

Homogeneidade espaçotemporal e modelos de distribuição para a precipitação pluvial no estado de São Paulo

Thomas Newton Martin^{1*}
Durval Dourado Neto²
Pedro Abel Vieira Junior³
Paulo Augusto Manfron⁴

RESUMO

O estudo do comportamento das variáveis do clima faz-se necessário para o planejamento das atividades agrícolas de uma determinada região. Dessa forma, o objetivo deste estudo foi avaliar o ajuste de cinco funções de densidade de probabilidade, além de determinar a variabilidade espacial e temporal utilizando-se dados diários de precipitação pluvial de 18 locais do Estado de São Paulo (Brasil). Aplicou-se o teste de Kolmogorov-Smirnov para testar o ajuste de cinco funções de densidade de probabilidade (normal, log-normal, exponencial, gama e weibull). A variabilidade temporal e espacial foi estudada pela análise de agrupamento, para identificação das regiões homogêneas e meses homogêneos. Utilizou-se o método hierárquico aglomerativo de Ward, onde a medida de dissimilaridade foi a distância euclidiana. Verificou-se que as distribuições que melhor se ajustaram aos dados foram a log-normal e a weibull e também que há uma variação sazonal da precipitação pluvial com três períodos definidos como seco, de transição e úmido.

Palavras-chave: Chuva, série histórica, variabilidade espacial e temporal.

ABSTRACT

Distribution models and spatial-temporal homogeneity for the pluvial precipitation in the State of São Paulo, Brazil

The study of climate variables is fundamental when planning agricultural activities for a region. The objective of this work was to evaluate the fitting of five probability density functions, as well as the spatial and temporal variability of daily pluvial precipitation, using data from 18 locations in the State of São Paulo, Brazil. The Kolmogorov-Smirnov test was used as a goodness-of-fit criterium to the adjustment of five probability density functions (normal, log-normal, exponential, gamma and Weibull). Spatial-temporal variability was studied by cluster analysis, in order to identify homogeneous regions and also months. We applied the agglomerative hierarchical method of Ward with the Euclidean distance. Analysis results showed log-normal and Weibull with best fit and also that seasonal variation of the pluvial precipitation in São Paulo State presents three well defined periods: dry, transition and humid.

Key words: rain, historical series, spatial and temporal variability.

Recebido para publicação em outubro de 2007 e aprovado em setembro de 2008

¹ Universidade Tecnológica Federal do Paraná, Campus Dois Vizinhos (UTFPR), Estrada para Boa Esperança, km 4, Dois Vizinhos, Paraná, Brasil, 85660-000, Cx. P. 157. E-mail: thomas.martin@hotmail.com, Autor para correspondência.

² ESALQ/USP. Departamento de Produção Vegetal, Cx. P. 9, 13418-900, Piracicaba, SP. dourado@esalq.usp.br. Bolsista CNPq.

³ ESALQ/USP. Doutorando em Fitotecnia. Programa de Pós-Graduação em Produção Vegetal Embrapa SNT EN Sete Lagoas, Cx. P. 151, 35900-470, Sete Lagoas, MG, pavieira@cnpmc.embrapa.br

⁴ Universidade Federal de Santa Maria. Departamento de Fitotecnia. Bolsista CNPq.

INTRODUÇÃO

O entendimento do comportamento da precipitação pluvial em uma macro região é necessário para o correto planejamento e desenvolvimento das atividades agrícolas regionais. Os fatores do clima mais estudados para avaliar a viabilidade e a época de implantação das mais diversas atividades agrícolas são a temperatura, a radiação solar e a precipitação pluvial (Fancelli & Dourado Neto, 2003). O planejamento regional, quanto à precipitação, pode ser realizado em diferentes formas, quando da disponibilidade de dados climáticos. Porém, devido à extensão regional, diversidade da distribuição espaço temporal da precipitação pluviométrica, escassez de estações climatológicas, necessidade de séries longas de dados climáticos e acesso a base de dados, deve-se utilizar técnicas que superem essas dificuldades e minimizem os erros.

A simulação de dados climáticos para regiões consideradas homogêneas é uma alternativa para se realizar tais estudos. Entretanto, para realizar simulações é preciso conhecer o comportamento da variável climática durante uma determinada série histórica, estimativas dos parâmetros da distribuição, tais como a média, a variância e a moda, os quais são utilizados para se verificar a adequabilidade dos dados a modelos de distribuições de probabilidade conhecidos, tais como: normal, log-normal, exponencial, gama e weibull. Dessa forma, torna-se possível simular, aleatoriamente, dados com a mesma distribuição de probabilidade. A simulação estocástica de dados foi aplicada para dados de temperatura e radiação solar por Dourado Neto *et al.* (2005) e Assis *et al.* (2006) e outros estudos já foram reali-

zados para a precipitação pluvial (Catalunha *et al.*, 2002; Dourado Neto *et al.*, 2005; Lyra *et al.*, 2006), radiação solar (Dourado Neto *et al.*, 2005), e temperatura (Assis, *et al.*, 2004; Dourado Neto *et al.*, 2005).

A determinação de regiões homogêneas significa a subdivisão de uma região maior (Estados) em áreas menores, que possuam as mesmas características quanto às variáveis climáticas em estudo. Pode-se, por exemplo, utilizar a análise de agrupamento para se estudar a similaridade ou a dissimilaridade entre indivíduos. Portanto, para que isso ocorra, se faz necessário a aplicação de uma classificadas como pertencentes à mesma classe ou grupo ou cluster, serão as mais similares entre si, segundo o critério definido pelo método e pelas variáveis consideradas (Everitt & Dunn, 1991). Utilizando-se dessa metodologia, Diniz *et al.* (2003), identificaram as regiões homogêneas quanto às temperaturas máximas e mínimas no Rio Grande do Sul, Brasil, e Lyra *et al.* (2006) determinaram as regiões homogêneas quanto à precipitação pluvial em Táchira (Venezuela).

De acordo com o exposto o objetivo desse estudo foi avaliar o ajuste de cinco funções de densidade de probabilidade, além de determinar a variabilidade espacial e temporal utilizando-se dados diários de precipitação pluvial para o Estado de São Paulo (Brasil).

MATERIAL E MÉTODOS

Os dados utilizados nesse trabalho foram às médias diárias da precipitação pluvial (mm) de 18 locais do Estado de São Paulo (Tabela 1). Utilizou-se o teste de

Tabela 1. Relação das estações convencionais de coleta de dados, latitude (Lat, dec), longitude (Lon, dec), altitude (Alt, m), ano inicial e final de coleta dos dados da variável chuva, para o Estado de São Paulo.

Local	Lat	Lon	Alt	Chuva		Fonte
				Inicial	Final	
Adamantina (SP)	-21,6833	-51,0083	443	1982	2002	IAC
Campinas (SP)	-22,9000	-47,0008	674	1890	2004	IAC
Capão Bonito (SP)	-24,0033	-48,3666	702	1946	2002	IAC
Gália (SP)	-22,3000	-49,5500	522	1979	2002	IAC
Itararé (SP)	-24,2500	-49,2500	1150	1974	2002	IAC
Jaú (SP)	-22,2833	-48,5666	580	1955	2002	IAC
Jundiá (SP)	-23,2000	-46,8833	715	1941	2003	IAC
Limeira (SP)	-22,5333	-47,4500	639	1970	2003	IAC
Mococa (SP)	-21,4666	-47,0016	665	1959	2001	IAC
Monte Alegre do Sul (SP)	-22,6833	-46,7166	777	1981	2000	IAC
Pariquera-Açú (SP)	-24,7166	-47,8833	25	1980	2000	IAC
Pindamonhangaba (SP)	-22,9166	-45,4500	560	1991	2002	IAC
Pindorama (SP)	-21,2166	-48,9333	562	1951	2000	IAC
Piracicaba (SP)	-22,2166	-48,9333	546	1917	2005	ESALQ
Ribeirão Preto (SP)	-21,1833	-47,8000	621	1939	2003	IAC
Tatuf (SP)	-23,3333	-47,8666	600	1988	2000	IAC
Tietê (SP)	-23,0116	-47,7166	538	1987	2000	IAC
Ubatuba (SP)	-23,4500	-45,0066	8	1984	2002	IAC

Kolmogorov-Smirnov a 5% de probabilidade de erro apresentado por Campos (1983). Esse teste foi escolhido por ser o mais versátil sem a perda de informações importantes para a obtenção dos objetivos propostos. Desenvolveu-se um algoritmo por meio do Microsoft Excel® que utilizou as funções de estimação dos parâmetros apresentada por Abramowitz & Stegun (1972). Dessa forma, foram aplicados os testes para cada um dos dias Julianos, por exemplo, para o dia 1º de janeiro, existem no máximo 115 valores para Campinas, sendo esse o conjunto de dados, dessa forma, serão 366 dias do ano (variando o número de elementos dentro de cada local) multiplicado por 18 locais (cada um com uma série histórica diferente). Sendo apresentado na Tabela 2.

Dentre as diversas distribuições de probabilidades a distribuição normal é a mais importante, sob a ótica do conhecimento agrônomo porque um grande número de fenômenos poderem ser estudados com este modelo. No modelo gama, os parâmetros α e β foram estimados por:

$$12A\alpha^2 - 6\alpha - 1 = 0; \hat{\alpha} = \frac{1}{4A} \left(1 + \sqrt{1 + \frac{4A}{3}} \right); \hat{\beta} = \frac{x}{\hat{\alpha}}$$

$A = \ln(\bar{x}) - \ln(\bar{x}_g); \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i; \bar{x}_g = \frac{1}{n} \sum_{i=1}^n \ln(x_i);$ em que \bar{x} se refere à média aritmética das observações, \bar{x}_g é a média geométrica das observações, x_i ao i-ésimo valor diário da variável e n é o número de observações. Abramowitz & Stegun (1972) definem o polinômio para o cálculo da função gama, para um intervalo de $1 \leq \alpha \leq 2$, da seguinte forma:

$$\Gamma(\alpha) = 1 + a_1x + a_2x^2 + a_3x^3 + a_4x^4 + a_5x^5 + a_6x^6 + a_7x^7 + a_8x^8$$

em que $x = \alpha - 1, a_1 = -0,577191652, a_2 = 0,988205891, a_3 = -0,897056937, a_4 = 0,918206857, a_5 = -0,756704078, a_6 = 0,482199394, a_7 = -0,193527818$ e $a_8 = 0,035868343$. Segundo os mesmos autores, no caso de $\alpha > 2$, o polinômio aproximador para o cálculo da função gama é estimado por:

$$\Gamma(\alpha) = \Gamma(n + N) = \Gamma(n + 1) \prod_{k=1}^{N-1} (n + N - k), \text{ em que } n \text{ é a parte fracionária de } \alpha; N \text{ a parte inteira de } \alpha, \text{ sendo } N \leq 2; k = 1, 2, 3, \dots, N.$$

Os parâmetros α e β do modelo Weibull foram estimados por: $RM = \frac{k_i - 0,3}{\sum k_n + 0,4}$ onde k_i é o número de ordem da variável (chuva) e k_n é o último número de ordem das variáveis. Podendo-se estimar os parâmetros de forma (β) e de escala (α) por:

$$\beta = \frac{\sum_{i=1}^n x_i y_i - \frac{\sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n}}{\sum_{i=1}^n x_i^2 - \frac{\left(\sum_{i=1}^n x_i\right)^2}{n}}$$

$$; a = y - \beta \cdot x; \alpha = \exp \frac{-a}{\beta}$$

Os dados foram analisados individualmente em cada dia do calendário Juliano (1 de janeiro a 31 de dezembro, totalizando 366 dias), segundo os anos observados e cada um dos 18 locais, sendo ajustadas 6.588 (366 dias/ano x 18 locais) distribuições em cada distribuição. Foram considerados, para fins de ajustes nas

Tabela 2. Freqüências máximas (Max), mínimas (Min), médias (Med) e números totais de dias do ano que aderiram às distribuições de densidade de probabilidade normal (N), exponencial (E), log-normal (LN), gama (G) e weibull (W), pelo teste de Kolmogorov-Smirnov a 5% de probabilidade de erro.

Precipitação Pluvial														
Distr.		Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Total
N	Max	31	29	31	30	31	30	31	31	30	31	30	31	6060
	Min	10	10	17	22	20	13	10	7	26	25	19	17	
	Med	28	27	29	28	30	27	25	26	29	30	28	29	
E	Max	31	27	29	27	29	27	27	30	30	30	28	31	5116
	Min	21	18	19	17	12	10	8	6	17	22	20	17	
	Med	26	23	25	23	23	21	20	22	25	26	24	27	
LN	Max	31	29	31	30	31	30	31	31	30	31	30	31	6229
	Min	30	27	30	22	20	13	9	7	26	28	28	29	
	Med	31	29	31	28	30	27	24	26	30	31	30	31	
G	Max	31	29	31	30	31	30	30	31	30	31	30	31	5922
	Min	29	25	28	16	14	6	7	5	21	25	23	29	
	Med	31	28	30	26	28	25	22	23	28	30	28	31	
W	Max	31	29	31	30	31	30	31	31	30	31	30	31	6233
	Min	30	27	30	22	20	13	10	7	26	28	28	29	
	Med	31	29	31	28	30	27	25	26	30	31	30	31	

distribuições de probabilidade, apenas os dias em que a precipitação pluvial diária foi superior ou igual a 0,1 mm. Para a identificação das regiões homogêneas e meses homogêneos, quanto à precipitação pluvial, utilizou-se a análise de agrupamento (Cluster Analysis). Utilizou-se o método hierárquico aglomerativo de Ward (1963), devido a esse basear-se no agrupamento pela variância mínima onde o enfoque é sobre a variabilidade que existe dentro de cada caso e os agrupamentos são efetuados ao se determinar que pares de casos, quando tomados em conjunto, apresentam o menor acréscimo de variabilidade (Landin, 2000), onde a medida de dissimilaridade foi a distância euclidiana (Everitt & Dunn, 1991), definida pela seguinte equação:

$$d_e = \left[\sum_{j=1}^n (P_{p,j} - P_{k,j})^2 \right]^{0.5}, \text{ onde } d_e \text{ é a distância euclidiana; } P_{p,j} \text{ e } P_{k,j} \text{ são as variáveis quantitativas } j \text{ (precipitação pluviométrica) dos locais ou das localidades } p \text{ e } k, \text{ respectivamente.}$$

Os dados de precipitação pluvial mensais foram organizados em uma matriz $P_{n \times p}$, em que o elemento P_{ij} representava o valor da i -ésima variável (localidade) do i -ésimo indivíduo (mês). Então, cada vetor coluna representava um mês, enquanto cada vetor linha representava uma localidade. O teste também foi aplicado de forma inversa, de modo a determinar, dentro de cada um dos períodos, as regiões homogêneas ou com similaridade de precipitação pluvial.

RESULTADOS E DISCUSSÃO

A partir dos resultados da Tabela 2 (resumo do número máximo, mínimo e média de aderências de cada mês nos 18 diferentes locais), verifica-se que, para a variável precipitação pluvial, as distribuições de probabilidades que melhor aderiram aos dados foram à distribuição weibull (94,61%), a log-normal (94,55%), a normal (91,99%), gama (89,89%) e exponencial (77,66%). Verifica-se que o número de aderências às distribuições de probabilidade possui uma redução em todas as densidades de probabilidades avaliadas nos meses de junho, julho e agosto. Por meio da Tabela 3, verifica-se que a menor precipitação mensal ocorre nos meses de junho, julho e agosto, indicando também uma redução na frequência de precipitações em cada mês. Com essa redução de eventos (número de precipitações), existe um menor número de dias avaliados desses meses, além do menor número de aderências de distribuições de probabilidade aos dados (provavelmente pela desproporcionalidade de volume de precipitação em cada dia de chuva). Existe uma redução gradual no número de aderências às distribuições de probabilidade de janeiro até julho e um

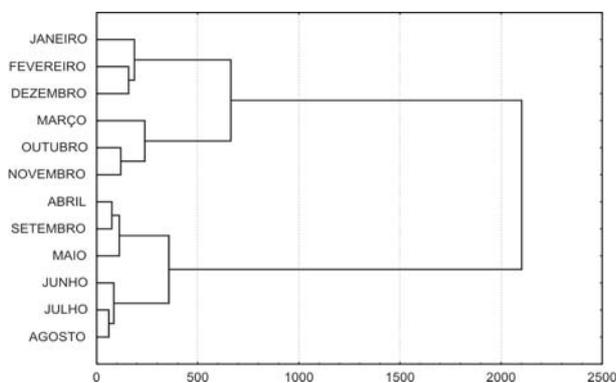
gradual aumento de julho a dezembro (Tabela 2). Os resultados obtidos nesse estudo quando comparados com os resultados obtidos por Dourado Neto *et al.* (2005), que utilizaram o teste de qui-quadrado para os dados de precipitação pluvial diária no município de Piracicaba (SP), verificaram que a distribuição Gama foi a que mais se adequou às estimativas diárias de probabilidade de precipitação pluvial para os meses de janeiro, fevereiro, março, outubro, novembro e dezembro. Lyra *et al.* (2006), obtiveram como melhores ajustes das distribuições de probabilidade para valores de precipitação pluvial diária, no estado de Táchira (Venezuela), para os meses secos, a distribuição exponencial, com exceção da região homogênea, com os maiores valores de precipitação pluvial do período, em que a gama se destaca. Já no período chuvoso, em todas as regiões homogêneas, a distribuição normal predomina, com exceção de agosto em que, novamente, a gama prevalece. Já nos meses de transição, destacam-se as distribuições gama (abril) e normal (novembro).

A Tabela 3 apresenta as precipitações médias mensais para todos os locais avaliados, juntamente com os desvios-padrão. É possível notar que nos meses de junho, julho e agosto, as precipitações ocorrem com menor frequência e com menor intensidade. Isso pode ser verificado na Figura 1, onde o grupo caracterizado como grupo dos meses secos, nos meses de junho, julho e agosto, essa intensidade é maior, contrapondo-se dos meses de abril setembro e maio. Porém, esses últimos ocorrem antes ou depois do período mais seco, e representam uma preparação (diminuição gradual) da intensidade de precipitação. Em contra partida, os meses em que ocorrem as maiores intensidades de precipitação pluvial são os meses de dezembro e janeiro. E, juntamente com o mês de fevereiro, são classificados pelo método de Ward, como o grupo de meses chuvosos (Figura 1). Um correto planejamento de cultivos de sequeiro, deve basear-se nessas informações, pois os cultivos devem coincidir o período de maior exigência hídrica com o período de maior disponibilidade do ambiente. Devido às elevadas variações de precipitação, representadas pelo desvio padrão da Tabela 3, pode-se assumir que existe dificuldade em prever com maiores precisões as prováveis datas de chuva.

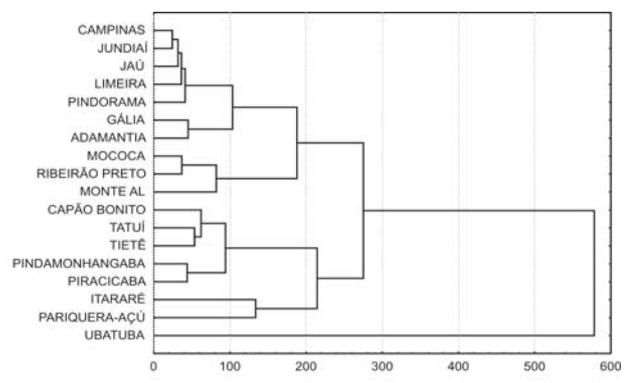
Com isso, os dados da Figura 1 auxiliam na tomada de decisões, pois apresentam a probabilidade de ocorrência de chuva, que é maior que 60% em alguns dias de janeiro para Campinas, por exemplo. E possuem um mínimo de 10 a 15% de probabilidade de ocorrência em meados de julho, tendo em vista essa mesma localidade.

Tabela 3. Estimativas de médias (\hat{m}) e desvios-padrão ($\hat{\sigma}$) para precipitação média mensal (mm), para as estações das cidades avaliadas

	Campinas		Capão Bonito		Gália		Itararé		Jaú		Jundiaí	
	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$
Jan	246,34	99,76	205,62	100,58	248,89	88,49	229,67	129,75	241,93	91,55	235,79	92,00
Fev	201,16	89,24	169,51	77,88	190,32	78,90	190,25	75,45	203,28	103,09	192,57	78,54
Mar	151,42	69,76	137,99	66,78	154,34	65,33	143,82	67,67	149,30	75,28	154,27	71,13
Abr	64,07	44,52	70,64	49,70	88,18	50,42	82,45	45,65	76,15	47,95	70,94	41,87
Mai	59,50	47,48	70,98	64,04	88,05	67,02	117,87	91,81	68,88	56,91	65,08	55,20
Jun	57,63	82,73	67,30	57,69	62,69	60,24	99,96	78,80	54,11	46,95	55,76	54,67
Jul	33,92	36,06	57,86	59,67	21,53	17,75	71,34	50,51	38,89	42,29	43,50	40,00
Ago	38,85	33,40	51,16	34,97	50,22	47,41	64,49	53,73	40,81	43,23	39,69	38,16
Set	68,05	52,72	89,76	56,39	81,52	55,08	126,15	76,04	72,20	47,29	74,88	65,25
Out	119,08	62,95	121,07	72,42	113,88	79,30	142,81	57,93	117,35	59,02	124,81	56,18
Nov	149,16	67,87	99,55	60,10	131,68	54,49	144,47	64,32	144,91	82,70	143,24	67,70
Dez	221,60	97,42	157,75	71,71	186,37	78,49	215,25	86,41	239,93	82,65	210,90	88,78
	Limeira		Mococa		Monte Alegre do Sul		Pariqüera-Açú		Pindamonhangaba		Pindorama	
	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$
Jan	244,67	92,72	259,68	90,51	278,73	126,59	227,87	91,24	205,71	61,79	249,23	99,92
Fev	186,22	106,58	202,64	96,84	205,95	99,09	234,98	109,60	193,52	92,14	214,53	103,95
Mar	170,80	108,24	162,44	79,98	193,59	74,81	246,84	105,85	153,07	51,64	157,14	75,95
Abr	77,32	48,01	86,64	55,35	91,52	42,97	97,14	37,10	53,84	30,96	72,65	54,31
Mai	63,87	54,62	65,28	45,52	88,15	66,06	83,28	61,59	52,41	37,30	61,00	51,64
Jun	55,25	51,30	39,43	34,27	58,11	55,70	89,93	60,13	28,49	24,43	40,15	37,20
Jul	35,65	36,01	25,29	30,59	36,87	33,01	70,07	42,92	18,95	16,49	31,45	30,89
Ago	42,10	37,38	36,31	34,57	40,54	37,96	53,91	39,80	27,48	33,33	31,73	32,29
Set	78,24	51,02	70,25	58,26	94,53	68,03	114,84	62,92	75,25	42,89	64,13	48,26
Out	117,13	65,32	135,35	80,31	143,26	88,32	121,53	58,44	125,87	70,00	112,09	58,44
Nov	160,05	67,46	181,56	76,34	147,84	61,56	128,85	68,57	119,15	57,03	136,90	69,57
Dez	222,66	79,02	273,00	101,95	257,86	91,91	162,19	70,12	196,34	76,00	221,82	93,11
	Piracicaba		Ribeirão Preto		Tatuí		Tietê		Ubatuba		Adamantina	
	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$	\hat{m}	$\hat{\sigma}$
Jan	228,84	87,35	273,54	106,56	222,31	102,05	232,68	87,50	313,28	135,09	246,45	110,90
Fev	183,57	97,74	222,46	100,21	202,57	89,99	177,56	55,57	325,63	234,74	185,52	83,26
Mar	144,01	78,73	168,30	79,12	167,78	90,93	141,49	78,03	325,29	152,18	160,60	100,38
Abr	63,01	47,19	72,69	56,24	69,63	60,76	71,36	29,84	234,55	135,79	78,96	53,00
Mai	56,68	50,88	55,32	46,26	68,83	53,49	67,64	56,70	127,09	83,35	92,84	70,86
Jun	47,00	40,97	34,36	33,81	42,88	26,61	49,64	43,35	92,88	73,85	45,28	55,03
Jul	30,88	32,69	26,89	30,30	47,08	45,38	28,01	28,54	100,23	76,51	31,46	23,46
Ago	33,74	30,15	29,64	32,25	34,35	18,12	22,43	18,31	70,31	40,31	64,14	56,46
Set	62,72	53,11	56,38	50,72	80,67	47,32	78,95	45,02	193,34	62,78	79,96	52,71
Out	110,74	57,92	126,08	60,69	118,81	55,59	95,60	50,56	218,51	100,01	86,03	77,49
Nov	132,67	62,64	172,15	74,48	106,58	70,32	101,95	61,98	234,14	98,90	146,73	75,33
Dez	200,17	76,42	270,72	115,68	169,12	60,61	151,23	66,77	271,19	144,47	202,59	114,84



(A)



(B)

Figura 1. Dendrogramas da dissimilaridade da precipitação pluvial, entre os meses do ano (a) e as 18 localidades (b) do Estado de São Paulo, obtido pelo método de agrupamento de Ward, baseado na distância euclidiana média padronizada.

CONCLUSÕES

Conforme os resultados obtidos, verifica-se que as distribuições que melhor se adaptam aos dados de precipitação pluvial diária são a log-normal e a distribuição de weibull. A variação sazonal da precipitação pluvial no Estado de São Paulo apresenta três períodos definidos como seco, de transição e úmido.

AGRADECIMENTOS

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão da bolsa de Doutorado Sanduíche no Exterior (Forschungszentrum Jülich GmbH, ICG-IV, Jülich, Deutschland). Ao Instituto Agrônomo de Campinas (IAC) e ao Departamento de Ciências Exatas, Escola Superior de Agricultura "Luiz de Queiroz", Piracicaba, São Paulo, pela disponibilização dos dados.

REFERÊNCIAS

- Abramowitz, M. & Stegun, I.A. (1972) Handbook of mathematical functions with formulas, graphs, and mathematical tables. Washington, D.C.: U.S. Government Printing Office, 1046p.
- Assis JP, Dourado Neto D, Manfron PA, Martin TN, Sparovek G & Timm LC (2004) Ajustes de séries históricas de temperatura e radiação solar global diária às funções de densidade de probabilidade normal e log normal em Piracicaba, SP. *Revista Brasileira de Agrometeorologia*, 12:113-121.
- Assis JP, Dourado Neto D, Nass L, Manfron PA, Bonnacarrère RAG & Martin TN (2006) Simulação estocástica de atributos do clima e da produtividade potencial de milho utilizando-se distribuição triangular. *Pesquisa Agropecuária Brasileira*, 41:539-543.
- Campos H *Estatística não paramétrica*. (1983) 4ª ed. Piracicaba: ESALQ/USP, 349 p.
- Catalunha MJ, Sedyama GC, Leal BG, Soares CPB & Ribeiro A Aplicação de cinco funções densidade de probabilidade a séries de precipitação pluvial no Estado de Minas Gerais. *Revista Brasileira de Agrometeorologia*, 10:153-162.
- Diniz GB; Berlato MA; Clarke RT & Fontanna DC (2003) Identificação de regiões homogêneas de temperaturas máxima e mínima do Rio Grande do Sul. *Revista Brasileira de Agrometeorologia*, 11:303-312.
- Dourado Neto D, Assis JP, Timm LC, Manfron PA, Sparovek G & Martin TN (2005) Ajuste de modelos de distribuição densidade de probabilidade a séries históricas de precipitação pluvial diária em Piracicaba-SP. *Revista Brasileira de Agrometeorologia*, 13:273-283.
- Everitt BS & Dunn G (1991) *Applied multivariate analysis*. London: Edward Arnold, 400p.
- Fancelli AL & Dourado Neto D (2003) *Milho: estratégias de manejo para alta produtividade*. Piracicaba: ESALQ/USP/LPV, 208p.
- Landim PMB *Análise estatística de dados geológicos multivariados*. Lab. Geomatemática, DGA, IGCE, UNESP/Rio Claro, Texto Didático 03, 128 pp. 2000. Disponível em <<http://www.rc.unesp.br/igce/aplicada/textodi.html>>. Acesso em: 10/10/2006
- Lyra GB, Garcia BIL, Piedade SMS, Sedyama GC & Sentelhas PC (2006) Regiões homogêneas e funções de distribuição de probabilidade da precipitação pluvial no Estado de Táchira, Venezuela. *Pesquisa Agropecuária Brasileira*, 41:205-215.
- Mirshawska V (1971) *Estatística*, v.2, São Paulo: Nobel, 367p.
- Ward JH (1963) Hierarchical grouping to optimize an objective function. *Journal of American Statistical Association*. 58:236-244.