

Dados topográficos e sua relação com a distribuição espacial da precipitação: estudo em área teste no estado de São Paulo - Brasil

Marcus Andre Fuckner¹
André Luiz Silva Maia¹
Fábio Iwashita¹
Polyanna da Conceição Bispo¹

¹Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12201-970 - São José dos Campos - SP, Brasil
{marcus, maia, polyanna}@dsr.inpe.br, iwashita@dpi.inpe.br

Abstract. The analysis of influential factors as temperature, latitude, vegetation cover and frontal systems action on the frequency, intensity and spatial distribution of the precipitation by specific area had been object of study of researches in the field of Physical Geography. This paper, ahead to a test area in the São Paulo State, use multivariate statistics analysis for build a multiple linear regression model with the objective to explain the precipitation considering topographic variables as a vertical curvature, horizontal curvature, south effect and sea effect, calculate based on SRTM data. The process of variables selection for the model let to conclude that, for the specific cases of the january and july months, representative of summer and winter seasons, respectively, the longitude, latitude, maritimity, altitude, temperature and topographic orientation are influential factors for the precipitation, considering the type of rain more common in each period: orographic, convective or frontal rains. The R^2 coefficients obtained were 0,85 to january and 0,90 to july.

Palavras-chave: precipitation, multiple linear regression, topographic variables, SRTM, precipitação, regressão linear múltipla, variáveis topográficas, SRTM.

1. Introdução

A distribuição espacial dos índices de precipitação pluviométrica pelo território brasileiro é heterogênea. Em determinadas regiões, altos índices podem ser explicados pelas altas temperaturas. Associadas à zona de convergência intertropical, elas permitem o desenvolvimento de exuberantes formações florestais latifoliadas, como é o caso da Floresta Amazônica.

Em outros casos, a atuação constante de sistemas frontais é responsável por elevada precipitação em estações como o inverno, como ocorre em algumas áreas da região sul do Brasil. Outro fator, a maritimidade, também está associada à ocorrência maior de chuvas em áreas litorâneas em relação a áreas mais distantes da costa. Altos índices de precipitação também podem ser explicados pela orientação e pujância das feições do relevo, que favorecem a ocorrência de chuvas orográficas em determinadas áreas.

Dentre os trabalhos que incorporaram dados topográficos para estudar a distribuição das chuvas pode ser citado o de Goovaerts (2000). Este autor obteve coeficientes de correlação (r) variando de 0,33 a 0,83 entre a precipitação para cada mês do ano e a elevação (obtida a partir de um Modelo Digital do Terreno) para 36 estações meteorológicas na região do Algarve, em Portugal. Seus resultados permitiram concluir que a regressão linear não é o melhor método para a interpolação espacial da precipitação, mas sim, outras técnicas de geoestatística, tal como a *co-krigagem*. No entanto, o autor coloca que a inserção de outros dados no modelo, ainda pouco explorados, tais como a distância da costa e a orientação das vertentes, pode levar ao encontro de resultados mais expressivos, assim como a incorporação da análise dos padrões de contigüidade espacial.

No Brasil, trabalhos que aplicaram técnicas de geoprocessamento a partir de informações agroclimatológicas puderam espacializar a distribuição da precipitação pelo Estado de São Paulo (Valeriano e Picini, 2003) e pelo litoral sul fluminense (Soares et al., 2005).

No primeiro trabalho foram utilizados dados de altimetria e distância em relação à costa para o estudo da distribuição das chuvas em todo o Estado de São Paulo. Todavia, os resultados obtidos foram pouco expressivos no que diz respeito ao detalhamento na distribuição das classes de volume da precipitação. Este mesmo trabalho concluiu, para o caso específico de uma área do Estado de São Paulo, sobre a influência da topografia para o volume da precipitação (**figura 1**).

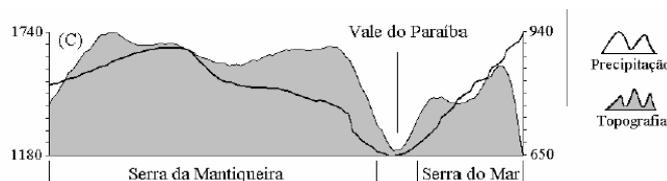


Figura 1: Efeito da topografia sobre a precipitação em transecto.

Fonte: Valeriano e Picini (2003).

Conforme Valeriano e Picini (2003), a variação da precipitação anual acompanha os desníveis altimétricos, sendo, portanto, a altitude influente na distribuição da precipitação. Entretanto, os valores absolutos não são correlacionados na totalidade dos dados, acompanhando apenas grandes feições orográficas. Outra informação de interesse apresentada por Valeriano e Picini (op. cit.) é o aumento do nível pluviométrico apresentado na zona costeira, sendo a proximidade da costa, portanto, outro fator influente.

No trabalho de Soares et al. (2005) foi observado que a disposição do relevo influencia marcadamente a distribuição das chuvas, sendo os locais a barlavento (voltados para a costa) e próximos ao litoral aqueles que apresentam os maiores índices, cuja diminuição ocorre a sotavento e conforme aumenta a distância do litoral.

Diante da provável influência de fatores ligados ao relevo na distribuição espacial das chuvas pelo Estado de São Paulo, este trabalho tem como objetivo avaliar, a partir de análise estatística multivariada, a relevância da inclusão de variáveis topográficas no modelo de distribuição pluviométrica, visando enriquecer seu estudo em uma região específica.

2. Procedimentos Metodológicos

As variáveis propostas para inclusão no modelo de distribuição pluviométrica, com as respectivas unidades, são: coordenadas geográficas – latitude e longitude – do local de coleta, altitude (m), declividade (%), curvatura vertical (graus/metro), curvatura horizontal (graus/metro), efeito sul, efeito mar, distância da costa (km) e temperatura (°C).

Cada variável em particular pode ser descrita da seguinte forma: **altitude:** elevação medida em relação ao nível do mar; **declividade:** obtida combinando-se a distância entre as curvas de nível adjacentes a um dado ponto amostral (distância horizontal), a escala do mapa e a equidistância entre as curvas de nível (distância vertical); **curvatura vertical:** conforme Valeriano (2003), a curvatura vertical é um dado que se refere ao caráter convexo/côncavo do terreno, analisado em perfil (**figura 2**); **curvatura horizontal:** refere-se ao caráter convergente/divergente do terreno em relação à direção da drenagem (**figura 2**); **efeito sul:** efeito calculado como o cosseno do ângulo azimutal em relação ao sul, segundo o qual vertentes viradas para o

sul têm efeito sul = +1, viradas para o norte efeito sul = -1; **efeito mar**: efeito calculado como o cosseno do ângulo azimutal em relação à direção do mar, segundo o qual vertentes viradas para o mar têm efeito mar = +1, viradas para o interior têm efeito mar = -1; e **distância da costa**: distância em relação à linha da costa.

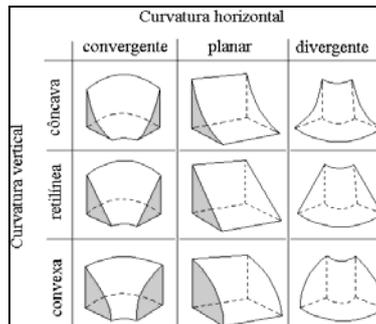


Figura 2: Desenho esquemático das variáveis topográficas curvatura horizontal e vertical.

A área de estudo corresponde a parte da Região Metropolitana de São Paulo, Vale do Paraíba e Litoral Norte do Estado (**figura 3**). Ela corresponde à Folha SF-23-Y-D, gerada em escala 1: 250 000 a partir de dados da missão *SRTM – Shuttle Radar Topographic Mission*. Os dados de curvatura vertical e horizontal, declividade, efeito sul e efeito mar foram calculados a partir da imagem *SRTM* e bases topográficas digitais aliadas ao uso de Sistemas de Informação Geográfica. Os dados de temperatura e precipitação foram coletados nas estações agrometeorológicas e representam uma média dos valores coletados entre 1962 e 1992, considerando um intervalo de 30 anos, fundamental para a caracterização de variáveis climáticas.

Todas as variáveis independentes foram correlacionadas com dados de precipitação obtidos junto ao DAEE (*Departamento de Águas e Energia Elétrica*) do Estado de São Paulo em 41 pontos georreferenciados (estações agrometeorológicas) plotados na **Figura 3**.

As variáveis independentes (X) foram correlacionadas com a variável dependente (Y), no caso, a precipitação, para cada mês referido. A partir de análise de regressão, foi possível concluir quais variáveis melhor explicam a distribuição pluviométrica em cada mês e, desse modo, enriquecem o modelo de distribuição espacial da precipitação pluviométrica quando incluídas.

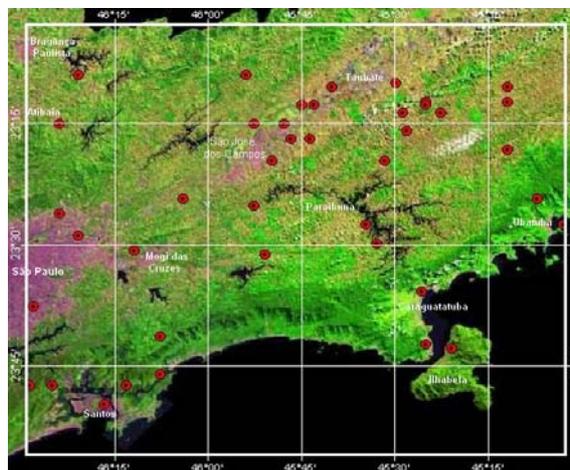


Figura 3: Localização da área e estações agrometeorológicas sobre mosaico TM/Landsat.

Para o estudo da influência das variáveis topográficas sobre a distribuição espacial da precipitação foi construído um modelo de regressão linear múltipla. Segundo Neter et al. (1996), e considerando as características desta aplicação específica, a construção do modelo seguiu basicamente três etapas: (a) coleta e preparação dos dados; (b) redução do número de variáveis preditivas; e (c) refinamento e seleção do modelo.

3. Resultados

3.1 Coleta e preparação dos dados

Dispondo dos dados originais, foram aplicadas análises preliminares informais buscando identificar a presença de *outliers* e o intervalo de valores válidos para cada variável. Não houve grande variação na temperatura média entre as observações em todos os meses. A maior parte dos valores de precipitação concentrou-se entre 200 a 250 mm para o mês de janeiro (a) e 30 e 60 mm para julho (b), embora uma estação agrometeorológica apresente valores medidos próximos a 600 mm em janeiro e 200 mm em julho. Estes valores não podem ser descartados porque neste local, situado na Serra do Mar, a conjugação de fatores ambientais leva a ocorrência de maiores índices de precipitação.

No que diz respeito à forma da relação entre as variáveis dependentes e independentes, a análise preliminar foi feita através de diagramas de dispersão e matrizes de correlação (**figura 4**). Algumas variáveis não apresentaram relação linear com *Y*, tais como declividade, efeito sul e efeito mar. Outras, tais como a distância da costa e a altitude, apresentaram correlação negativa.

No caso da altitude, observações situadas em áreas próximas ao nível do mar tendem a apresentar valores mais altos de precipitação. O mesmo acontece com as observações próximas à linha da costa. Era esperado que isso acontecesse, dentre outros fatores, pela atuação da orografia no favorecimento da ocorrência de chuvas.

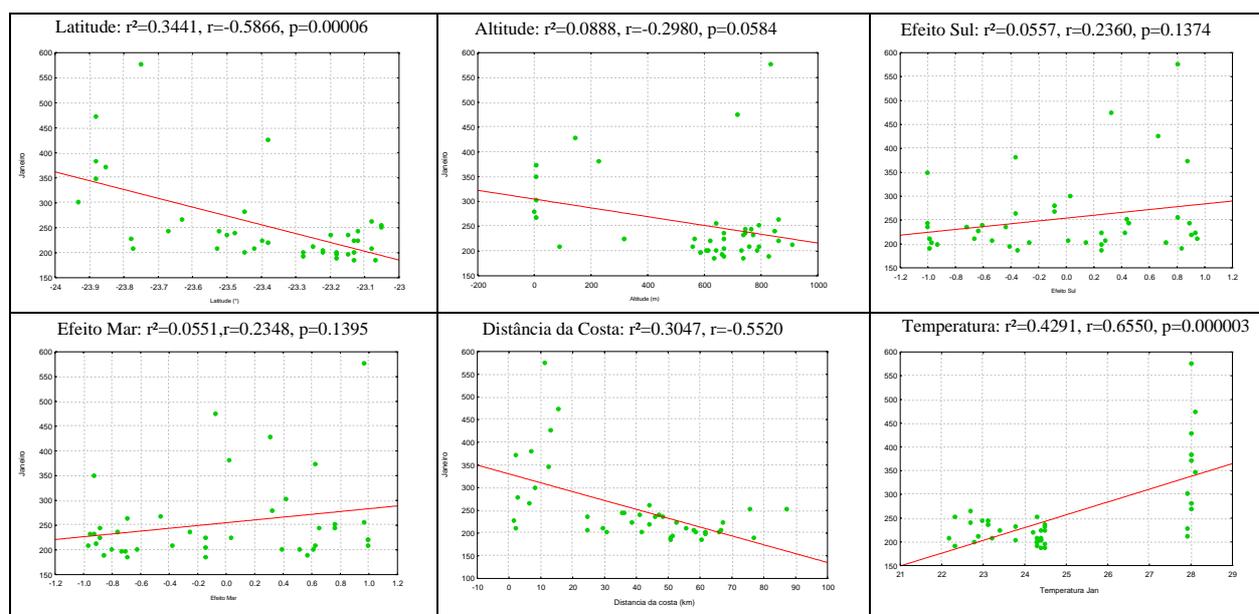


Figura 4: Diagramas de dispersão das variáveis explicativas em relação à variável dependente (janeiro): latitude; altitude; efeito sul; efeito mar; distância da costa e temperatura de janeiro.

Dentre o conjunto de variáveis utilizadas para construção do modelo de regressão, aquela que apresentou o maior coeficiente de determinação (R^2) foi a temperatura (**figura 4**), para todos os meses. Todavia, isto é função da grande variação nos valores de precipitação apresentado pelas observações com temperatura média em torno de 28 °C. Desconsiderando a temperatura, o maior R^2 foi fornecido pela variável latitude (**figura 4**).

Na análise da correlação entre as variáveis independentes, através da matriz de correlação e dos diagramas de dispersão, foi identificada uma alta correlação entre variáveis (**figura 5**) como efeito sul e efeito mar (0,91), por exemplo. Apesar do número de variáveis consideradas ser grande para o número de observações (10 para 41), através do procedimento conhecido como *best subsets* foram selecionadas as melhores variáveis explicativas para cada mês considerado.

Variable	Correlations (Dados)										
	Longitude (°)	Latitude (°)	Altitude (m)	Declividade (%)	Curvatura vertical (°/m)	Curvatura horizontal (°/m)	Efeito Sul	Efeito Mar	Distância da costa (km)	Temperatura Janeiro (°C)	Janeiro
Longitude (°)	1.00	0.41	-0.04	0.29	-0.08	0.26	-0.17	-0.31	-0.11	0.02	-0.27
Latitude (°)	0.41	1.00	0.58	0.11	-0.43	0.16	0.15	0.05	0.85	-0.68	-0.59
Altitude (m)	-0.04	0.58	1.00	0.28	-0.15	-0.10	0.11	0.10	0.62	-0.82	-0.30
Declividade (%)	0.29	0.11	0.28	1.00	0.00	0.17	0.00	-0.06	-0.02	0.01	-0.05
Curvatura vertical (°/m)	-0.08	-0.43	-0.15	0.00	1.00	0.08	-0.17	-0.09	-0.39	0.40	0.39
Curvatura horizontal (°/m)	0.26	0.16	-0.10	0.17	0.08	1.00	0.23	0.19	0.03	0.15	0.02
Efeito Sul	-0.17	0.15	0.11	0.00	-0.17	0.23	1.00	0.91	0.20	-0.06	0.24
Efeito Mar	-0.31	0.05	0.10	-0.06	-0.09	0.19	0.91	1.00	0.16	-0.08	0.23
Distância da costa (km)	-0.11	0.85	0.62	-0.02	-0.39	0.03	0.20	0.16	1.00	-0.73	-0.55
Temperatura Janeiro (°C)	0.02	-0.68	-0.82	0.01	0.40	0.15	-0.06	-0.08	-0.73	1.00	0.66
Janeiro	-0.27	-0.59	-0.30	-0.05	0.39	0.02	0.24	0.23	-0.55	0.66	1.00

Figura 5: Matriz de Correlação entre as variáveis explicativas para o mês de janeiro.

3.2 Redução do número de variáveis explicativas

Visando a redução do número de variáveis explicativas, após a análise exploratória dos dados foi gerado um modelo de regressão linear múltipla com todas as variáveis. Este modelo foi comparado com os efeitos de algumas transformações realizadas sobre os dados (Y^2 , \sqrt{Y} , $\log Y$), e os melhores resultados foram obtidos considerando os dados originais (**figura 6**). Dentre as formas de seleção de variáveis através de *best subsets*, foram testadas: R^2 , R^2 ajustado e $Mallows' C_p$. No modelo completo, considerando todas as 10 variáveis, o R^2 obtido foi de 0,88 para o mês de janeiro e 0,92 para julho. No modelo reduzido, um modelo com apenas cinco variáveis gera coeficientes de 0,85 para janeiro e 0,89 para julho, valores estes muito próximos (com apenas 0,03 de diferença) àqueles obtidos considerando todas as variáveis, o que salienta sua maior importância para a explicação de Y em relação às demais.

Regression Summary for Dependent Variable: Janeiro (Dados)							Regression Summary for Dependent Variable: Julho (Dados)						
R=,93797374 R²=,87979474 Adjusted R²=,83972632 F(10,30)=21,957 p<,00000 Std.Error of estimate: 33,556							R=,96090057 R²=,92332991 Adjusted R²=,89777322 F(10,30)=36,129 p<,00000 Std.Error of estimate: 13,533						
N=41	Beta	Std.Err. of Beta	B	Std.Err. of B	t(30)	p-level	N=41	Beta	Std.Err. of Beta	B	Std.Err. of B	t(30)	p-level
Intercept			2221,247	1343,215	1,65368	0,108621	Intercept			398,841	543,3972	0,73398	0,468661
Longitude (°)	-1,37893	0,290123	-275,135	57,888	-4,75291	0,000047	Longitude (°)	-1,15341	0,231680	-116,218	23,3442	-4,97845	0,000025
Latitude (°)	2,21655	0,516125	666,372	155,165	4,29460	0,000169	Latitude (°)	1,64180	0,413188	249,253	62,7287	3,97351	0,000411
Altitude (m)	0,73411	0,158983	0,218	0,047	4,61751	0,000068	Altitude (m)	0,17250	0,124251	0,026	0,0187	1,38833	0,175260
Declividade (%)	-0,15693	0,084766	-0,931	0,503	-1,85134	0,073988	Declividade (%)	-0,01816	0,067316	-0,054	0,2018	-0,26972	0,789224
Curvatura vertical (°/m)	0,07650	0,090517	185,720	219,756	0,84512	0,404734	Curvatura vertical (°/m)	0,24621	0,071364	301,852	87,4921	3,45006	0,001686
Curvatura horizontal (°/m)	-0,07886	0,076394	-16,494	15,977	-1,03235	0,310160	Curvatura horizontal (°/m)	-0,08764	0,060853	-9,256	6,4268	-1,44023	0,160157
Efeito Sul	0,18252	0,168271	23,000	21,204	1,08469	0,286701	Efeito Sul	0,02806	0,133934	1,785	8,5228	0,20947	0,835498
Efeito Mar	-0,10210	0,173599	-12,301	20,916	-0,58813	0,560850	Efeito Mar	0,10368	0,138955	6,308	8,4543	0,74613	0,461396
Distancia da costa (km)	-2,19457	0,443029	-7,757	1,566	-4,95356	0,000027	Distancia da costa (km)	-1,82043	0,353263	-3,249	6,3005	-5,15315	0,000015
Jan	1,18656	0,163674	48,824	6,735	7,24952	0,000000	Jul	0,67906	0,118754	15,555	2,7201	5,71833	0,000003

Figura 6: Regressão múltipla base (todas as variáveis) para janeiro (esquerda) e julho (direita).

3.3 Refinamento e seleção do modelo

Nesta etapa foram comparados os critérios R^2 , R^2 ajustado e $Mallows' C_p$ para todos os modelos possíveis em cada mês. Com base nestes critérios, foram selecionados três modelos para cada mês (com 4, 5 ou 6 variáveis) visando uma análise mais detalhada dos resíduos e da presença de *outliers*. Com base nestas análises e nos parâmetros estimados, o modelo mais adequado para cada mês foi selecionado segundo as recomendações apresentadas por Neter et al. (1996).

Pela análise da distribuição normal dos resíduos, o melhor modelo de regressão é o que apresenta cinco variáveis no caso do mês de janeiro, e seis no caso de julho. Quanto a relação entre os resíduos e os valores preditos, observa-se correlação espacial em ambos os modelos, tanto para janeiro quanto para julho. Isto está de acordo com os resultados de uma pesquisa desenvolvida em Portugal por Goovaerts (2000), que encontrou forte correlação espacial entre os resíduos do modelo de regressão. Procurando estudar a correlação espacial dos resíduos foram elaborados diagramas com a distribuição geográfica dos valores pela área de estudo (**figura 7**).

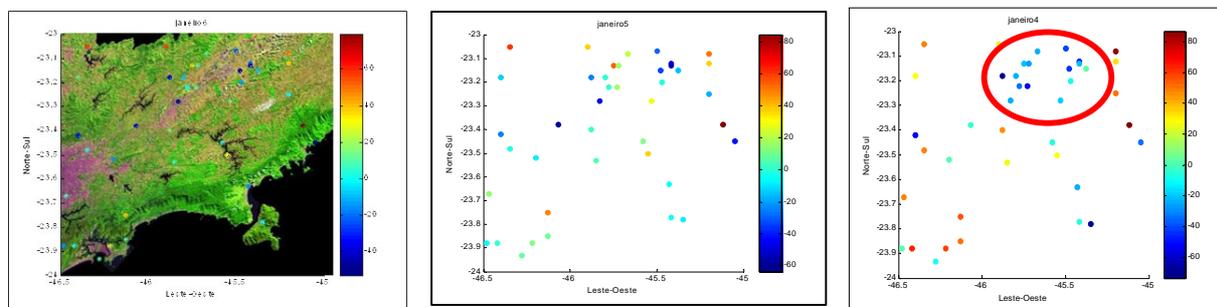


Figura 7: Diagrama com a espacialização geográfica dos resíduos para os modelos selecionados para o mês de janeiro com seis, cinco e quatro variáveis.

Analisando os diagramas pode ser observada a configuração de grupamentos (*clusters*) com valores próximos de resíduos, destacando-se o caso do Vale do Paraíba. Os grupamentos de valores próximos quanto aos resíduos também foram observados em outros meses.

Considerando a distribuição dos resíduos dos modelos, e os parâmetros estimados para cada um (**tabelas 1 e 2**), foi escolhido um modelo de regressão com cinco variáveis para o mês de janeiro, com um R^2 de 0,848, e um modelo com seis para o mês de julho, com R^2 de 0,907.

Para a análise da influência de *outliers*, foram pesquisados os casos extremos indicados através do índice *DFITTS*. Segundo Neter et al. (1996), para pequenas amostras de dados, o valor de *DFITTS* deve ser inferior a 1, o que indica que a observação não é um *outlier* influente. Foram encontradas várias observações com valores superiores a 1, sendo que a observação a qual foram associados os mais altos valores em todos os modelos (chegando ao valor 38 para janeiro) localiza-se na Serra do Mar próxima ao litoral. Os extremos ocorrem, portanto, pela orografia.

Os *outliers* encontrados foram mantidos no modelo, não podendo ser desconsiderados porque representam casos atípicos importantes para o enfoque do estudo.

3.4 Validação do modelo

Os modelos de regressão podem ser validados em termos de comparação entre os coeficientes de regressão para o conjunto de treinamento (com a separação de um conjunto menor de dados do conjunto total, cerca de 25%) e de validação (conjunto completo de dados).

Tabela 1: Parâmetros estimados para o modelo de regressão com cinco variáveis para janeiro.

	Janeiro Parâm.	Janeiro s(b)	Janeiro t	Janeiro p	IC -95.00%	IC +95.00%	Janeiro β	Janeiro s(β)	IC -95.00%	IC +95.00%
Intercepto	2701.241	1245.383	2.16900	0.036961	172.979	5229.503				
Longitude (°)	-312.823	45.765	-6.83544	0.000000	-405.730	-219.915	-1.56779	0.229362	-2.03342	-1.10216
Latitude (°)	759.280	130.655	5.81133	0.000001	494.036	1024.523	2.52559	0.434597	1.64331	3.40786
Altitude (m)	0.199	0.034	5.81140	0.000001	0.129	0.268	0.66909	0.115134	0.43536	0.90283
Distancia da costa (km)	-8.559	1.361	-6.28961	0.000000	-11.321	-5.796	-2.42147	0.384995	-3.20305	-1.63989
Temp Jan (°C)	48.602	5.488	8.85658	0.000000	37.462	59.743	1.18117	0.133367	0.91042	1.45192

Tabela 2: Parâmetros estimados para o modelo de regressão com seis variáveis para julho.

	Julho Parâm.	Julho s(b)	Julho t	Julho p	IC -95.00%	IC +95.00%	Julho β	Julho s(β)	IC -95.00%	IC +95.00%
Intercepto	707.042	533.8667	1.32438	0.194211	-377.905	1791.990				
Longitude (°)	-123.316	20.7684	-5.93767	0.000001	-165.523	-81.110	-1.22386	0.206118	-1.64274	-0.80498
Latitude (°)	272.864	58.8251	4.63857	0.000050	153.318	392.411	1.79733	0.387475	1.00989	2.58477
Curvatura vertical (°/m)	336.441	73.3329	4.58785	0.000058	187.410	485.471	0.27442	0.059815	0.15286	0.39598
Efeito Sul	8.311	3.8315	2.16904	0.037165	0.524	16.097	0.13060	0.060212	0.00824	0.25297
Distancia da costa (km)	-3.419	0.5965	-5.73290	0.000002	-4.632	-2.207	-1.91584	0.334184	-2.59499	-1.23670
Temp Jul (°C)	12.192	1.7620	6.91940	0.000000	8.611	15.773	0.53228	0.076925	0.37595	0.68861

Infelizmente, devido ao reduzido número de observações com as quais foi trabalhado (41), o modelo não pôde ser validado separando-se dados para posterior inclusão e aplicação dos procedimentos estatísticos para a comparação de resultados. Da mesma forma, a coleta de novos dados não pôde ser realizada porque o número de observações depende do número de estações meteorológicas existente. No entanto, sua significância é grande se comparada à distribuição de estações por outras regiões do Estado de São Paulo, mais escassa ainda quanto a sua densidade.

Não havendo um número maior de estações, o modelo poderá ser validado na continuidade desta pesquisa através de uma validação cruzada, a fim de verificar se os resultados obtidos se assemelham quando há um menor número de pontos amostrais, e/ou se aplicam a áreas onde a densidade de estações é menor. Provavelmente, pelo fato de a cada região estarem associadas diferentes estruturas de relevo, um modelo específico deverá ser encontrado a partir de dados topográficos de cada área. Além disso, Neter et al. (1996) afirmam que quando um modelo de regressão linear não pode ser validado sob as formas tradicionais da estatística, a validação pode basear-se em evidências empíricas e/ou teorias científicas. Foi este o caminho percorrido.

4. Conclusões

Embora o modelo de regressão não tenha sido validado, a inclusão da variável explicativa altitude no modelo para janeiro está de acordo com evidências empíricas e a climatologia, que destaca a relevância das estruturas de relevo para o favorecimento de chuvas orográficas. Mais frequentes na estação do verão, este tipo de chuva está associado à proximidade da costa, ocorrência de maiores temperaturas e aquecimento da superfície terrestre favorecendo a evaporação, condensação e precipitação em função da barreira topográfica imposta pela Serra do Mar.

Além disso, outro tipo de chuvas frequente neste período (verão) são as chuvas convectivas, que ocorrem em função da elevação do vapor d'água associada à presença de zonas de baixa pressão (**figura 8a**). Tal elevação contribui para o encontro com ar de temperatura mais baixa em maior altitude, bem como aerossóis, favorecendo a condensação e posterior precipitação. Por sua vez, a inclusão da curvatura vertical e efeito sul no modelo de regressão para o mês de julho pode

estar associada à ocorrência de chuvas frontais, embora a influência da curvatura vertical seja muito localizada. Mais frequentes no inverno, a ocorrência deste tipo de chuvas está ligada à entrada de frentes frias associadas à massa de ar polar atlântica (**figura 8b**).

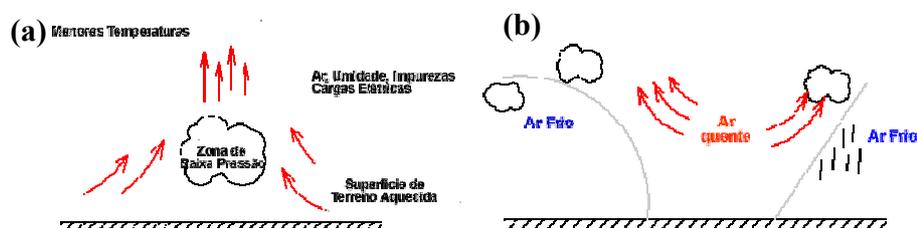


Figura 8: Desenho esquemático ilustrando a formação de chuvas convectivas (a) e frontais (b).

Apesar de o modelo considerando esta variável não ter sido selecionado, o efeito mar apareceu no maior R^2 gerado por um modelo considerando quatro variáveis para janeiro, ou seja, é importante para explicar a distribuição das chuvas no verão, assim como a declividade, também incluída em tal modelo. Por sua vez, a temperatura mostrou grande significância para explicar a precipitação, tendo sido a única incluída em todos os modelos, para todos os meses do ano.

Embora os coeficientes de determinação obtidos para os dois meses analisados com detalhe (janeiro e julho) sejam altos (considerando os modelos reduzidos selecionados), entre 0,85 e 0,90, as análises apresentadas neste trabalho poderiam ser aprofundadas caso fosse incorporada estatística espacial, visando buscar a decorrelação espacial dos dados, apresentada nos resíduos dos modelos selecionados. A análise espacial é importante para estudos que envolvem estatísticas não-paramétricas, que não dependem de pressupostos como condições de contorno, tais como a normalidade da distribuição dos dados e independência.

Nesse sentido, conforme a bibliografia especializada, conclui-se que resultados mais eficazes para a interpolação espacial de dados pluviométricos poderão ser obtidos a partir do emprego de outras técnicas de análise estatística multivariada. Entretanto, a inclusão de dados topográficos em modelos de regressão apresentou resultados positivos, com significativo potencial de explicação da distribuição das chuvas na área teste escolhida.

5. Agradecimentos

Agradecemos aos Pesquisadores do INPE Dr. Márcio de Morrison Valeriano e Dra. Corina da Costa Freitas, pela dedicada orientação prestada à execução deste trabalho.

6. Referências Bibliográficas

Goovaerts, P. Geostatistical approaches for incorporating elevation into the spatial interpolation of rainfall. **Journal of Hidrology**, v. 228, pp. 113-129, 2000.

Neter, J.; Kutner, M.; Nachtsheim, C.; Wasserman, W. **Applied Linear Statistical Models**. Chicago, IL: Richard D. Irwin, Inc, 1996.

Soares, F. S.; Francisco, C. N.; Carvalho, C. N. Análise dos fatores que influenciam a distribuição espacial da precipitação no litoral sul fluminense – RJ. In: Simpósio Brasileiro de Sensoriamento Remoto, XII, 2005, Goiânia, Brasil. **Anais...** São José dos Campos: INPE, 2005, pp. 3365-3370.

Valeriano, M. M. Curvatura vertical de vertentes em microbacias pela análise de modelos digitais de elevação. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 7, n. 3, pp. 539-546, 2003.

_____; Picini A. G. **Geoprocessamento de informações agroclimatológicas**. São José dos Campos, SP: INPE: Coordenação de Ensino, Documentação e Programas Especiais (INPE-1028-RPQ/751), 2003. 133p.