número reduzido de falhas “*missing values*”. Por outro lado, os utilizadores dos registos climatológicos,

frequentemente, necessitam de dados temporais em localizações geográficas onde não fora observada qualquer medida directa das variáveis climatológicas. Condições climatológicas das áreas ou pontos de interesse têm que ser calculados interpolando observações no tempo de estações vizinhas. Um dos objectivos de se avaliar a consistência no espaço de uma série temporal é delinear as áreas para as quais a cadeia seja capaz de fornecer informações climatológicas suficientemente precisa, *i.e.*, onde os erros ou resíduos associados à interpolação no tempo ou no espaço não excedam um valor “aceitável” pelo utilizador.

O propósito deste trabalho é obter séries climatológicas homogéneas a partir de uma rede de campos meteorológicos. Adoptamos três critérios de reconstrução, baseados no Método de Interpolação Óptima (OIM) considerando o preenchimento das falhas através da:

1. Substituição dos “*missing values*” pela normal climatológica;
2. Interpolação temporal considerando a função de autocorrelação;
3. Interpolação espacial: método Directo *versus* método Indirecto.

Na reconstrução espacial foram utilizadas funções exponenciais que se mostraram satisfatórias para modelar a função de autocorrelação da precipitação, assim como a função esférica é a que melhor se adapta às temperaturas extremas. Este procedimento não serviu só para homogeneizar e completar as séries climatológicas, mas também para verificar se os valores apresentavam-se integrados numa estrutura espaço-tempo da série e é possível avaliar a estimativa do erro associado a cada valor estimado da nova série (Kusserow et al 1995). Numa primeira fase, com o objectivo de ilustrar o método, foram seleccionadas sete estações meteorológicas, consideradas representativas da variabilidade climática várias regiões de Portugal Continental, estimando e preenchendo os “*missing values*” nas séries (temperaturas extremas mensais e precipitação mensal acumulada), através da interpolação temporal ou espacial.

## 2 – METODOLOGIAS

Historicamente, a reconstrução de séries climatológicas não tem sido feita de forma sistemática e cuidadosa. Frequentemente, esta é realizada de forma aleatória e casual em que os “*missing values*” são substituídos pela normal climatológica, contudo sem o cálculo do erro associado a esta simulação. Métodos de homogeneização de séries e de recuperação de registos com falhas têm sido amplamente desenvolvidos, tendo estes processos por base, em regra a comparação com séries obtidas entre as mesmas características climáticas e a utilização da própria série para colmatar registos com falhas pois alguns indícios indicam, por exemplo a forte relação entre a variação da temperatura mínima e a máxima do ar, a forte relação entre um registo e o seu registo antecedente e subsequente. Algumas destas constatações poderão ser verificadas ao executar a análise da função correlação entre temperatura máxima e mínima de cada estação e aplicação da função autocorrelação para cada série de dados.

Neste trabalho foram utilizados três critérios para a reconstituição de campos meteorológicos, dando ênfase ao cálculo do resíduo quadrático médio (MSR) associado a cada simulação. A metodologia adoptada assenta na minimização do MSR recorrendo à interpolação temporal (normal climatológica e modelo autorregressivo integrado a médias móveis - ARIMA) e à interpolação espacial (directa e indirecta).

### 2.1 – INTERPOLAÇÃO TEMPORAL

Alguns dos conceitos inerentes à análise estatística de séries temporais, tem como objectivo corroborar a explicação dos métodos de previsão pela metodologia Box-Jenkins. Um processo estocástico temporal envolve sempre uma variação de uma

função no tempo. A diferença fundamental entre um processo estocástico e uma variável aleatória é exactamente a determinação de estrutura de dependência ou correlação. Os processos estocásticos temporais podem ser considerados como sendo funções que variam no tempo mas que têm uma intensidade que varia de forma aleatória.

Na prática, as séries climatológicas analisadas são não-estacionárias, ou seja partes diferentes destas séries comportam-se de forma semelhante excepto na sua diferença ao nível das médias locais. Sejam  $\{Z_t\}$   $n$  realizações dum processo estocástico no domínio do tempo e  $\varepsilon_t$  uma série de variáveis aleatórias não-correlacionadas:  $\varepsilon_t \approx N(0, \sigma^2)$ . O processo gerador das séries observadas pode ser modelado através do modelo sazonal  $ARIMA(p, q, d) \times (P, Q, D)_s$  dado pela equação:

$$\Phi(B)\Phi_s(B^s)Y_t = \Theta(B)\Theta_s(B^s)\varepsilon_t, \quad (1)$$

onde  $Y_t = \nabla^d \nabla_s^D Z_t$  com  $\nabla = 1 - B$  e  $\nabla_s = (1 - B^s)$  os operadores diferença. Neste caso, as séries das diferenças  $Y_t = \nabla^d \nabla_s^D Z_t$  são descritas por um modelo  $ARMA(p, q)$  estacionário (Box e Jenkins, 1976). Para determinar se a estacionariedade foi obtida, quer pela remoção da tendência quer pela diferenciação, deve examinar-se a função de autocorrelação das séries dos resíduos. Uma vez que o grau de diferenciação tenha sido determinado, as ordens dos parâmetros associados ao modelo autorregressivo integrado a médias móveis são seleccionados através da análise das características da função de autocorrelação (ACF ( $\gamma$ )) e da função de autocorrelação parcial (PACF ( $\pi$ )). Segundo Wei (1990), no diagnóstico do modelo, deve-se atentar aos seguintes factos:

1. A variância do processo ARIMA é dependente do tempo;
2. A variância do processo ARIMA não é assintoticamente limitada;
3. A ACF ( $\gamma$ ) é também dependente do tempo e é invariante relativamente à translação no tempo.
4. A ACF ( $\gamma$ ) tende assintoticamente a zero.

A expressão que nos permite calcular o resíduo quadrático médio é a seguinte:

$$MSR = \frac{\sum_{i=1}^n (Z_i - \bar{Z})^2}{n} \quad (2)$$

O processo de interpolação temporal só é válido se o MSR seguir uma distribuição normal; isto é, os resíduos são não autocorrelacionados com média nula e variância constante.

### 2.1.1 – TRANSFORMAÇÕES QUE ESTABILIZAM A VARIÂNCIA

Nem todos os problemas de não-estacionariedade podem ser solucionados através da diferenciação da série. Algumas séries temporais podem ser estacionárias com relação à média, porém não o são para a variância. Assim, há necessidade de se introduzir uma função estabilizadora de forma que a série transformada apresente uma variância constante. De forma geral para se estabilizar a variância podemos utilizar a transformada da potência, introduzida por Box e Cox (1964):

$$T(Z(t)) = Z(t)^\lambda = \frac{Z(t)^\lambda - 1}{\lambda}, \quad (3)$$

onde  $\lambda$  é o chamado parâmetro de transformação. Esta função estabilizadora (3) deve obedecer aos seguintes requisitos:

- 1º - A função estabilizadora só é definida para séries positivas.

2º - A transformada estabilizadora pode ser aplicada antes de ser feita qualquer outra análise, nomeadamente a da diferença.

3º - O atributo  $\lambda$  na transformada de potência pode ser tomado como parâmetro no modelo a ser estimado a partir das séries observadas. A estimativa da probabilidade máxima de  $\lambda$  é aquela que minimiza o quadrado da soma residual (Wilks, 1995).

## 2.2- INTERPOLAÇÃO ESPACIAL

Neste segundo momento da etapa de reconstrução das séries de dados, deve ter-se em conta a dependência espacial entre estações meteorológicas. Para este efeito desenvolveu-se um algoritmo que permite, de uma forma consistente, colmatar os vários registos com falhas. Os parâmetros e os ponderadores utilizados no algoritmo baseiam-se na informação disponível do carácter georeferenciado, assumindo dependência espacial nos diferentes pontos (longitude, latitude). Considerando que as observações meteorológicas utilizadas se encontram numa área relativamente grande e que, este factor implica uma grande diversidade entre as estações meteorológicas, procurou-se através da comparação das observações obter parâmetros estatísticos independentes do tempo, permitindo assim num determinado momento estimar um ponto de uma malha utilizando a informação das observações meteorológicas de todos os outros pontos da malha.

Sejam  $\{Z(s)\}$   $n$  realizações dum processo estocástico espacial e  $\varepsilon(s)$  variáveis aleatórias não-correlacionadas:  $\varepsilon_i \approx N(0, \sigma^2)$ . Neste modelo o processo estocástico espacial é constituído por duas componentes:

$$Z(s) = \mu(s) \cdot \beta + \varepsilon(s), \quad (4)$$

onde  $\mu(s) \cdot \beta$  é a tendência à superfície em larga escala (a componente de 1ª ordem) e  $\varepsilon(s)$  representa a componente local (a componente de 2ª ordem). A decomposição do processo em duas componentes é meramente teórica. No entanto, este pressuposto permite-nos compreender certas características comportamentais do processo e prever o seu comportamento futuro. Na prática, estamos interessados em modelar a componente de 1ª ordem. Concluindo, podemos afirmar que os objectivos da modelação são os seguintes:

1. Compreender e descrever a natureza da variação, através dos dados observados e isolar a tendência exibida em larga escala;
2. Modelar a estrutura de covariância no fim de ser retirada a tendência à série de dados observados. Ou seja, o interesse é a predição ou interpolação nos locais que não foram amostrados ou onde ocorreram falhas na observação.

Tal como no caso anterior a interpolação espacial só é válida se os MSR foram não autocorrelacionados com média nula e variância constante.

### 2.2.1- FUNÇÃO VARIOGRAMA

Antes de iniciar-mos o processo de Krigagem é necessário estimar a função variograma associada à função de covariância, que nos fornece o grau de dependência espacial do processo ou fenómeno sob estudo. O objectivo é obter uma estimativa indirecta da matriz de covariância espacial. Subsequentemente, utiliza-se o método dos mínimos quadráticos generalizados para obter um modelo contínuo que incorpore de forma simultânea os efeitos de 1ª e de 2ª ordem. No entanto, isto só faz sentido se os dados apresentam estacionariedade de segunda ordem, pois em caso contrário o variograma é dominado pela componente de 1ª ordem e podemos não ter informação a cerca da

variação da componente de 2ª ordem isoladamente. A matriz de covariância deve ser simétrica e positiva semi-definida. O variograma fornece os ponderadores ( $\lambda$ ) para o sistema de interpolação espacial por Krigagem.

### 2.2.2 – KRIGAGEM DIRECTA

O modelo paramétrico  $\mu(s).\beta$  pode representar uma variação lenta e  $\varepsilon(s)$  pode representar o desvio padrão de  $\mu(s).\beta$ , que é a sobreposição linear de funções básicas

$$\mu(s_0) = \sum_n \lambda_i Z(s_i). \quad (5)$$

O campo  $\varepsilon(s)$  é modelado como um campo aleatório gaussiano tendo uma função de autocovariância estacionária e homogénea. A série completa das observações directas é decomposta em duas sub-séries uma “*continuos*”:  $Z_C$  e outra com “*missing values*”:  $Z_M$ .

O objectivo deste trabalho é determinar a melhor estimativa para  $\lambda$  considerando apenas  $Z_C$ .

### 2.2.3 – KRIGAGEM INDIRECTA (MÉTODO DE GANDIN)

Com este método no lugar de interpolar o campo das observações directas interpola-se a anomalia associada e as propriedades da correlação espacial do campo de anomalias são analisadas. Contudo, se o ponto onde a predição é requerida é um dos pontos medidos, podemos calcular a covariância com as outras estações vizinhas:

$$\mu(s_0) = \sum_n \lambda_i (Z(s_i) - \bar{Z}), \quad (6)$$

onde a matriz de covariância pode ser obtida a várias escalas (mensal, sazonal, anual).

## 3 – CONDIÇÕES EXPERIMENTAIS

Para ilustrar os métodos foram analisadas a temperatura absoluta máxima e mínima mensal e a precipitação mensal acumulada observadas em sete estações meteorológicas clássicas do Instituto Meteorológico de Portugal (Montalegre, Porto – Serra do Pilar, Guarda, Lisboa – Geofísico, Évora, Beja e Faro), estações estas que supostamente cobrem a variabilidade climática das várias regiões de Portugal Continental. O período em análise é de 1956 a 2000. Na Figura 1 discrimina-se a localização espacial das estações meteorológicas consideradas neste estudo.

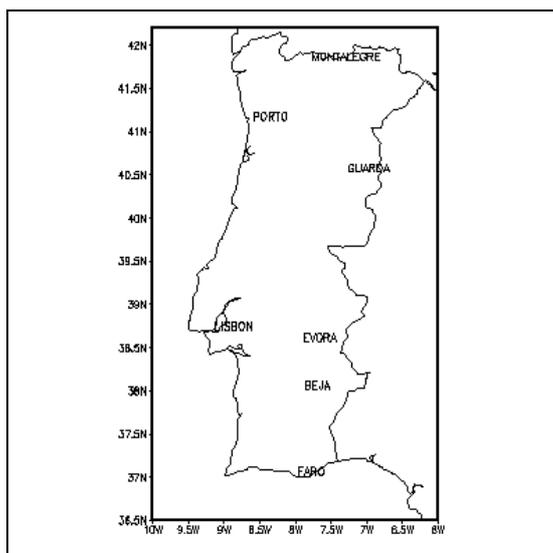
O tipo de falhas apresentado por estas estações é muito diversificado:

1. Beja tem uma falha ao nível das temperaturas extremas;
2. Porto – Serra do Pilar tem uma falha que corresponde a um ano completo ao nível das temperaturas extremas;
3. Montalegre e Guarda têm várias falhas quer ao nível das temperaturas extremas quer ao nível da precipitação mensal acumulada;
4. Évora e Faro têm falhas ao nível da precipitação mensal acumulada.

Lisboa–Geofísico é uma série completa não apresentando qualquer tipo de falha.

## 4 – ANÁLISE DOS RESULTADOS

Após a aplicação das várias técnicas de interpolação verificamos que não há uma técnica que seja incomparavelmente melhor do que as outras. A técnica a adoptar depende do tipo de falha que a série apresenta assim como da localização espacial da estação meteorológica. Seguidamente vamos apresentar alguns dos resultados obtidos neste trabalho.



**Figura 1** – Mapa de Portugal Continental com a localização das sete estações meteorológicas (IM), que supostamente cobrem a variabilidade climatológica do território. (Case Study: Target Climatological Stations from Mainland Portugal)

## 4.1 RESULTADOS OBTIDOS POR INTERPOLAÇÃO TEMPORAL

### 4.1.1 – BEJA

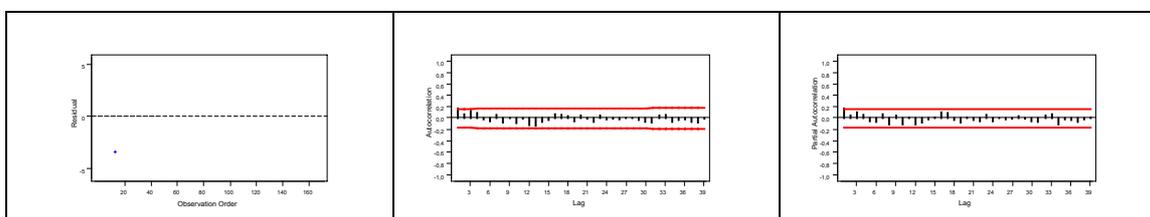
A série de temperaturas extremas desta estação apresenta um “missing values” (Setembro de 1975) e os resultados obtidos na previsão desses valores estão sumariados na Tabela I.

**TABELA I**

TEMPERATURA	NORMAL		ARIMA	
	TMAX	TMIN	TMAX	TMIN
$\hat{Z}$	36,2	9,9	35,5	9,4
MSR	8,3	3,3	6,9	2,8

Resultados obtidos na previsão do “missing values” da estação de Beja.

Pela análise da Figura 2 verificamos que os MSR seguem uma distribuição normal. O gráfico das funções ACF e PACF continuam a exibir alguns picos para lags que não correspondem aos múltiplos de 12 porque ao processo está associado um ruído branco.



**FIGURA 2** – Gráfico dos resíduos versus a ordem dos dados e têm uma distribuição normal. No gráfico da ACF e da PACF, a existência de alguns picos revelam a existência de um ruído branco.

#### Modelo ARIMA para TAMIN:

Tipo Coef SE Coef t p  
SMA 12 0,8873 0,0593 14,96 0,000

Differencing: 1 seasonal of order 12

Residuals: SS = 472,331 MS = 3,047 DF = 155

Modified Box-Pierce (Ljung-Box) Chi-Square statistic:

p-value 0,123 (12) 0,371 (24) 0,729 (36) 0,388 (48)

Verificamos que o critério menos adaptável ao preenchimento desta falha é a previsão pela normal climatológica. Quer a interpolação espacial quer o ARIMA dão-nos resultados satisfatórios pois o MRS não excede o percentil 75 do desvio padrão.

#### 4.1.2 – MONTALEGRE

Na série associada a esta estação fez-se a previsão das temperaturas extremas relativamente a um ano completo (2000) e os resultados estão apresentados na Tabela II

**TABELA II**

TEMPERATURA	NORMAL		ARIMA	
	TMAX	TMIN	TMAX	TMIN
$\hat{Z}$	12,9	-4,72	12,68	-4,28
	14,0	-4,22	13,89	-4,04
	17,4	-3,12	17,09	-2,87
	19,4	-1,79	19,63	-1,80
	23,3	0,19	23,66	0,46
	27,5	3,26	27,73	3,44
	30,5	6,92	30,91	6,96
	30,3	6,56	30,41	6,56
	28,0	4,62	28,04	4,75
	21,6	1,45	21,68	1,65
	17,3	-1,75	16,97	-1,68
	14,2	-3,89	13,84	-3,96
	MSR	6,5	2,3	7,0

Valores obtidos na previsão dos “missing values” (ano 2000) para a estação de Montalegre

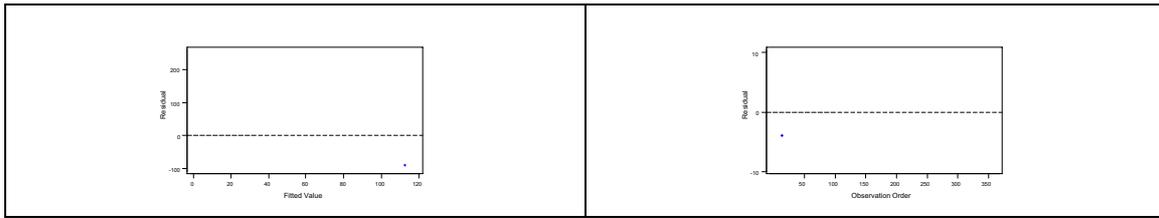
#### Modelo ARIMA para TAMIN:

Tipo Coef SE Coef t p  
 SMA 12 0,9484 0,0208 45,56 0,000  
 Differencing: 1 seasonal of order 12  
 Residuals: SS = 1930,43 MS = 3,75 DF = 515  
 Modified Box-Pierce (Ljung-Box) Chi-Square statistic  
 p-value 0,000 (12) 0,000 (24) 0,002 (36) 0,022 (48)

Os resultados da estatística do  $\chi^2$  e de Box-Ljung revelam que os resíduos são autocorrelacionados pelo que seria conveniente modelá-los como um ARMA. Pelo facto de não termos definido o modelo ARIMA com erro ARMA o MRS associado à substituição pela normal climatológica é menor que o MRS associado ao ARIMA. A interpolação espacial relativamente a esta estação não conduz a resultados satisfatórios, em parte é devido à orografia bastante irregular e diversificada associada à região desta estação climatológica.

#### 4.1.3 – ÉVORA

Esta estação apresenta 2 “missing values” ( Fevereiro e Março) ao nível da precipitação mensal acumulada. Pela análise do gráfico dos resíduos *versus* os valores determinados e verificamos que os resíduos estão altamente correlacionados (fig. 3) pelo que optamos por aplicar a função estabilizadora  $\sqrt{\text{precipitação}}$  e comparamos com o novo gráfico obtido para os resíduos (fig.3) já exhibe uma distribuição aleatória conduzindo a uma distribuição normal de média nula e variância constante, facto este que é corroborado pelos valores obtidos para o p-value da estatística do  $\chi^2$  e Box-Ljung.



**Figura 3** – Gráfico dos resíduos *versus* os valores determinados para a precipitação antes de aplicar a função estabilizadora e após aplicar a função estabilizadora.

Os valores obtidos pelos testes antes e depois de aplicar a função estabilizadora estão apresentados na Tabela III

**TABELA III**

PRECIPITAÇÃO	NORMAL	ARIMA	ARIMA*
$\hat{Z}$	8,2	81,8	8,4
MSR	6,5	55,7	6,8
	48	2389	10

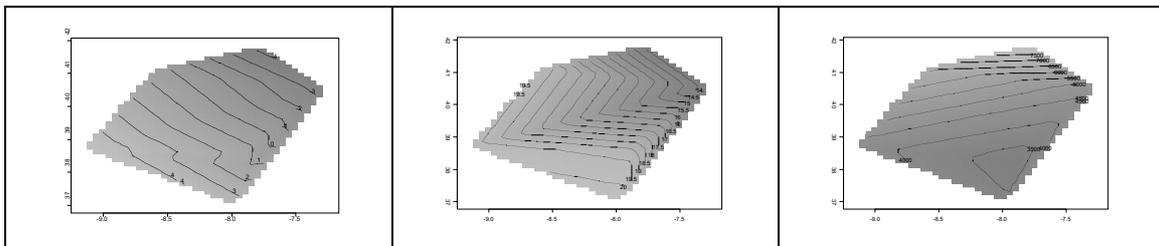
\*Dados obtidos para a precipitação antes e depois de aplicar a função estabilizadora à variância.

**Modelo ARIMA para a SQRT(PRECIPITAÇÃO)**

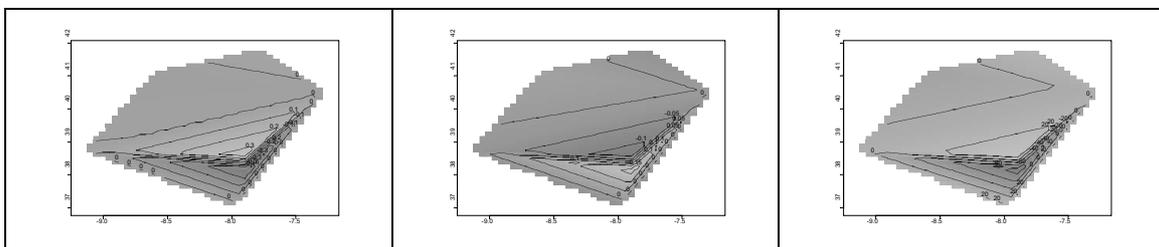
Tipo Coef SE Coef t p  
 SMA 12 0,9458 0,0258 36,62 0,000  
 Differencing: 1 seasonal of order 12  
 Residuals: SS = 3388,34 MS = 9,76 DF = 347  
 Modified Box-Pierce (Ljung-Box) Chi-Square statistic  
 P-Value 0,349 (12) 0,472 (24) 0,709 (36) 0,346 (48)

**4.2 - RESULTADOS OBTIDOS POR INTERPOLAÇÃO ESPACIAL**

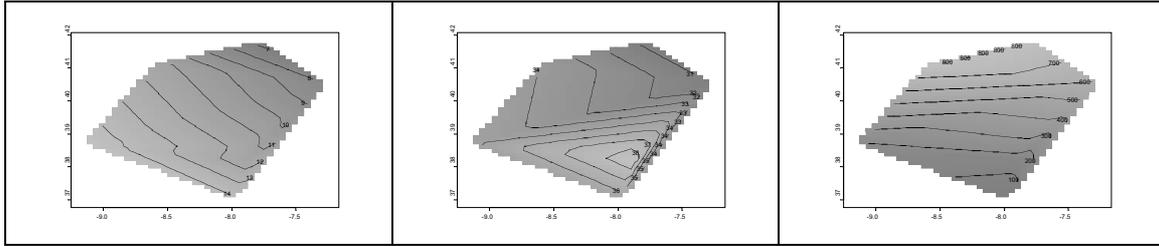
Da análise da interpolação espacial efectuada para os vários meses do ano e para as variáveis em estudo seleccionamos apenas os resultados obtidos por krigagem directa e krigagem indirecta referentes aos meses de Fevereiro (Figuras 4, 5, 8e 9) e de Julho (Figuras 6, 7, 10 e 11).



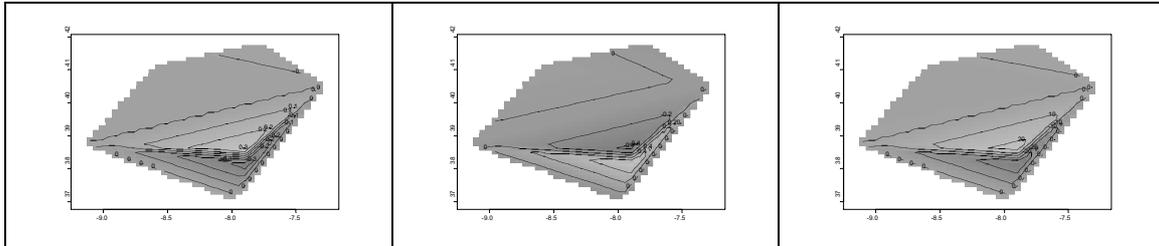
**Figura 4** - Isolinhas de temperatura (mínima e máxima) e precipitação para o mês de Fevereiro.



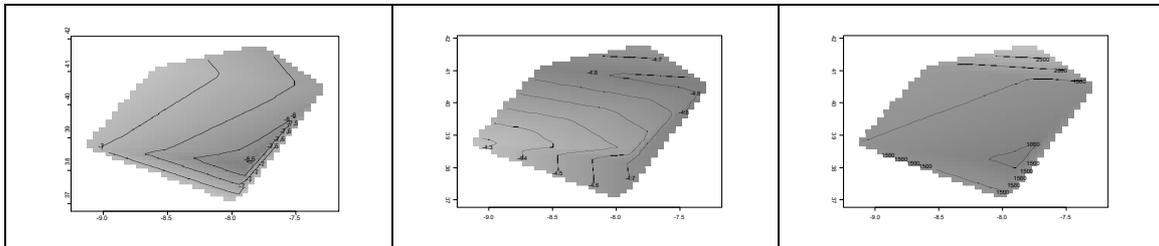
**Figura 5** - Isolinhas dos resíduos associados ao ajuste de temperatura (mínima e máxima) e de precipitação para o mês de Fevereiro.



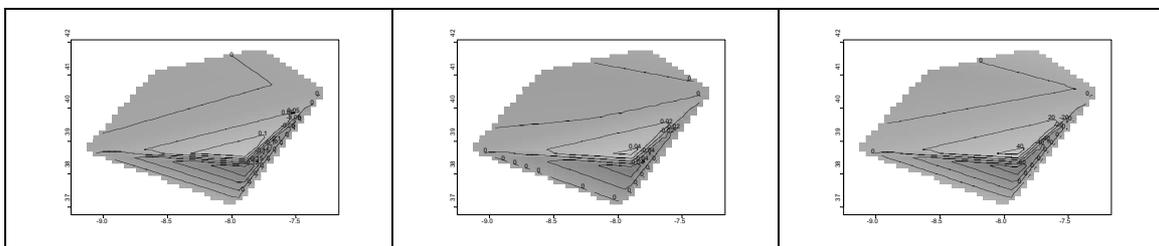
**Figura 6** - Isolinhas de temperatura (mínima e máxima) e precipitação para o mês de Julho.



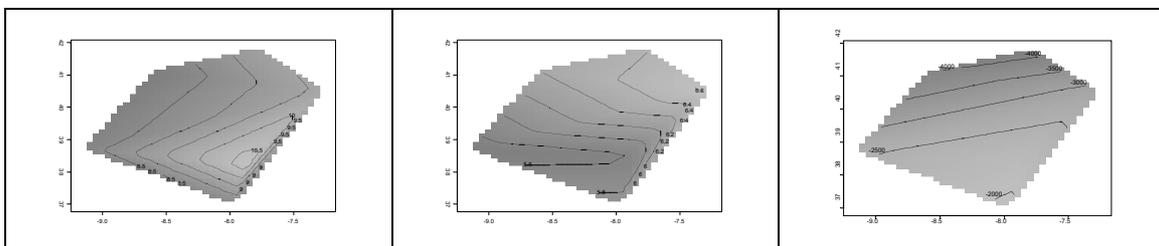
**Figura 7** - Isolinhas dos resíduos associados ao ajuste de temperatura (mínima e máxima) e de precipitação para o mês de Julho.



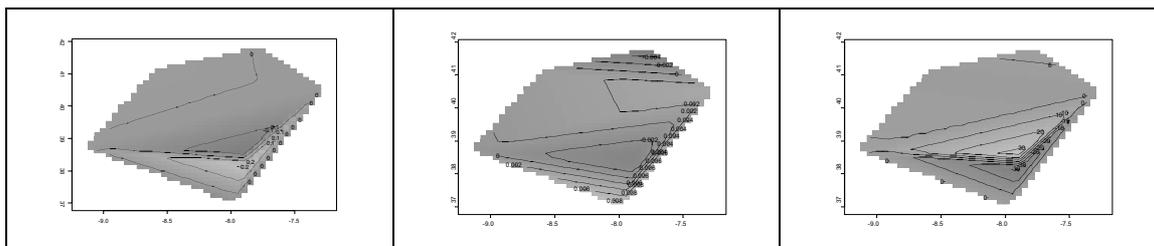
**Figura 8** - Isolinhas da anomalia de temperatura (mínima e máxima) e precipitação para o mês de Fevereiro.



**Figura 9** - Isolinhas dos resíduos associados ao ajuste da anomalia de temperatura (mínima e máxima) e de precipitação para o mês de Fevereiro.



**Figura10** - Isolinhas da anomalia de temperatura (mínima e máxima) e precipitação para o mês de Julho.



**Figura11** - Isolinhas dos resíduos associados ao ajuste da anomalia de temperatura (mínima e máxima) e de precipitação para o mês de Julho.

Podemos verificar que a nível das temperaturas mínimas há um padrão espacial e temporal regular para os vários meses do ano. Assim como as regiões mais pluviosas numa estação do ano mantêm comportamento idêntico nas outras estações do ano. Ao nível das anomalias da temperatura máxima e precipitação o padrão é pouco regular pelo que conduz a resultados não muito satisfatórios. Por outro lado verificamos que a simulação feita para sul do país é aquela que apresenta um resíduo quadrático médio menor.

## 5 – CONCLUSÕES

Os resultados confirmam que as estações no norte do país não apresentam uma significativa correlação espacial, devido a uma grande complexidade da orografia o que produz erros de interpolação inaceitáveis; este facto indica que o método a ser aplicado é o de reconstituição temporal. As estações da zona centro e especialmente sul do país exibem uma boa correlação espacial indicando que o método de interpolação espacial é o mais recomendado na reconstrução das séries climatológicas. Contudo as áreas foram delimitadas onde o MSR associado à interpolação não excede o percentil 75 do desvio-padrão do local para cada mês e estação considerando zonas de influência.

Assumindo um erro relativo arbitrário de 10% o país é representado apropriadamente pelas séries à excepção de algumas áreas devido às condições específicas de orografia e se está localizada no interior do país ou numa zona de influência simultânea do oceano Atlântico e do mar Mediterrâneo. Verifica-se que o método de interpolação óptima em termos da MSR conduz a resultados pouco robustos face aos *outliers*.

Em suma podemos afirmar que este trabalho apresenta um método de reconstrução e homogeneização das séries climatológicas com “*missing values*” no qual a estrutura espaço-temporal dos campos (de temperaturas extremas e precipitações acumuladas) investigados é analisada isoladamente; assim como, a estimativa do MSR é avaliado para cada simulação e é possível calcular o MSR para cada valor da nova série de dados.

## 5 – REFERÊNCIAS

- Bailey, T. C., Gatrell A. C., Interactive Spatial Data Analysis, Addison-Wesley Longman Limited, England, 1995.
- Capilla, C., Capilla, R, Modeling the heterogeneous spatial structure of temperature observations from a meteorological network in Spain, Journal of Geophysical Research, vol 107, 2002.
- Cressie, N. A. C., Statistics for Spatial Data, rev. ed., John Wiley, New York, 1993.
- Kusserow, A. H., Optimum Averaging of Incomplete Climatological Data, 6<sup>th</sup> International Meeting on Statistical Climatology, Ireland, 1995.
- Vázquez, C. L., Application of ANN to the prediction of missing daily precipitation records, and comparison against linear methodologies, International Conference on Engineering Applications of Neural Networks, Stockholm, 1997.
- Wei, W. W. S., Time Series Analysis, Addison-Wesley Publishing Company, 1994.
- Wilks, D. S., Statistical Methods in the Atmospheric Sciences, Academic Press, New York, 1995