

SENSORIAMENTO REMOTO PARA ESTIMATIVA DA PRECIPITAÇÃO NO ESTADO DO RIO GRANDE DO SUL

GUILHERME NOBEL CONTI¹
CARLOS ANDRÉ BULHÕES MENDES²

¹ Exército Brasileiro – Comissão Regional de Obras/3
Rua Sete de Setembro, 332 – 90010-190 – Porto Alegre – RS, Brasil
guilherme.com@uol.com.br

² IPH/UFRGS – Instituto de Pesquisas Hidráulicas/Universidade Federal do Rio Grande do Sul
Av. Bento Gonçalves, 9500 – 91501-970 – Porto Alegre – RS, Brasil
cabmendes@yahoo.com

Abstract. At this work, the application of remote sensing and geoprocessing techniques for precipitation estimation at the south of Brazil was investigated. The precipitation estimations using remote sensing techniques and geoprocessing intend to potencialize the utilization of existent pluviometric stations through a spacialization based on physics criteria. This physics criteria are based on the cloud tops temperature and the brightness in the visible channel (Satellite GOES8 images). The studying area is the Rio Grande do Sul state, where the 1998's daily precipitation data of 142 raingauges were used.

Keywords: precipitation, remote sensing, statistics analysis.

1. Introdução

Convencionalmente, a estimativa da precipitação é feita através de mensurações diretas e pontuais da precipitação acumulada em determinado espaço de tempo e extrapoladas e/ou interpoladas para toda área de interesse. Com esta prática, acaba-se por imputar uma estimativa de precipitação para as áreas mais distantes dos postos pluviométricos sem qualquer indício físico real sobre a quantidade de precipitação verdadeiramente ocorrida.

No Brasil, de forma geral, é notória a pequena quantidade e relativa má distribuição espacial dos postos pluviométricos. Neste contexto, surge a necessidade de metodologias que contemplem melhores estimativas da precipitação, notadamente através de técnicas de sensoriamento remoto, o que é o objeto da presente pesquisa. A hipótese norteadora para as estimativas da precipitação com técnicas de sensoriamento remoto é a de que certas características espectrais e o padrão geográfico das imagens de satélites possuem uma relação de interdependência com os processos físicos das nuvens e indiretamente com as quantidades precipitadas sobre a superfície terrestre.

O método de estimativa de precipitação desenvolvido nesta pesquisa utiliza imagens do satélite *Geostacionary Operational Environmental Satellite – 8* (GOES 8) nas bandas espectrais do visível e infravermelho. A estimativa da precipitação foi realizada para dois períodos diferenciados de acumulação da precipitação (diário e decendial), durante todas as estações do ano de 1998 no Estado do Rio Grande do Sul.

2. Princípios físicos gerais da precipitação

O vapor de água contido na atmosfera constitui-se num reservatório potencial da água que, sob determinadas condições, condensa possibilitando as precipitações. O ar pode atingir a saturação por duas maneiras: por acréscimo de vapor d'água ao ar (maior evaporação) ou por resfriamento. Dentre estas, o resfriamento é preponderante. Como a capacidade do ar em conter vapor d'água varia com a temperatura, o resfriamento ocasiona a diminuição do volume da massa de ar, diminuindo assim a capacidade do ar em conter vapor. Para que

ocorra a precipitação é necessário que as gotas tenham um volume tal que o seu peso supere as forças que as mantêm em suspensão. Assim, a precipitação está intimamente ligada ao crescimento das gotículas, ocorrendo principalmente pela diminuição da temperatura.

Segundo Tucci e Bertoni (2000), nas nuvens com temperatura abaixo de 0° C a tensão máxima de vapor (vapor saturante) é, para uma mesma temperatura, menor para o gelo do que para a água sobrefundida. Quando uma nuvem fria, devido à turbulência, contiver ao mesmo tempo cristais de gelo e gotículas de água sobrefundida, estas se vaporizam em proveito dos cristais de gelo, tornando-se centros de condensação e aumentando de volume, ocasionando a precipitação. Esta teoria é conhecida como Teoria de Tor Bergeron – Fındensen, de 1935.

3. Área de estudo e os dados de precipitação utilizados

Os dados de precipitação utilizados referem-se a 142 postos pluviométricos, compreendendo o ano de 1998. O Estado do Rio Grande do Sul possui 282.062 km² de superfície, o que resulta (desconsiderando-se a distribuição espacial dos postos) numa média de 1.986,35 km² por posto pluviométrico.

Com as coordenadas geográficas dos postos (latitude e longitude) construiu-se uma “máscara” contendo o posicionamento dos postos dentro das imagens do GOES 8. Esta máscara está representada na **figura 1** Devido a intrínseca falta de precisão do georreferenciamento por modelos de geometria orbital, salienta-se que no posicionamento dos postos pode ocorrer um erro máximo de aproximadamente 5 km. Observa-se ainda na **figura 1** que os postos pluviométricos estão mal distribuídos na área de estudo

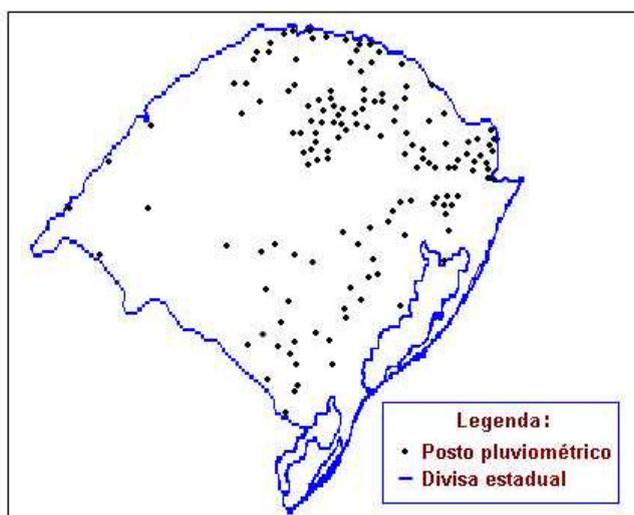


Figura 1: Máscara Posicional

O ano de 1998 pode ser considerado atípico climatologicamente devido ao fenômeno “El Niño”, que é o aquecimento das águas do oceano pacífico (o resfriamento é chamado de “La Niña”). Estes fenômenos induzem a mudanças na circulação atmosférica global e conseqüentemente na distribuição da precipitação. Tipicamente, o fenômeno La Niña é associado a condições mais secas para o sul do continente americano. Segundo o Fórum de Previsão Climática Regional para o Sudeste da América do Sul (1998), o período de julho a setembro de 1998 caracterizaria-se pela transição de condições de El Niño (iniciado em 1997) para La Niña. Esta transição ocasionaria a predominância de condições mais secas no período de outubro a dezembro no sudeste da América do Sul, o que foi confirmado nos dados de precipitação disponibilizados. Desta forma, na presente pesquisa tomou-se a decisão de se analisar separadamente cada um dos semestres de 1998 para construção de estimativas diferenciadas.

4. As imagens do satélite GOES 8

O satélite americano GOES 8 é operado pela National Oceanic and Atmospheric Administration (NOAA), sendo que o desenvolvimento, construção e lançamento coube à National Aeronautic and Space Administration (NASA). O satélite foi lançado em abril de 1994, tornando-se operacional no ano seguinte sobre a linha do equador a 75°W de longitude.

A plataforma do GOES 8 carrega instrumentos multicanais projetados para captar a radiação e a energia refletida pela Terra, sendo que a superfície terrestre é imageada simultaneamente em todos os cinco canais disponíveis a cada 15 minutos. O canal 1 (Visível) situa-se no comprimento de onda de 0,52 a 0,72 μm , o canal 2 (Infravermelho de ondas curtas) de 3,78 a 4,03 μm , o canal 3 (Vapor d'água) de 6,47 a 7,02 μm , o canal 4 (Infravermelho) de 10,2 a 11,20 μm e o canal 5 (Infravermelho de ondas longas) de 11,5 a 12,5 μm (Ellrod, 1998).

As imagens aqui utilizadas são dos canais 1 e 4 (ambas cedidas pelo Instituto Nacional de Pesquisas Espaciais - INPE). As imagens abrangem o período de 01 de janeiro a 31 de dezembro de 1998, porém, como existem 69 dias com falhas no imageamento, apenas 296 dias são passíveis de serem processados com uma resolução temporal de 3 horas. Como o canal 1 depende da exposição solar, apenas se dispõem de imagens neste canal nos horários diurnos, sendo para que para o canal Infravermelho existem imagens em todos os horários, perfazendo doze imagens diárias disponíveis (4 do canal 1, 8 do canal 4). A precisão espacial das imagens fornecidas pelo INPE é de 4 km.

A informação contida nas imagens do canal 1 representa a reflectância, isto é, a razão entre a radiação incidente e a refletida neste canal, tendo duas casas de precisão (por exemplo: 6289 representa 62,89%). A informação contida nas imagens do canal 4 representa a temperatura do topo das nuvens, ou na ausência de nuvens, a temperatura da própria superfície terrestre. A temperatura é expressa em Kelvin com duas casas de precisão (por exemplo: 25845 representa 258,45 K). Ressalta-se que as temperaturas contidas nestas imagens não são produzidas diretamente pelos sensores do GOES 8, mas sim através de correlações com as temperaturas reais (obtidas com sondas atmosféricas) a partir da mensuração da energia oriunda da superfície terrestre.

5. As características das nuvens nas imagens de satélite

Embora exista algum debate sobre a exata relação entre o brilho da nuvem no canal visível e a precipitação, é geralmente aceito que as nuvens mais brilhantes são mais espessas e conseqüentemente com maior tendência a gerar precipitação (Rosenfeld, 1990). No canal visível a Terra não emite radiação, mas reflete a oriunda do Sol., permitindo as seguintes observações:

- Os continentes, mares e oceanos são escuros;
- As nuvens mais espessas são mais brilhantes porque refletem mais radiação solar (nuvens cumuliformes ou bancos de nuvens estratificadas com grande espessura);
- As nuvens de grande altura mas pouco espessas (cirriformes) são pouco ou nada visíveis.

A temperatura da superfície da nuvem (mensurada através do canal infravermelho) é aceita como um dos fatores mais importantes na geração da precipitação. Quanto menor a temperatura, maior é a penetração nas camadas mais altas da atmosfera e, conseqüentemente, maior a tendência a gerar precipitação. No canal infravermelho a atmosfera quase não absorve radiação, porém as nuvens sim. Assim, para as imagens obtidas no canal do infravermelho, pode-se enumerar as seguintes observações:

- Os continentes, mares e oceanos são claros;
- As nuvens frias emitem menos radiação, e desta forma, são vistas mais escuras do que em relação a superfície;
- As nuvens cirriformes possuem pequena absorção da radiação solar, mas absorvem radiação térmica vinda do solo, voltando a emití-la. Portanto, estas nuvens quando situadas em altitudes elevadas também podem ser visualizadas no canal infravermelho.

6. Algoritmo de reconhecimento da precipitação

A peça central de todo o processo de estimativa é o algoritmo de reconhecimento da precipitação, que tem por objetivo gerar um banco de dados suscetível de ser correlacionado estatisticamente com a precipitação observada no postos pluviométricos. O algoritmo de reconhecimento da precipitação nada mais é do que um programa computacional que baseado na reflectância e na temperatura do topo das nuvens pretende identificar quais as nuvens passíveis de gerar precipitação em cada horário imageado.

O produto final do algoritmo é um banco de dados composto pela variável independente nomeada "IR", que corresponde ao somatório (diário ou decendial) das assinaturas das imagens no canal 4. A assinatura de um pixel do canal 4 em um dado horário somente participará do somatório (diário ou decendial) se a sua posição estiver contida na área considerada precipitável naquele horário. Após a separação das áreas consideradas precipitáveis, as imagens resultantes são somadas (em períodos diários ou decendiais), gerando o banco de dados para a regressão. Através de regressão quadrática (tendo como variável dependente a precipitação dos postos pluviométricos) obtém-se um modelo estatístico que possibilita estimar a precipitação em toda a área de estudo.

Os parâmetros do algoritmo são três: R, k_D e k_N . O parâmetro R refere-se a reflectância, somente sendo aplicado nas imagens diurnas (canal 1). Os parâmetros k_D e k_N referem-se a temperatura do topo das nuvens, sendo aplicados em todas as imagens do canal 4 (k_D para o período diurno e k_N para o noturno). Para que um determinado pixel seja reconhecido como tendo uma nuvem precipitável diurna é necessário que a reflectância (canal 1) seja superior a R e a temperatura inferior a k_D (canal 4). No período noturno é necessário que a temperatura seja inferior a " k_N " (canal 4).

Estes parâmetros são funções da dinâmica e da estrutura física das nuvens e podem variar largamente tanto no tempo quanto no espaço (Dugdale et al., 1991). Desta forma, a escolha dos parâmetros (especialmente k_D e k_N) deve ser criteriosa, pois deve retratar tanto quanto possível a maior parte dos fenômenos meteorológicos precipitáveis na área de interesse. Durante o período diurno, as imagens do canal 1 e 4 excluem de forma mais confiável as nuvens não precipitáveis, o que permite uma temperatura maior como limite diurno (em comparação ao período noturno, onde não há o auxílio das imagens do canal 1), tendo-se em vista a não exclusão de nuvens precipitáveis mais quentes (240 a 275K). Desta forma, optou-se pela adoção de temperaturas diferentes nos períodos diurno e noturno (k_D e k_N diferenciados).

7. Calibração do algoritmo de reconhecimento da precipitação

Calibrar o algoritmo de reconhecimento da precipitação significa obter os valores mais adequados para os parâmetros (R, k_D , k_N), com o intuito de se conseguir a melhor representatividade da precipitação. Após diversos testes realizados de forma iterativa com os dados disponíveis, obteve-se como melhores parâmetros os seguintes: 30% (R), 235 K (k_D) e 270 K (k_N). Com tais parâmetros, o algoritmo reconheceu acertadamente 78,9% das observações ("chuva" ou "não chuva") dos postos pluviométricos (73,22% de acerto para as ocasiões com precipitação e 81,45% para as sem precipitação).

Barret *et al.* (1990) apresentam o resultado alcançado por dois algoritmos baseados nas microondas passivas, onde o total de acertos foi de 86,8 % (algoritmo de frequência) e 84,0 % (algoritmo de polarização). Como a qualidade das estimativas com a utilização de microondas passivas são tidas como de melhor qualidade (comparativamente aos critérios biespectrais no infravermelho e visível), considera-se que os resultados alcançados na presente pesquisa são compatíveis com a metodologia ora empregada.

8. Regressão para precipitação diária

A descontinuidade observada na distribuição dos pontos $P \times IR_{diário}$ na **figura 2** (referente ao 1º semestre) é explicada pela diferenciação numérica da variável $IR_{diário}$ entre os dias com diferentes quantidades de imagens diárias (de 1 até 8) retratando precipitação. Como existem sete agrupamentos identificáveis de pontos $P \times IR_{diário}$, conclui-se que o algoritmo reconheceu até 7 imagens diárias como precipitáveis (dentre as 8 possíveis). A mesma situação repete-se no 2º semestre. Os valores limites de cada agrupamento estão apresentados na **tabela 1**.

Nº de imagens diárias precipitáveis	Faixas de $IR_{diário}$ (Kx100)	Faixas de $IR_{diário}$ (K)
1	14.800 a 27.000	148 a 270
2	38.000 a 54.000	380 a 540
3	59.000 a 81.000	590 a 810
4	82.000 a 100.000	820 a 1.000
5	102.000 a 121.000	1.020 a 1.210
6	123.000 a 141.000	1.230 a 1.410
7	150.500 a 160.000	1.505 a 1.600

Tabela 1: Faixas de variação de IR.

Excluindo-se as amostras nulas e os erros de reconhecimento do algoritmo, têm-se 9.566 observações não nulas de precipitação corretamente identificadas pelo algoritmo (4.646 no 1º e 4.920 no 2º semestre). Para as regressões em cada uma das faixas de variação de $IR_{diário}$ utilizou-se o programa INFER®. Os resultados das regressões encontram-se na **tabela 2** e a representação gráfica das regressões (precipitação calculada) para o 1º semestre de 1998 encontram-se na **figura 2**. Na **figura 3** encontra-se a estimativa realizada para o dia 07 de janeiro de 1998 com os modelos apresentados na 2ª coluna da **tabela 2**. Ressalta-se na estimativa realizada na **figura 3** os modelos foram aplicados individualmente nas áreas com valor de $IR_{diário}$ situado nas faixas específicas em que cada modelo foi construído.

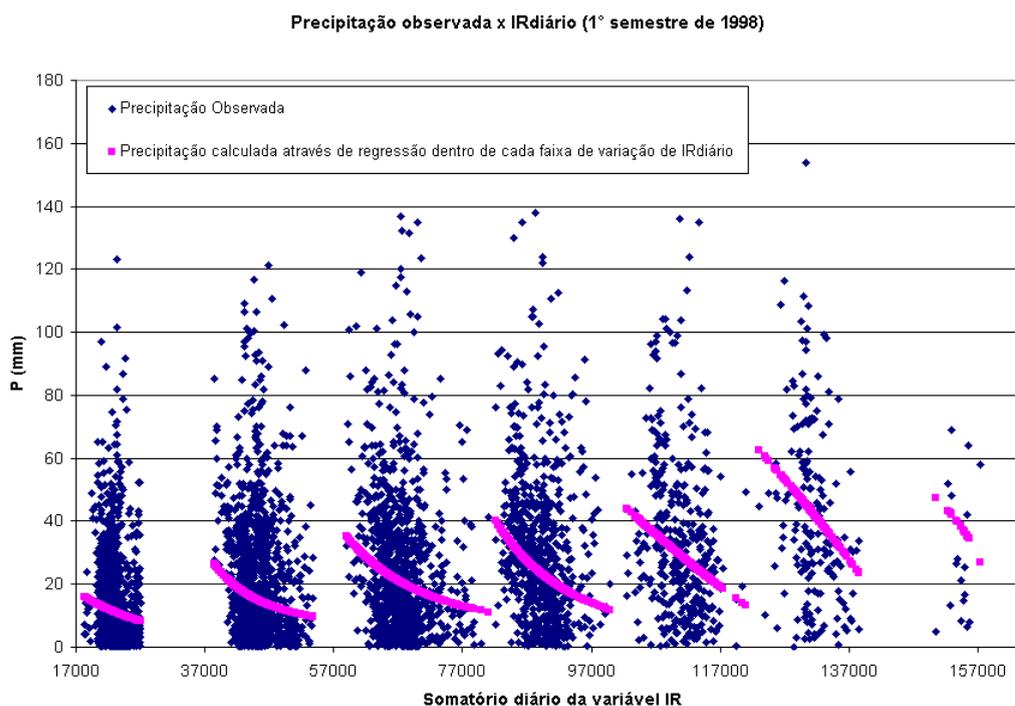


Figura 2: Representação das faixas de variação de $IR_{diário}$ e da precipitação calculada.

Faixa	1º semestre 1998	2º semestre 1998
1	R = 0,1099 R ² = 0,0121 F _{calculado} = 13,17 (ĕ _{modelo} = 99,95%) P = (6,1545 – 0,13781 · IR _{diário} ^{1/3}) ³	R = 0,1064 R ² = 0,0113 F _{calculado} = 17,10 (ĕ _{modelo} = 99,95%) P = 17,197 – 3,7187 · 10 ⁻¹³ · IR _{diário} ³
2	R = 0,1617 R ² = 0,0261 F _{calculado} = 33,98 (ĕ _{modelo} = 99,95%) P = (1,6377 + 7,6370 · 10 ¹³ / IR _{diário} ³) ³	R = 0,3008 R ² = 0,0905 F _{calculado} = 131,5 (ĕ _{modelo} = 99,95%) P = (33,401 – 0,8274 · IR _{diário} ^{1/3}) ²
3	R = 0,2002 R ² = 0,0401 F _{calculado} = 41,72 (ĕ _{modelo} = 99,95%) P = (1,6944 + 8,7225 · 10 ¹⁴ / IR _{diário} ³) ²	R = 0,2393 R ² = 0,0573 F _{calculado} = 67,99 (ĕ _{modelo} = 99,95%) P = (16,586 – 0,3431 · IR _{diário} ^{1/3}) ³
4	R = 0,2468 R ² = 0,0609 F _{calculado} = 47,69 (ĕ _{modelo} = 99,95%) P = (0,8474 + 1,4301 · 10 ¹⁵ / IR _{diário} ³) ³	R = 0,4698 R ² = 0,2207 F _{calculado} = 150,7 (ĕ _{modelo} = 99,95%) P = 1090,7 – 23,599 · IR _{diário} ^{1/3}
5	R = 0,2390 R ² = 0,0545 F _{calculado} = 22,23 (ĕ _{modelo} = 99,95%) P = (11,236 – 4,2822 · 10 ¹⁵ · IR _{diário} ³) ²	R = 0,3509 R ² = 0,1231 F _{calculado} = 38,89 (ĕ _{modelo} = 99,95%) P = (16,383 – 1,1857 · 10 ⁻⁴ · IR _{diário} ³) ³
6	R = 0,2621 R ² = 0,0687 F _{calculado} = 12,54 (ĕ _{modelo} = 99,90%) P = 153,34 – 4,8834 · 10 ⁻¹⁴ · IR _{diário} ³	R = 0,1424 R ² = 0,0203 F _{calculado} = 3,126 (ĕ _{modelo} = 90,00%) P = (23,430 – 0,4013 · IR _{diário} ^{1/3}) ³
7	R = 0,4436 R ² = 0,1968 F _{calculado} = 3,920 (ĕ _{modelo} = 90,00%) P = (5862437 – 108229 · IR _{diário} ^{1/3}) ^{1/3}	R = 0,4843 R ² = 0,2346 F _{calculado} = 3,984 (ĕ _{modelo} = 90,00%) P = (7,6084 – 1,1601 · 10 ⁻¹⁵ · IR _{diário} ³) ³

Tabela 2: Modelos matemáticos para as 7 faixas de variação de IR_{diário}. R é o coeficiente de correlação, R² é o coeficiente de determinação, F é a estatística de Fisher, ĕ_{modelo} é a significância alcançada pelo modelo e P é a precipitação diária estimada (mm)

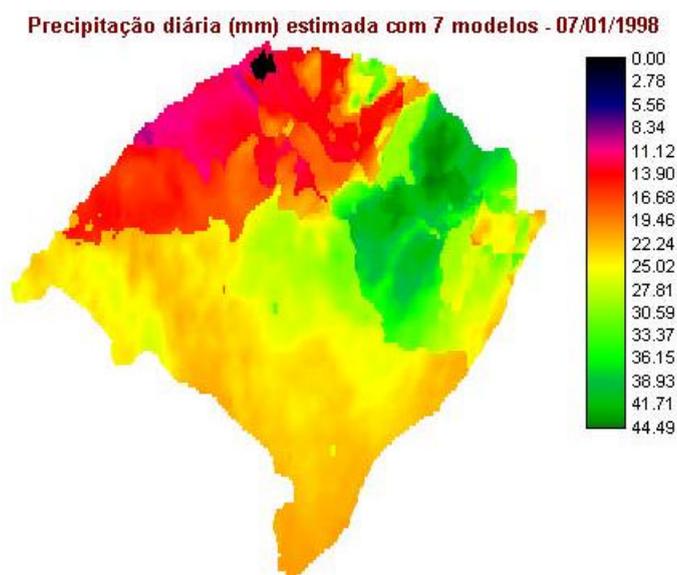


Figura 3: Estimativa da precipitação para o dia 07 de janeiro de 1998.

9. Regressão para precipitação decendial

Segundo Dugdale et al. (1991) as estimativas de precipitação feitas sem o auxílio de operações de vizinhança provavelmente apresentam maior utilidade quando feitas para

períodos de acúmulo da precipitação ao entorno de 10 dias. Como as distribuições espaciais e temporais da precipitação são de natureza essencialmente aleatória, o aumento do número de eventos considerados ocasiona uma diminuição na variabilidade da precipitação quando se analisa o montante acumulado da precipitação.

Nesta regressão foram utilizados apenas 19 períodos decendiais (dentre os 36 possíveis) devido aos dias com imagens faltantes. Ressalta-se que os períodos considerados são compostos unicamente por dias seqüenciais, desprezando-se os períodos que contenham dias com imagens faltantes.

Ao contrário da regressão para a precipitação diária, na amostra utilizada para a regressão decendial incluem-se os erros de reconhecimento do algoritmo e os elementos nulos, isto porque estes estão presentes em todos os 19 períodos, tornando impossível a sua remoção (sob pena de torná-los incomparáveis entre si). Os resultados numéricos obtidos encontram-se na **tabela 3** e a **figura 4** ilustra graficamente o modelo matemático obtido.

Modelo e Indicadores Estatísticos	
R	0,6794
R ²	0,4616
F _{calculado}	2311
ĕ _{modelo}	99,95%
Modelo	$P = 26,649 + 6,3387 \times 10^{-10} \cdot (IR_{decendial})^2$

Tabela 3: Modelo matemático para a precipitação decendial. R é o coeficiente de correlação, R² é o coeficiente de determinação, F é a estatística de Fisher, ĕ_{modelo} é a significância alcançada pelo modelo e P é a precipitação decendial estimada (mm)

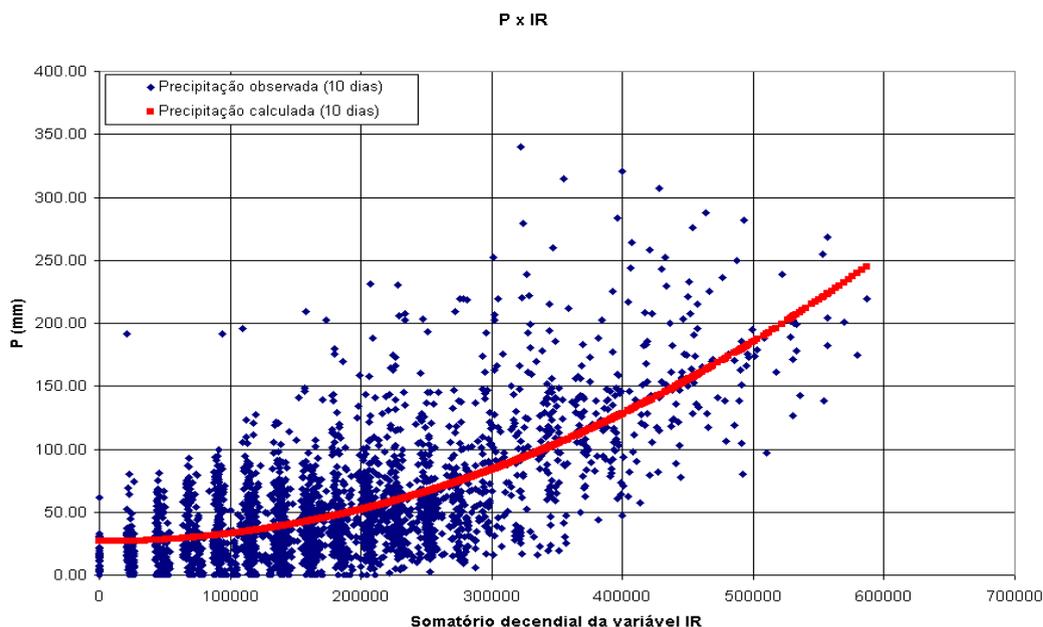


Figura 4: Representação das faixas de variação de IR_{decendial} e da precipitação calculada.

A imagem decendial representa a soma de 80 imagens horárias (8 imagens horárias compõem uma imagem diária) ou das 10 diárias produzidas no período. O modelo é aplicado de forma integral, em toda a imagem decendial. A **figura 5** representa a estimativa de precipitação decendial para o período de 03 a 12 de janeiro de 1998 (das 8:00h do dia 02 às 08:00h do dia 12), tendo sido calculada através do modelo expresso na **tabela 3**.

10. Fontes de erro

Na presente configuração do conjunto algoritmo/modelo, várias fontes de erro podem ser apontadas como atuantes, sendo as principais as seguintes: a relativa incapacidade do algoritmo em reconhecer nuvens cirriformes em altitudes elevadas (especialmente as noturnas), baixas precisões temporal (3 horas) e espacial (4 km) das imagens, ruídos nas imagens (apesar do filtro de média empregado), falta de precisão no processo de georreferenciamento; efeito do vento (deslocamento horizontal da água durante a sua queda), eventuais erros nos dados dos postos pluviométricos e a má distribuição espacial dos mesmos.

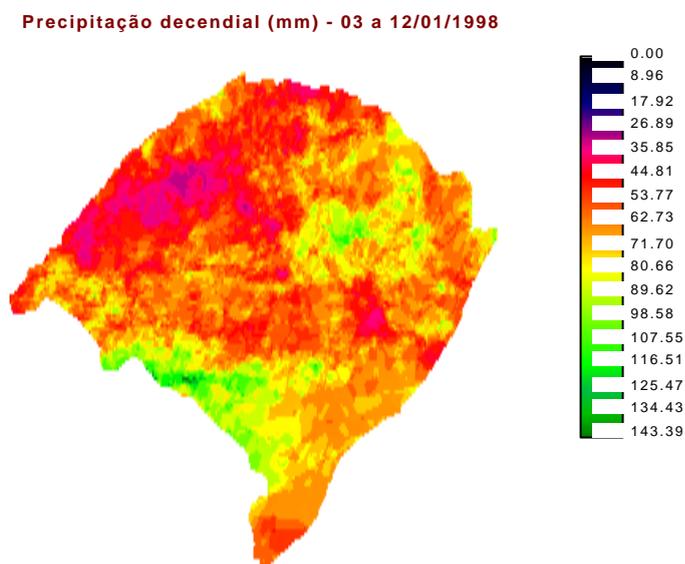


Figura 5: Estimativa de precipitação decenal.

11. Conclusão

Comparando-se os coeficientes de correlação obtidos para as regressões realizadas, pode-se concluir que na atual configuração (especialmente devido a resolução temporal de 3 horas) do conjunto algoritmo/modelo, este é mais indicado para a precipitação decenal. Apesar disso, os coeficientes de correlação obtidos para a precipitação diária foram considerados compatíveis com as técnicas empregadas e com os dados disponíveis.

Por mais progressos que ocorram, as técnicas de sensoriamento remoto jamais poderão fornecer todas as respostas e, desta forma, as estimativas da precipitação com tais técnicas devem ser tomadas como complementares às convencionais. A melhor estratégia para o difícil problema de estimar a precipitação em todas as escalas espaciais e temporais deve ser o uso conjunto de todos os dados disponíveis de solo, radar e de satélites.

Referências

- Barret E. C., C. H. Power e A. Micallef (1990): Remote sensing for hidrology and water management: the Mediterranean coasts and islands. In proceedings of Internacional Training Course sponsored by the Council of Europe, Malta, 2 a 12 de outubro de 1988, 340p.
- Dugdale G., Hardy S., Milford J. R. (1991): Daily Catchment Rainfall Estimated from Meteosat. Hidrological Processes, v. 5, p 261-270, mai. 1991.
- Fórum de Previsão Climática Regional para o Sudoeste da América do Sul, Foz do Iguaçu, 16 jun.1998. Prognóstico Climático. Disponível em: <http://www.inmet.gov.br/climato/prog_clim.htm> Acesso em 10 jan. 2002.
- Rosenfeld D., Lensky I. M. (1998): Satellite based insights into precipitation Formation processes in continental and maritime convective clouds. Bulletin of the American Meteorological Society, v. 79, n. 11, p. 2457-2475, nov. 1998.
- Tucci C. E. M., Bertoni J. C. (2000): Precipitação. In: Hidrologia: ciência e aplicação. Associação Brasileira de Recursos Hídricos, 2 ed. Porto Alegre, 943p.
- Ellrod G. P., Achutuni R. V., Daniels J. M., Prins E. M., Nelson J. P. (1998): An Assessment of GOES-8 Imager Data Quality. Bulletin of the American Meteorological Society, v. 79, n. 11, p. 2509-2526, nov. 1998.