

# Análise espaço-temporal dos extremos de precipitação para o estado do Espírito Santo

Kenny Delmonte Oliveira <sup>1</sup>

<sup>1</sup>Instituto Nacional de Pesquisas Espaciais - INPE  
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil  
{kenny.oliveira}@inpe.br

**Abstract.** Among the main global climate change characteristics is the increase of the extreme weather events, mainly related to unusual droughts and heavy rainfall, which causes huge social and economic damages. In this context, the development of techniques that can help identify risk areas and contribute to the mitigation of the impacts is of substantial value for the planning actions of monitoring and reduction of injuries. The aims of this work were to analyze the space-time distribution of the variables controlling the magnitude for extreme precipitations of the State of Espírito Santo, to represent them in several scenarios of return period and to point out the uncertainties generated by the indicator kriging to the probability distribution function. The results showed that the distribution curve of the probability density functions generated increases drastically in the 1 to 10 years period and later stabilizes. The uncertainty map created by indicator kriging has the advantage of being fixed at time, that is, the uncertainty is the same for any return period, and can also support the decision about the major errors; and important application of the variation coefficient uncertainty map (%) in the decision making for future studies with maximum precipitation events.

**Palavras-chave:** indicator kriging, maximum precipitation distribution, return period, krigagem indicativa, distribuição da precipitação extrema, período de retorno.

## 1. Introdução

Eventos climáticos extremos têm sido apontados como uma das principais consequências das mudanças climáticas globais. De acordo com o relatório do Painel Intergovernamental de Mudanças Climáticas (IPCC), estes eventos podem ocorrer sob a forma de fortes precipitações, ondas de calor, secas severas e fenômenos climáticos de grande magnitude ou de frequência anormal, culminando em desastres naturais de consequências calamitosas para habitantes de áreas mais vulneráveis além de perdas econômicas, principalmente relacionadas à produção agrícola.

Em diversas partes do mundo eventos como precipitações extremas, tufões, secas severas, dentre outros, vêm tornando-se cada vez mais frequentes. No Brasil, cabe destacar o furacão Catarina, em 2004; seca na Amazônia, em 2005; e chuvas extremas no Espírito Santo, em 2013, todos com consequências desastrosas para as comunidades envolvidas.

Para o sudeste brasileiro, Marengo et al. (2009) afirma que desde a década de 50 a região tem apresentado eventos pluviais extremos. De acordo com o Instituto Nacional de Meteorologia (INMET), as chuvas de dezembro de 2013, na região sudeste do país, estão entre os maiores desastres naturais já registrados na região, deixando 46 vítimas fatais e mais de 54 mil desalojados ou desabrigados, afetando um total de 155 municípios entre o estado do Espírito Santo e a faixa leste do estado de Minas Gerais. Só no estado do Espírito Santo, de 2000 a 2009, cerca de 4.023.187 pessoas foram afetadas de alguma maneira (desalojados, desabrigados, feridos e mortos) por eventos extremos, que por sua vez ainda resultou em um prejuízo em torno de R\$1.257.975.844,11 somando os danos materiais, ambientais, econômicos e sociais, afirma o autor.

Os custos sociais e econômicos decorrentes de tragédias geradas por estes eventos, principalmente diante de previsões de aumento de sua ocorrência, demandam estudos para identificação de zonas de risco e planos de monitoramento. Em ambos os casos se faz necessária a previsão destes fenômenos utilizando, por exemplo, o período de retorno geralmente abordado em obras hidráulicas para planejamento de defesa civil.

O período de retorno ( $t$ ), também conhecido como período de recorrência ou tempo de recorrência, é o intervalo de tempo estimado de ocorrência de um determinado evento. É definido como o inverso da probabilidade de um evento ser igualado ou ultrapassado. Este parâmetro estatístico tem grande utilidade para análises de risco e dimensionamento de obras de engenharia, geralmente com o objetivo de quantificar a ocorrência de certo fenômeno natural.

Sendo  $t$  obtido majoritariamente, como um dado pontual e limitado a um intervalo de tempo, seria possível tornar essa informação disponível para qualquer local e momento de forma que as incertezas fossem invariantes temporalmente?

Assim, destacada a importância espaço-temporal dessa variável e a limitação de registros em áreas específicas, buscou-se por meio do presente trabalho realizar a modelagem probabilística de eventos de precipitação extrema para o estado do Espírito Santo, de forma que os dados de chuvas extremas possam ser calculados para qualquer período de retorno desejado sob suporte de análise de incerteza dos dados.

## 2. Metodologia de trabalho

O local do estudo compreende o estado do Espírito Santo, situado entre as coordenadas de latitude  $-17^{\circ}52'$  e  $-21^{\circ}17'$  e longitude  $-41^{\circ}54'$  e  $-39^{\circ}38'$ , com área de  $46.077,51\text{km}^2$  (Figura 1). O Estado é grande produtor agrícola de café, eucalipto, culturas frutíferas, dentre outros. Possui clima diversificado variando de quente e seco na porção norte, a frio e úmido na região sul, ditado tanto pelo efeito de continentalidade e maritimidade, quanto pelas condições topoclimáticas, devido ao elevado gradiente altitudinal resultante da complexa topografia.

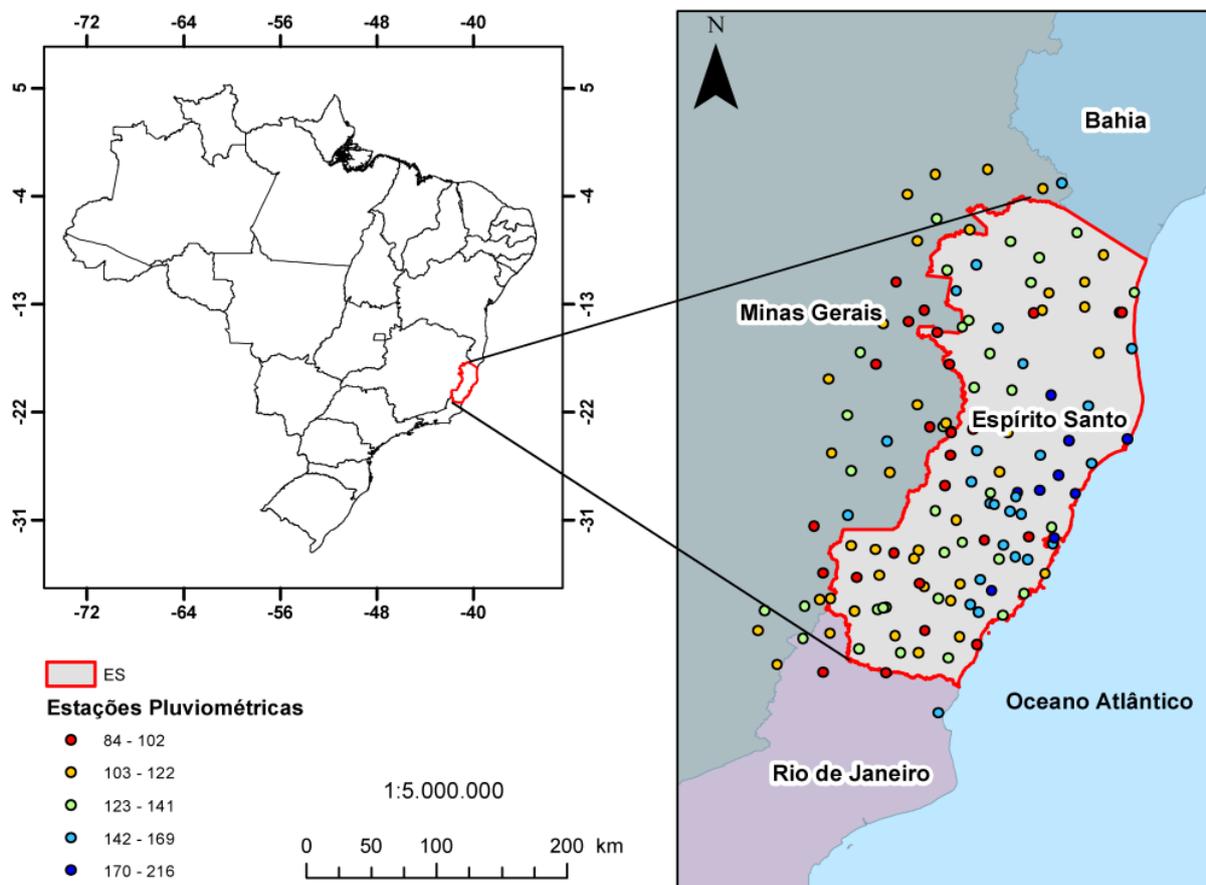


Figura 1 – Área de estudo.

## 2.1 Base de dados e ajuste de funções de distribuição de densidade de probabilidade

Para a análise dos extremos de precipitação utilizaram-se dados de precipitação diária de 134 estações automáticas da Agência Nacional das Águas (ANA) e do INMET no período de janeiro de 2007 a setembro de 2015, sendo contempladas também as estações fora dos limites da área de estudo para aprimoramento da espacialização dos dados.

Da série histórica de cada estação, foi obtido o evento extremo máximo de cada ano, compondo assim a série histórica de chuvas máximas anuais. Aos dados foram ajustadas cinco funções de distribuição de densidade de probabilidade para eventos extremos máximos, a saber: Gumbel, Log-Normal tipo II e III, Pearson tipo III e Log- Pearson tipo III.

Para as distribuições de frequência utilizadas, a estimativa da “magnitude da precipitação máxima com determinado período de retorno” ( $K$ ) é dada pela Equação 1. Onde  $t$  é o período de retorno,  $\sigma$  e  $\mu$  são o desvio padrão e média dos eventos das amostras, respectivamente.

$$M = \mu + K \sigma \quad (1)$$

## 2.2 Decorrelação de variáveis correlacionadas

A existência de correlação entre atributos de amostras de uma mesma localidade, ou seja, a não independência das variáveis, pode resultar na combinação de altos valores de um atributo com baixos valores do outro, culminando na representatividade irrealista do fenômeno e comprometimento dos resultados da modelagem. Visando não incorrer nesse problema avaliou-se a correlação entre os parâmetros que comporiam a função de densidade de probabilidade (fdp) de eventos extremos e uma vez identificada correlação, procedeu-se com a decorrelação das mesmas com a técnica de principais componentes segundo Richards (1986), resultando em novos conjuntos de dados totalmente decorrelacionados, e sobre os mesmos realizou-se a espacialização dos dados por Krigeagem Ordinária. Após espacializados, a transformação inversa da principal componente foi aplicada sobre os parâmetros, garantindo que os cálculos fossem feitos considerando a unidade de medida do fenômeno.

## 2.3 Simulação geoestatística

Uma vez definida a fdpa de melhor ajuste, com menor erro padrão e maior estabilidade espacial, os parâmetros da própria função de eventos extremos foram espacializados por Krigeagem Ordinária, de forma a possibilitar, por álgebra de mapas, a obtenção do período de retorno para qualquer intervalo de tempo desejado.

A krigagem ordinária considera apenas a minimização da variância do erro associado à estimativa gerada pela análise variográfica. Enquanto que a krigagem indicadora - KI faz uma análise dos modelos de incerteza, ou seja, determinação da função densidade de probabilidade acumulada (fdpa) para cada posição do espaço considerado, representadas por vetores  $x$ . O cálculo da análise de incerteza da probabilidade de ocorrência dos dados, foi realizado KI. Para compor a fdpa foram estabelecidos nove teores de corte (*cutoff*) com referência nos percentis de 10%, 20%,..., 90% sob os dados amostrados, obtendo-se portanto nove mapas de probabilidade.

## 2.4 Simulação condicionada e análise de incertezas

As probabilidades  $P(Z(x_0) \leq z_{c1})$ ,  $P(Z(x_0) \leq z_{c2})$ ,...,  $P(Z(x_0) \leq z_{ck})$  associadas aos valores dos teores de corte  $z_{c1}$ ,  $z_{c2}$ ,..., $z_{ck}$  constituem a distribuição de probabilidades de  $Z(x)$ . As probabilidades calculadas devem apresentar caráter monotônico, ou seja,  $P(Z(x_0) \leq z_{c1}) < P(Z(x_0) \leq z_{c2}) < \dots < P(Z(x_0) \leq z_{ck})$ , para  $z_{c1} < z_{c2} < \dots < z_{ck}$ , caso contrário, diz-se que houve problema de relação de ordem (Hohn, 1998). Os problemas de relação de ordem são comuns já que para cada teor de corte há um semivariograma ajustado com diferentes patamares e amplitudes. Assim, visando não incorrer nesse problema adotou-se a proposta de Deutsch e

Journal (1992) de utilizar o variograma da indicadora da mediana para estimativa de todas as demais probabilidades que irão compor a fdpa condicional.

O procedimento para o uso da KI foi realizado segundo Druck et al. (2004) e Yamamoto e Landim (2009). Dada uma variável aleatória  $z(x)$  definiu-se o teor de corte de tal modo que esteja dentro do intervalo desta variável. Esta é caracterizada pela sua fdpa univariada,  $F(x, z)$ , definida como:

$$F(x; z) = Prob\{Z(x) \leq z\} \quad (2)$$

A fdpa foi construída condicionada aos  $n$  dados amostrados,  $F(x; z | (n))$ , dada por:

$$F(x; z | (n)) = Prob\{Z(x) \leq z | (n)\} \quad (3)$$

A  $F(x; z | (n))$  modela a incerteza da variável  $Z$  no local  $x$ , após estimada esta função, pode-se utilizá-la tanto para produzir estimativa dos valores em locais não conhecidos como modelar a incerteza destes valores. Para tanto, calculou-se as estimativas dos valores desconhecidos  $\hat{z}(x)$  e de sua respectiva variância  $\hat{\sigma}^2(x)$ , e construiu-se um intervalo de confiança do tipo gaussiano centrado em  $\hat{z}(x)$ :

$$Prob\{z(x) \in [\hat{z}(x) - 2\hat{\sigma}(x), \hat{z}(x) + 2\hat{\sigma}(x)]\} \quad (4)$$

Baseando-se na Equação 2, essa técnica indicadora foi considerada como a esperança de uma variável por indicação,  $I(x, z_k | (n))$ , em  $n$  amostras:

$$F(x; z_k | (n)) = E\{I(x, z_k) | (n)\} \quad k = 1, \dots, K \quad (5)$$

onde  $I(x, z_k | (n)) = 1$  se  $z(x) \leq z_k$  e  $I(x, z_k | (n)) = 0$  se  $z(x) > z_k$ .

Os indicadores foram estimados por meio da transformação dos dados para valores binários 0 e 1. Com a variável  $Z(x)$  discretizada em  $K$  teores de corte, a fdpa foi construída. A partir desta derivou-se a média e variância condicionais. A primeira é do tipo  $E$  e se comporta de acordo com a seguinte equação (Deutsch e Journal, 1992):

$$\hat{z}_E(x) = \sum_{k=1}^{K+1} z_{k,k-1} [\hat{F}(x; z_k | (n)) - \hat{F}(x; z_{k-1} | (n))] \quad (6)$$

em que  $z_{k,k-1} = \frac{z_k + z_{k-1}}{2}$  é o ponto médio da classe.

Já a variância condicional foi calculada pela equação 7:

$$\sigma_E^2(x) = \sum_{k=1}^{K+1} [z_k - \bar{z}_{z_k}(x)]^2 [\hat{F}(x; z_k | (n)) - \hat{F}(x; z_{k-1} | (n))] \quad (7)$$

Para gerar as incertezas derivou-se também outra medida usando as propriedades da distribuição normal, por meio dos percentis 84% e 16% mostrada por Hohn (1988) como segue:

$$\mu + 1\sigma_\phi = \phi_{84} \quad (8)$$

$$\mu - 1\sigma_\phi = \phi_{16} \quad (9)$$

Subtraindo-se a Equação 8 da Equação 9 obteve-se o desvio padrão condicional para cada um dos parâmetros da fdpa de eventos extremos. Este procedimento resultou nos mapas de incerteza da média e do desvio padrão amostrais. No entanto, a tomada de decisão sobre mais de um mapa de incerteza pode ser complexa, assim, é possível, ao considerar os dois parâmetros citados, obter Coeficiente de Variação (CV) condicional gerado a partir da razão do mapa de incerteza da probabilidade do desvio padrão condicional pela incerteza da probabilidade da média condicional

Tanto para krigagem ordinária quanto para a indicadora foram testadas os seguintes modelos experimentais de semivariograma: circular, esférico, tetraesférico, pentaesférico, exponencial, gaussiano, quadrático racional, efeito furo (*hole effect*), K-Bessel, J-Bessel e estável. Para cada um desses foram feitas as otimizações dos parâmetros do semivariograma (efeito pepita, alcance e patamar) conjuntamente com base na validação cruzada. Uma vez identificado o modelo de melhor ajuste considerou-se o efeito de anisotropia, de vizinhança

(padrão ou suavizado) e os tipos de setores de vizinhança (um setor, 4 setores, 4 setores com *offset* de 45° e 8 setores).

A avaliação da qualidade do ajuste do semivariograma foi realizada com base nas seguintes medidas de desempenho: o Erro Médio Padrão, Raiz do Quadrado Médio do Erro e Raiz do Quadrado Médio do Erro Padronizado.

O mapa de  $M$  foi gerado por álgebra de mapas para cada período de retorno e o mapa de incerteza de acordo com as equações 8 e 9.

O pressuposto fundamental deste estudo é o de encontrar os locais de menor incerteza para eventos de precipitação máxima e entender as diferenças de magnitude para cada período de retorno.

### 3. Resultados e Discussão

Duas fdpa para eventos extremos máximos apresentaram-se superiores as demais, sendo essas a Log-Normal 3 e Log-Normal 2, com erro padrão médio respectivos de 19,73 e 22,28. Devido à baixa amostragem dos dados priorizou-se a contemplação espacial do fenômeno em detrimento de outros critérios, assim, optou-se pela adoção da fdpa que conciliasse maior estabilidade espacial com melhor ajuste para os pontos amostrados e menor erro, a qual se destacou a fdp Log-Normal 2 que tem como parâmetros a média e o desvio padrão.

Tabela 1 – Estatísticas descritivas básicas do erro padrão das funções densidade de probabilidade (fdp) de eventos extremos máximos.

	<b>Média</b>	<b>Desvio Padrão</b>	<b>Coef. Variação (%)</b>	<b>Máximo</b>	<b>Mínimo</b>
<b>Gumbel</b>	27,64	10,76	38,94	64,05	9,87
<b>Pearson3</b>	26,91	27,30	101,45	176,09	3,99
<b>LogPearson3</b>	29,88	17,89	59,88	92,78	7,96
<b>LogNormal2</b>	22,28	11,86	53,23	70,14	5,88
<b>LogNormal3</b>	19,73	8,77	44,45	51,45	7,39

Os modelos de semivariograma que melhor se ajustaram na krigeagem ordinária foram o circular para a média e esférico para o desvio padrão. A análise de anisotropia não apresentou melhoras para qualquer um dos ajustes. Melhores resultados foram obtidos para a KO da média sob a transformação logatítima. Já para a KI o melhor ajuste para o semivariograma da mediana foi obtido com o modelo K-Bessel sob efeito de suavização com fator 0,1 (Tabela 2).

A validação dos modelo adotados foi fundamentada em estatísticas de erro de previsão por validação cruzada. As previsões centradas nos valores verdadeiros são indicativas de imparcialidade, dessa forma o erro médio de previsão deve ser próximo de zero, porém, por este depender da escala dos dados, os erros de previsão foram submetidos à padronização, dividindo-os por seus erros padrão de previsão, da qual a média também deve ser próxima de zero. O Erro Médio Padronizado foi respectivamente de 0,002, -0,004 e 0,006 para a média, desvio padrão e mediana dos dados. Baseando-se em uma média livre de influências escalares, esses indicadores apresentaram resultado satisfatório e com imparcialidade das previsões.

A validação do erro padrão de previsão foi obtida por análise da variabilidade da previsão dos dados verdadeiros. Para tanto, uma adequada estimação requer que o Erro Médio Padrão deva apresentar valores próximos à Raiz do Quadrado Médio do Erro. Apesar da imprecisão da estimativa, dos valores para a RMS o Erro Padrão Médio, a semelhança entre estes valores, ocorrido para os três ajustes, é indicativa da avaliação correta da variabilidade e exatidão das predições. Dividindo-se o erro de previsão pelo erro padrão de previsão, para obtenção da RMS Padronizado, obteve-se o valor próximo a 1 para todos as estimativas, com melhor resultado obtido para a KO do desvio padrão. Tal resultado corrobora com a validação do modelo ajustado, por apresentar-se ligeiramente superior a 1 o ajuste da KI da mediana foi

considerado indicativo de subestimativa da previsão e o inverso foi observado para a KO da média. Para a KO da média, essa análise também pode ser observada ao considerar o intercepto e o coeficiente angular, com respectivos valores de 54,666 e 0,367.

Tabela 2 – Parâmetros do semivariograma e suas medidas de desempenho, para KO e KI.

<b>Parâmetros</b>	<b>KO Média</b>	<b>KO Desvio Padrão</b>	<b>KI Mediana</b>
<b>Parâmetros do Semivariograma</b>			
Modelo	Circular	Esférico	K-Bessel
Transformação	Logarítmica	-	-
Efeito Pepita	0,013	89,344	0,082
Patamar	0,028	166,106	0,277
Alcance (km)	149,761	170,521	188,247
Tamanho do <i>Lag</i> (km)	18,814	18,955	23,534
Número de <i>Lag</i>	11	12	12
Análise de anisotropia	Sem melhoras	Sem melhoras	Sem melhoras
<b>Parâmetros de Vizinhaça de Pesquisa</b>			
Tipo de vizinhaça	Padrão	Padrão	Suavizado
Máximo de vizinhos	5	5	5
Mínimo de vizinhos	2	2	2
Tipo de Setor	4 setores, 45° de <i>offset</i>	4 setores, 45° de <i>offset</i>	4 setores, 45° de <i>offset</i>
Fator de anisotropia	1	1	1
<b>Medidas de Desempenho</b>			
$\beta_0$	54,666	23,621	-
$\beta_1$	0,367	0,203	-
Erro médio - EM	-0,031	-0,065	-0,0007
RMS	10,484	10,857	0,643
EM padronizado	0,002	-0,004	0,006
RMS padronizado	0,896	1,013	1,410
Erro padrão médio	11,625	10,668	0,460

As análises da magnitude da dependências espaciais são representadas pelos semivariogramas da Krigeagem Ordinária e Indicadora do conjunto amostral de séries de precipitação máxima para a rede de estações de monitoramento de precipitação para o estado do Espírito Santo e áreas adjacentes. As Figuras 2 a 4 ilustram os semivariogramas dos parâmetros da fdp de eventos extremos, ou seja, da média e do desvio padrão e do teor de corte na mediana do conjunto amostral de dados.

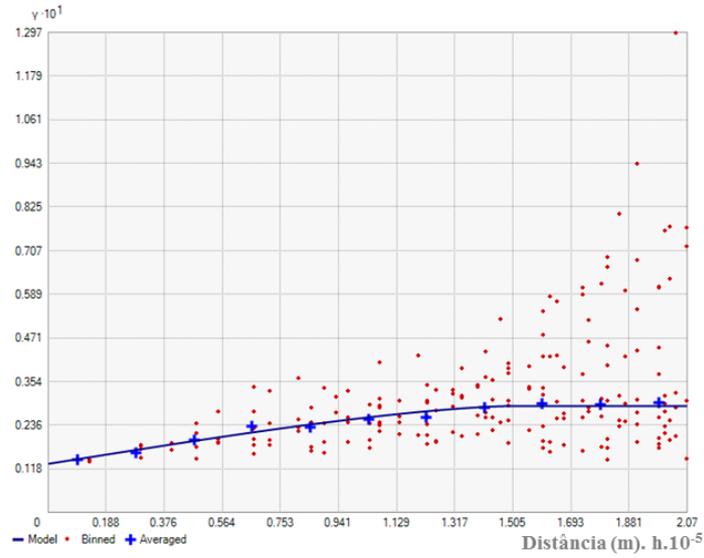


Figura 2 – Semivariograma da média de precipitação extrema por KO.

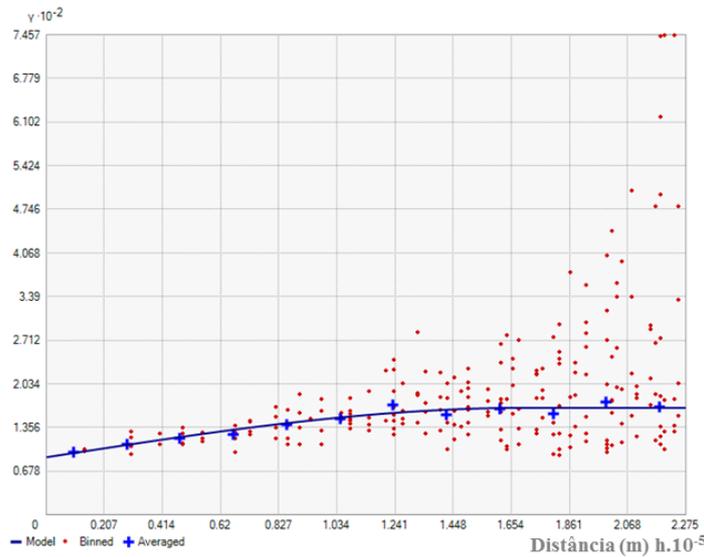


Figura 3 – Semivariograma do desvio padrão de precipitação extrema por KO.

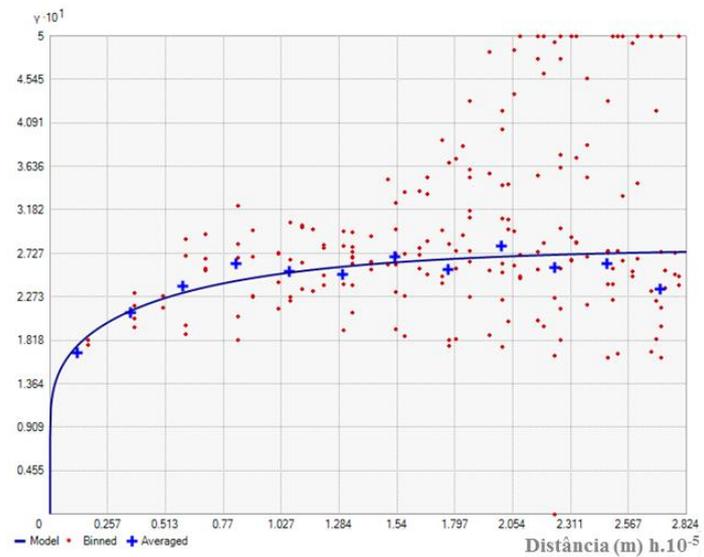


Figura 4 – Semivariograma da mediana de precipitação extrema por KI.

Pela figura 5 pode-se observar o conjunto de mapas de probabilidade de ocorrência dos valores de precipitação máxima média para nove teores de cortes, definidos pelos percentis do conjunto dos dados amostrais. Devido ao gradiente explicitado entre os mapas é possível deduzir que o fenômeno estudado é dominado predominantemente por efeitos orográficos e de continentalidade.

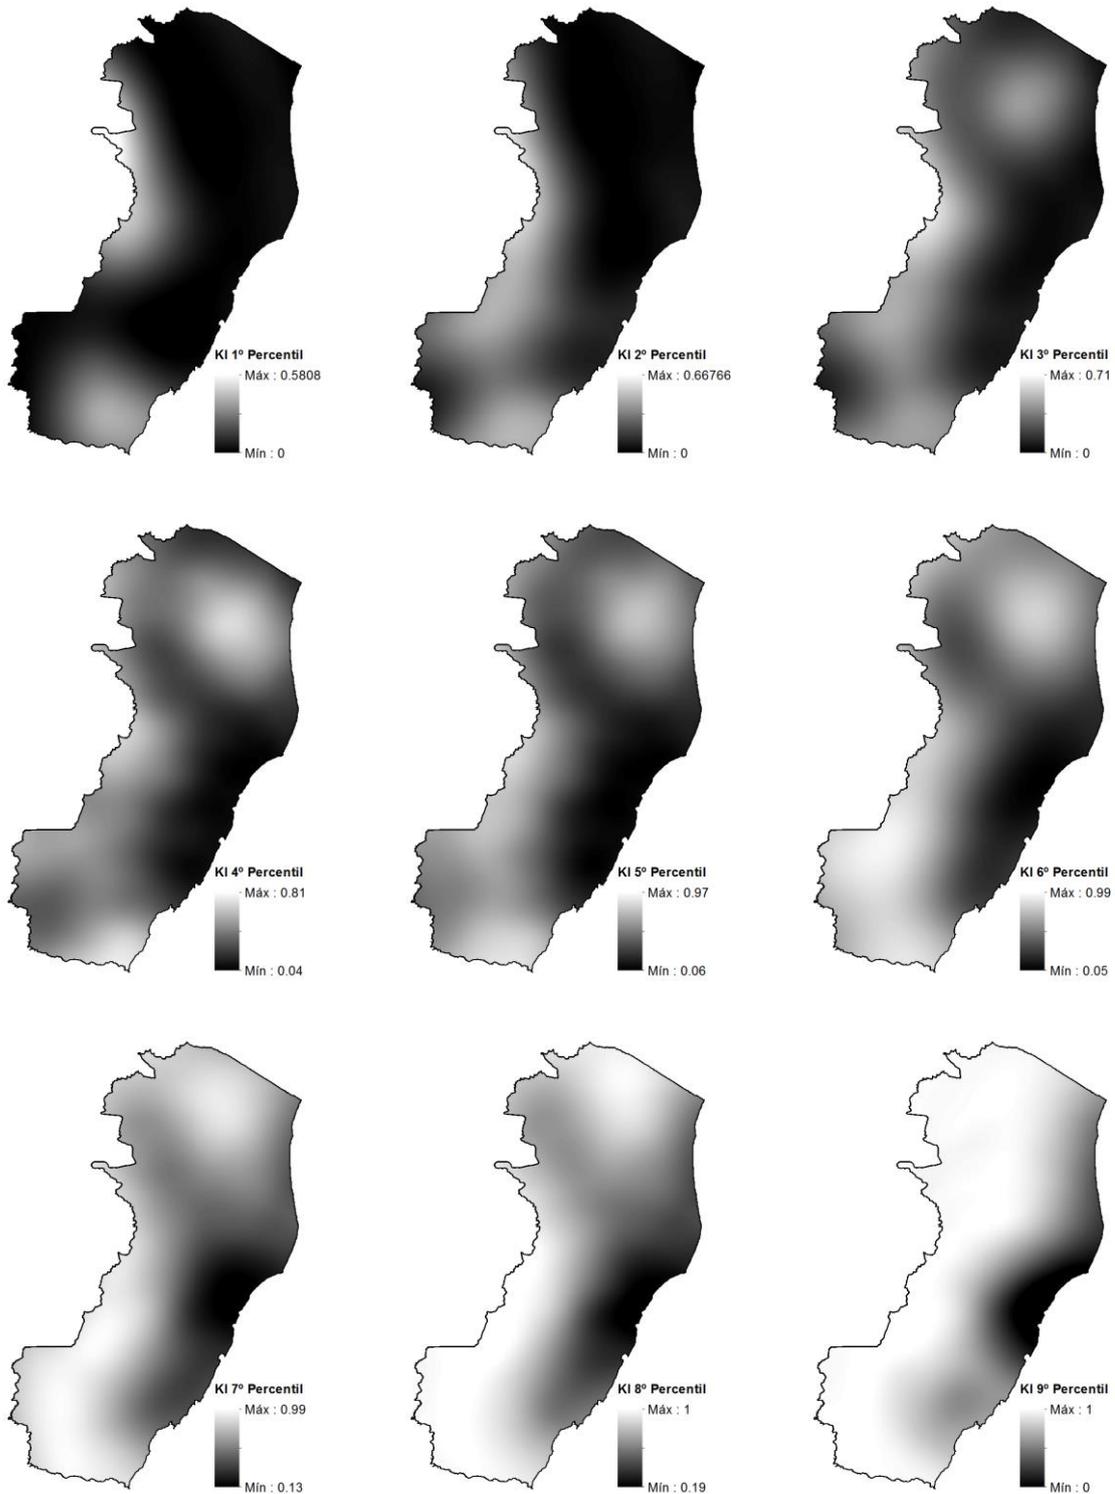


Figura 5 – Mapas de probabilidade calculados pela KI da mediana em nove teores de corte, definidos pelos percentis do conjunto amostral.

Observa-se que os maiores extremos de precipitação máxima média ocorrem do centro-leste ao centro-oeste do estado, com valores médio na faixa longitudinal central do estado (Figura 6). Duas zonas centrais no norte e sul do estado destacam-se por efeitos topoclimáticos. No norte do estado a mancha apresenta-se com valores médios superiores ao da região sul, o que pode ser explicado pela posição topográfica, com amplitude de altitude variando em até 2.000 m. O comportamento do desvio padrão seguiu a mesma tendência observada no mapa de precipitação máxima média.

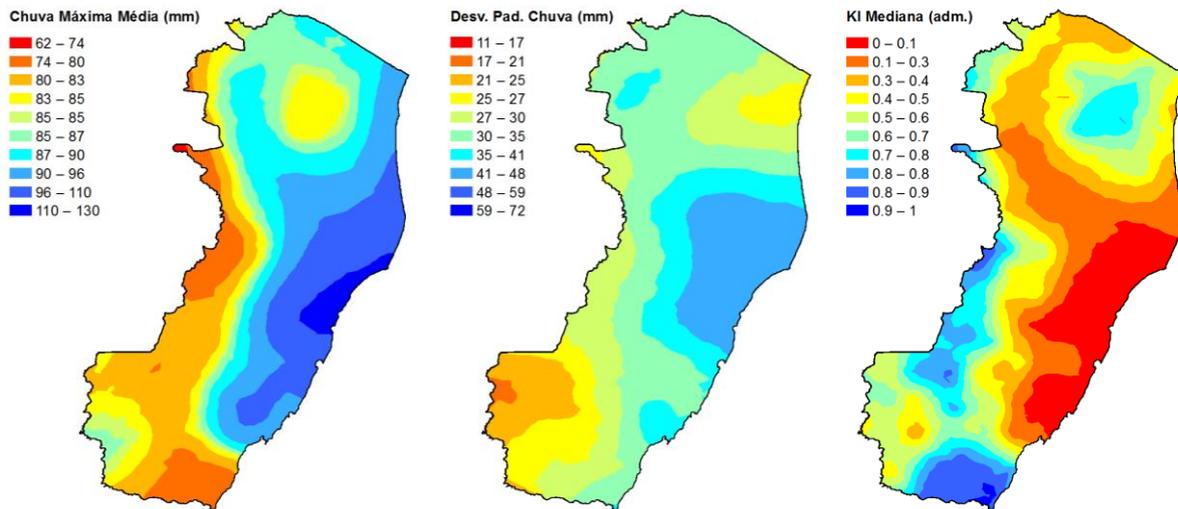


Figura 6 – Mapas da média e desvio padrão condicional especializados por KO e da mediana por KI.

A espacialização da precipitação, seja considerando todos seus valores ou seus extremos, é influenciada fortemente pelos fenômenos ligados as mudanças climáticas, bem como: o El Niño e La Niña, ocorrência de frentes frias, o gradiente térmico entre o mar, o continente e o relevo, entre outros (Mello e Silva, 2009). Este gradiente pode ser um dos mais relevantes fenômenos no Estado do Espírito Santo. Segundo Carvalho e Assad (2005), os valores de precipitação mais elevados no litoral são concordantes ao relevo devido a presença de serras e as vertentes a barlavento, que ficam expostas aos ventos úmidos. Portanto, o relevo apresenta-se como importante fator na formação das chuvas orográficas (Carvalho et al., 2012).

Na Figura 7, observa-se a pronunciada influência da topografia promovendo a distinção entre as partes leste e oeste do estado seccionando-o longitudinalmente. Percebe-se também possível efeito de maritimidade na região litorânea central a oeste do estado caracterizado como os eventos de precipitação de maior intensidade para todos os *ts* considerados.

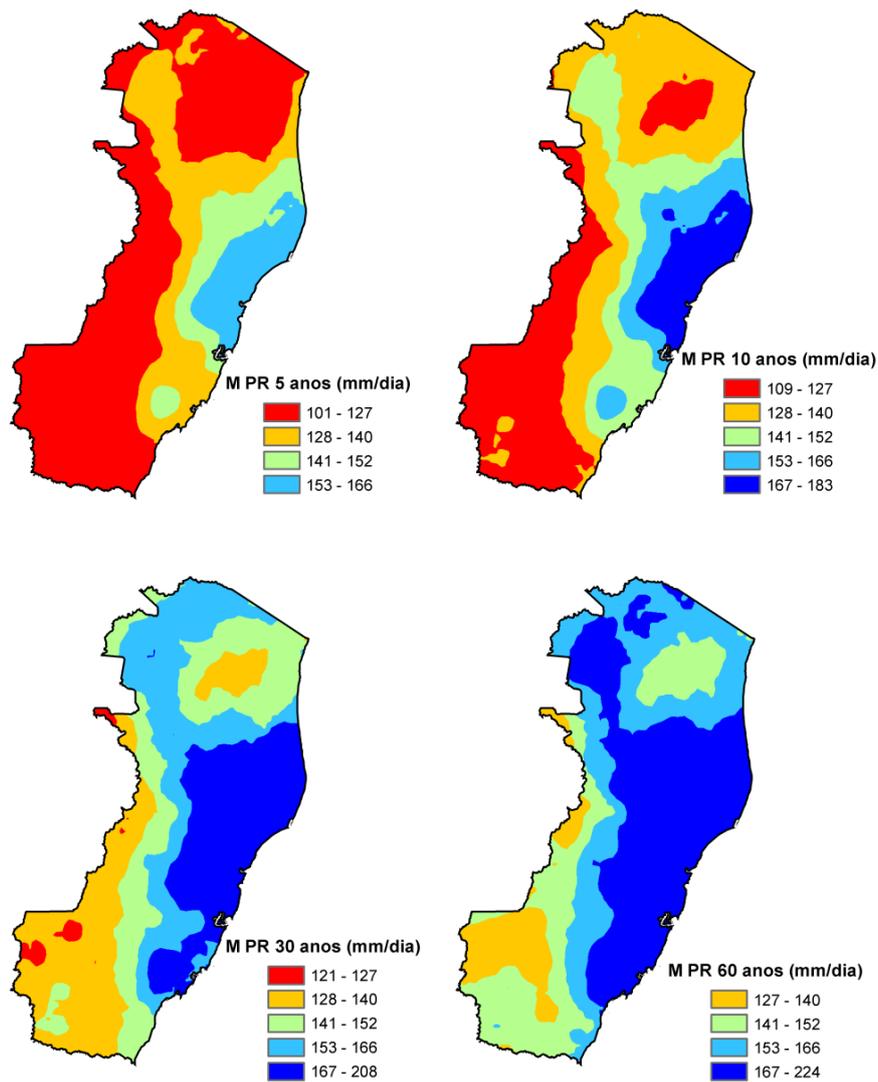


Figura 7 - Magnitude para os eventos de precipitação máxima nos períodos de retorno de 5, 10, 30 e 60 anos.

É relevante ressaltar a importância da identificação das incertezas associadas aos dados analisados. Pelos critérios adotados foi possível garantir que os mapas de incerteza se mantivessem fixo no tempo, ou seja, para qualquer período de retorno definido haverá a mesma incerteza local para os dados (Figura 8). O mapa de incerteza obtido pelo CV (%) tende a favorecer a consideração espacial desse efeito de forma prática para tomada de decisões, uma vez que a adoção de mais de um mapa para isso pode dificultar consideravelmente a análise.

Além da aplicação convencionalmente realizada sobre o uso do mapa de incerteza, para o presente caso, o mesmo pôde ser adotado como referência para indicação da alocação de estações meteorológicas visando adensamento da rede de estações meteorológicas e redução da incerteza dos dados pelo detalhamento da variabilidade local do fenômeno.

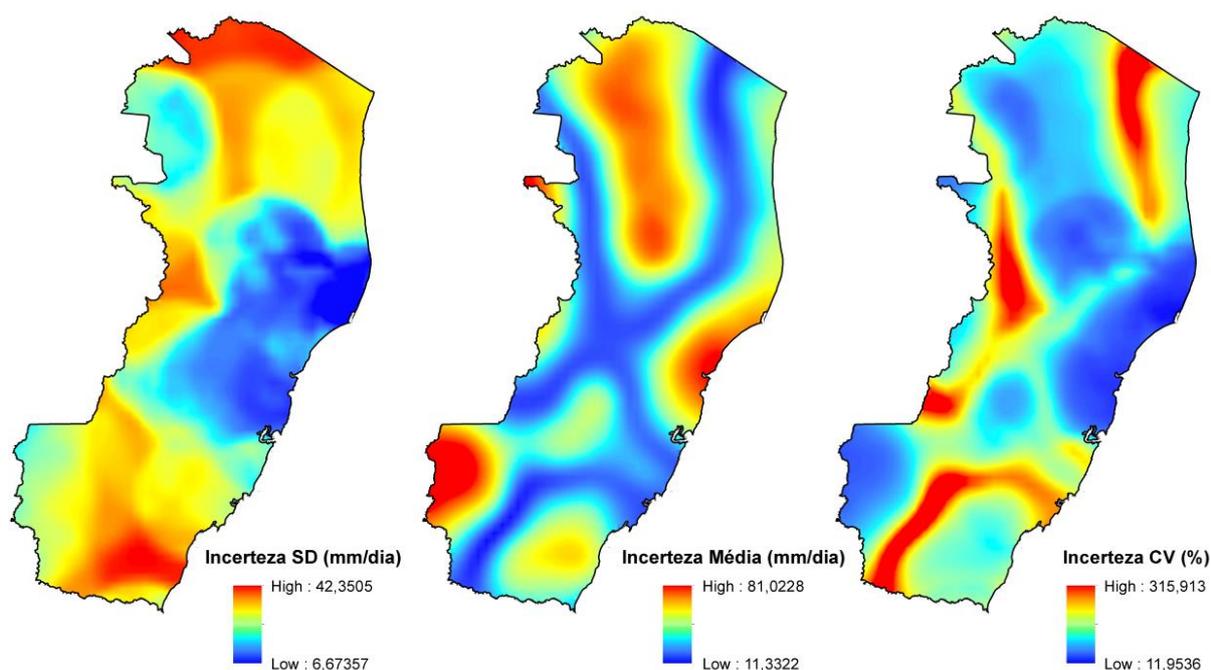


Figura 8 – Mapas de incerteza do desvio padrão, média, e CV (%), da esquerda para a direita.

#### 4. Conclusões

A espacialização dos parâmetros de uma fdp mostrou-se mais adequada para obtenção da estimativa da magnitude da precipitação máxima, quando comparada à espacialização do fenômeno para cada período de retorno individualmente, já que adotando-se álgebra de mapas a única variável de variação temporal da fdp passou a ser o próprio período de retorno, mantendo-se fixo no espaço e tempo os demais parâmetros.

A metodologia apresentada nesse trabalho pode ser considerada mais adequada quando se deseja realizar a análise da magnitude do fenômeno no tempo com suporte da análise da incerteza, quando comparada com o método convencional, ao qual se obteria um mapa de incerteza para cada período de retorno adotado, tornando complexa a tomada de decisões.

O CV mostrou-se como uma medida de incerteza eficaz para a redução do número de mapas de incerteza dos parâmetros da fdp de eventos extremos.

#### Referências Bibliográficas

Caldeira, T. L.; Beskow, S.; Mello, C. R. ; Faria, L. C.; Souza, M. R.; Guedes, H. A. S. Modelagem probabilística de eventos de precipitação extrema no estado do Rio Grande do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.19, n.3, p.197–203, 2015.

Camargo, E. C. G. **Distribuição espacial do risco associado a eventos raros por geostatística binomial e simulação condicionada**. 2007. 148 p. (INPE-14800-TDI/1243). Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

Carvalho, J. R. P. de; Assad, E. D. Análise espacial da precipitação pluviométrica no Estado de São Paulo: comparação de métodos de interpolação. **Engenharia Agrícola**, v.25, p.377- 384, 2005.

Carvalho, J. R. P. de; Assad, E. D.; Pinto, H. S. Interpoladores geoestatísticos na análise da distribuição espacial da precipitação anual e de sua relação com altitude. **Pesquisa Agropecuária Brasileira**, v.47, p.1235- 1242, 2012.

Cunha, A. de M. et al. Espacialização da precipitação pluvial por meio de krigagem e cokrigagem. **Pesquisa Agropecuária Brasileira**, v. 48, n. 9, p. 1179-1191, 2013.

Deutsch e Journel (1992). **GSLIB: Geostatistical Software Library and user's guide**. New York, Oxford University Press, 1992. 339p.

Druck, S.; Carvalho, M. S.; Câmara, G.; Monteiro, A. V. M. (eds). **Análise Espacial de Dados Geográficos**. Brasília, EMBRAPA, 2004.

Hohn, M. E. **Geostatistics and petroleum geology**. Kluwer Academic Publishers, 1988.

Journel, A. G. The indicator approach to estimation of spatial data. **Proceedings of the 17th APCOM**, p. 793-806, New York: Port City Press, 1982.

Journel, A. G. Nonparametric estimation of spatial distributions. **Mathematical Geology**, v. 15, p. 445-468, 1983.

Kite, G. W. **Frequency and risk analyses in hydrology**. 5. ed. Highlands Ranch, Colorado: Water Resources Publications.1988. 257p.

Marengo, J. A . Future Change of Climate in South America in the Late 21st Century: the CREAS Project. **AGU AS Newsletter**, v. 3, n. 2, p. 5, 2009.

Mello, C. R. de; Silva, A. M. da. 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, p.68- 74, 2009.

Richards, J.A. **Remote sensing digital image analysis: an introduction**. Springer Verlag, New York.

1986. 281p.

Yamamoto, J. K.; Lamdim, P. M, B. **Geoestatística: Conceitos e Aplicações**. São Paulo: Oficina de Textos. 2009. 215p.

Yamamoto, J. K.; Furuie, R. A. Um estudo sobre estimativa de dados lognormais. **Geociências/Unesp**, v. 29, n. 1, p. 5-19, 2010.