
USO DO TRMM PARA A CORREÇÃO ESTATÍSTICA DA CHUVA PREVISTA PELO MODELO BRAMS

SIMONE PEREIRA FERREIRA

FLAVIO VARONE

RITA DE CÁSSIA MARQUES ALVES

Universidade Federal do Rio Grande do Sul – CEPSRM/UFRGS
Fundação Estadual de Pesquisa Agropecuária – FEPAGRO/ CEPSRM/UFRGS
Universidade Federal do Rio Grande do Sul – CEPSRM/UFRGS
simonepferreira@yahoo.com.br, fvarone@gmail.com, rita.cma@terra.com.br

RESUMO – A chuva é uma das variáveis, previstas por modelos numéricos de previsão do tempo, mais importante. Ela influencia em setores produtivos e na segurança e bem estar da população. Apesar da sofisticação e confiabilidade dos modelos numéricos, eles ainda apresentam limitações. Por isso, foram desenvolvidos modelos estatísticos para aprimorar os resultados. Neste trabalho está sendo apresentada uma alternativa para os dados observados utilizados nos métodos estatísticos, a utilização da estimativa de chuva do algoritmo 3B42 do TRMM.

ABSTRACT - Rainfall is one of the most important variables predicted by numerical weather prediction model that influences productive sector and welfare of the population. Despite the sophistication and reliability of numerical models, they still have limitations. Therefore, statistical models were developed to improve the results. This paper presents an alternative to the observed data used in statistical methods, the use of rainfall estimation from TRMM 3B42 algorithm.

1. INTRODUÇÃO

A Previsão numérica do tempo consiste na integração numérica de sistemas de equações que simulam os processos físicos, dinâmicos e termodinâmicos em relação ao tempo para simular os processos atmosféricos. A previsão ou estimativa de campos e fenômenos meteorológicos é uma tarefa complexa. Os modelos numéricos de previsão do tempo são capazes de prever diversas variáveis: temperatura, umidade, pressão, chuva e outras utilizadas por meteorologistas na previsão do tempo. Dentre essas, a chuva é uma das mais importantes por influenciar em setores produtivos e na segurança e bem estar da população.

O BRAMS (*Brazilian developments on the Regional Atmospheric Modelling System*) é um modelo de mesoescala (Freitas et al., 2009). É baseado no modelo atmosférico RAMS (Walko et al., 2000), com principal objetivo de adaptá-lo para os trópicos. Os modelos de mesoescala possuem espaçamento de grade reduzida em relação aos modelos globais, o que faz com que representem fenômenos típicos desta magnitude. Esses modelos geralmente são aplicados a estudos ou previsões de tempo em escala regional ou local. O comportamento dos modelos pode variar dependendo da estação do ano, da região, do horário inicial de integração, da resolução, e também da quantidade de observações assimiladas pelo modelo. Algumas variáveis previstas pelos modelos já possuem alto grau de precisão, enquanto outras, como a chuva não apresentam resultados plenamente satisfatórios em alguns modelos numéricos de previsão do tempo (Ferreira, 2011).

Apesar da sofisticação e confiabilidade dos modelos numéricos, eles ainda apresentam limitações, principalmente, na representação de fenômenos locais e de pequena escala que não podem ser resolvidos explicitamente. Os modelos apresentam erros intrínsecos em suas soluções. Esses erros têm várias causas, entre elas, pode-se citar: imperfeições do método numérico, resolução da grade, entre outros. As metodologias matemáticas, estatísticas e dinâmicas desenvolvidas têm minimizado em parte o problema, porém, há necessidade de se explorar novas técnicas com o intuito de aprimorar as previsões e estimativas. Alguns métodos estatísticos foram criados para tratar esses erros. Os principais métodos estatísticos que utilizam métodos de regressão multivariada são: “*Perfect Prog Method*” - PPM (Klein et al., 1959), o “*Model Output Statistics*” - MOS (Glahn e Lowry, 1972) e “*Model Output Calibration*” - MOC (Mao et al., 1998).

Os satélites meteorológicos são uma alternativa para monitorar a chuva em grande escala. Inicialmente a chuva começou a ser estimada de forma indireta, identificada pela temperatura de brilho do topo da nuvem (Adler e Negri, 1988). Estudos mostram que a combinação de sensores pode melhorar a acurácia, cobertura e resolução dos dados. O algoritmo 3B42 do *Tropical Rainfall Measuring Mission* (TRMM) é um exemplo dessa combinação (Huffman et al., 2003). Combina estimativas de precipitação dos sensores do TRMM: *Special Sensor Microwave Imager* (SSM/I), *Advanced Microwave Scanning Radiometer* (AMSR-E) e o *Advanced Microwave Sounding Radiometer* (AMSU-B). As estimativas pelo 3B42 estão disponíveis em grades de $0,25^\circ \times 0,25^\circ$ a cada 3 horas.

O propósito deste trabalho é determinar a possibilidade de utilizar dados do TRMM (3B42), no lugar dos dados observados, com o MOC para fazer correções estatísticas do modelo BRAMS. O MOC utiliza dados observados para montar as equações de regressão multivariada. A utilização do método fica restrita a localidades que possuam estações meteorológicas. Com a possibilidade de utilizar dados estimados por satélite fica ampliada a área de aplicação do método estatístico.

De acordo com Sugahara (2000) os métodos estatísticos que utilizam equações de regressão e saídas do modelo como preditores são utilizadas operacionalmente em vários países como Estados Unidos, Austrália, Canadá, Japão e Holanda. Na Austrália, em 1984, foram utilizadas para ajustar as temperaturas máxima e mínima diárias, probabilidade de ocorrência e quantidade de precipitação. Na Holanda, para a previsão de probabilidades de tempestade e de precipitação congelada, brilho solar, temperaturas máxima e mínima do ar e velocidade máxima do vento. O MOS e o MOC foram testados por Ferreira (2011) em oito localidades no Rio Grande do Sul para as variáveis temperatura da superfície, umidade relativa, pressão à superfície e chuva acumulada em 1h com resultados satisfatórios. O MOC foi testado por Tozzi e Silva (2002) para a variável temperatura (6 e 18h) em Cuiabá, Belo Horizonte e Porto Alegre. Outros trabalhos que utilizam métodos para calibração/ajuste de modelos podem ser encontrados em: Baars e Mass, (2005); Brunet et al. (1998); Chou et al. (2007); Gneiting et al. (2005); Hart et al. (2004); Kim et al. (1998a); Kim et al. (1998b); Silveira e Mol (2006) e Vislocky e Young (1989).

A estimativa de precipitação do TRMM (3B42) tem sido discutida em vários trabalhos. Leivas et al (2011) avaliaram as previsões do modelo BRAMS para chuva e os dados estimados pelo TRMM na Amazônia com resultados satisfatórios. Vianna et al (2011) testaram na região Sul encontrando um r (coeficiente de correlação) médio de 0,74. Hand e Shepherd (2009) avaliaram o produto em Oklahoma (EUA) e obtiveram r igual 0,42. Collischonn et al. (2007) avaliaram na bacia do rio Paraguai e encontraram r entre 0,25 e 0,64, considerado aceitável pelos autores. O estudo também mostrou que existe uma tendência do satélite superestimar a precipitação em torno de 8%.

O restante do artigo está organizado da seguinte maneira. A seção 2 apresenta alguns conceitos básicos, discute trabalhos relacionados e mostra a metodologia utilizada. A seção 3 apresenta os resultados obtidos, enquanto a seção 4 conclui o trabalho.

2. MATERIAL E MÉTODOS

As previsões utilizadas neste trabalho são do modelo BRAMS operacional do Laboratório de Meteorologia e Qualidade do Ar do Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia da Universidade Federal do Rio Grande do Sul (LMQA/CEPSRM/UFRGS). As simulações foram executadas, em paralelo, utilizando o modelo BRAMS 4.2 em um *cluster Sun Fire X2200*, instalado no Centro Nacional de Supercomputação (CESUP/UFRGS). Para inicializar o modelo BRAMS foram utilizadas as análises do modelo global T213L42 do CPTEC/INPE com resolução de 63×63 km. Os experimentos foram realizados com uma grade centrada na latitude $-30,0$ e longitude $-50,0$ com espaçamento horizontal de 12 km e 88 pontos na direção horizontal (x) e 76 na vertical (y). Essas configurações são da previsão de 24h para todo o estado do Rio Grande do Sul (Figura 1).

O pós-processamento das previsões é realizado para fazer ajustes nas saídas e para gerar produtos gráficos das previsões. As previsões do modelo são por vezes utilizadas como entrada para métodos estatísticos podendo assim gerar previsões para locais específicos. Os resultados são pontuais. Neste trabalho é testado o *Model Output Calibration* (Mao et al., 1998). Esse método estima o erro de previsão da variável. A ideia principal é que o erro da previsão pode, nos últimos dias, ter sofrido influência de algumas variáveis do modelo e que isto poderá ocorrer nos próximos dias. O período de treinamento adotado foi de 28 dias, de 29 de maio até 04 de julho de 2010, nesse intervalo havia dados faltosos na série, tanto das estações quanto do modelo. O ponto escolhido para testar o método está localizado nas coordenadas $31,3478^\circ\text{S}$ e $54,0133^\circ\text{O}$ (Figura 1). Esse ponto está localizado na estação meteorológica automática do INMET (Instituto Nacional de Meteorologia) no município de Bagé (RS).

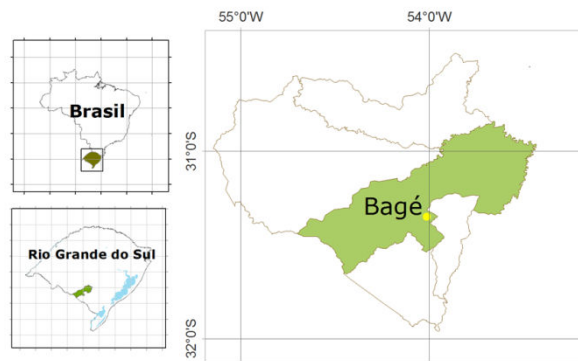


Figura 1 – Área de estudo - município de Bagé (RS). Localização da estação do INMET em amarelo.

1.1 Desenvolvimento das equações do MOC

Esta seção é uma adaptação de Mao et al. (1998). Para facilitar a compreensão foi trocada a variável temperatura por chuva, utilizada nesse trabalho. As equações abaixo descritas podem ser utilizadas para diversas variáveis previstas por qualquer modelo numérico de previsão do tempo.

Seja $C_{ij}(k)$ com ($k = 1, 2, \dots, N$) uma série de previsões de chuva recente do modelo numérico de previsão do tempo com tamanho N no ponto de grade (i, j) e $C_{ij}^o(k)$ a série de dados observados, o erro da previsão é dado pela equação 1.

$$\Delta C_{ij}(k) = C_{ij}(k) - C_{ij}^o(k) \quad (1)$$

Neste trabalho os valores consecutivos de k são intervalos de 3h (saídas do modelo numérico ou neste caso dados do algoritmo 3B42 do TRMM). Assumindo que $\Delta C_{ij}(k)$ está associado a várias variáveis e parâmetros do modelo, então $\Delta C_{ij}(k)$ deve ser uma função de $X_{ij,l}(k)$; isto é:

$$\Delta C_{ij}(k) = f(X_{ij,l}(k)) \quad (2)$$

onde $k = 1, 2, \dots, N$; $l = 1, 2, \dots, n$ e $X_{ij,l}(k)$ é a k -ésima variável obtida ou derivada do modelo no mesmo ponto de grade (i, j). O índice l (2) está relacionado com a quantidade de variáveis geradas pelo modelo numérico e que serão utilizadas como preditores da equação de regressão. A equação de regressão linear gerada a partir da função f da equação (2) é:

$$\Delta C_{ij}(k) = \alpha_0 + \sum_{l=1}^n \alpha_l X_{ij,l}(k) \quad (3)$$

Uma vez que os coeficientes α_0 e α_l são conhecidos, o erro da previsão do modelo pode ser estimado pela equação (3). A previsão corrigida ($\tilde{C}_{ij}(k)$), após a calibração, é obtida a partir de:

$$\tilde{C}_{ij}(k) = C_{ij}(k) - \Delta C_{ij}(k) \quad (4)$$

A equação de regressão linear múltipla é gerada pelo método *Stepwise* para selecionar os preditores. A análise de regressão *Stepwise* é provavelmente a técnica mais utilizada de seleção de variáveis. O procedimento constrói iterativamente uma sequência de modelos de regressão pela adição ou remoção de variáveis em cada etapa. O critério para adicionar ou remover uma variável em qualquer etapa é geralmente expresso em termos de um teste parcial F (Wilks, 2006; Montgomery et al., 2001; Neter et al., 2004). Por esse método, é gerada uma equação para cada simulação do modelo, neste caso 24h.

1.2 Preditores das equações

Neste estudo não são levadas em consideração as relações físicas entre preditando e preditores, somente a relação estatística. Foram utilizadas todas as variáveis geradas pelo modelo BRAMS no período simulado, assim como, não foram testadas as diferentes parametrizações que podem ser feitas no Modelo. Na Tabela 1 são descritas todas as variáveis, a quantidade de níveis na vertical (1000, 850, 700, 500 e 200 hPa), seu significado e a unidade com que são representadas.

Tabela 1 – Variáveis do modelo BRAMS utilizadas como preditores

variável	níveis na vertical	significado	unidade
u10m; v10m	0	componentes <i>u</i> e <i>v</i> do vento 10 m	m/s
t2m	0	temperatura do ar 2 m	°C
tempc	5	temperatura	°C
rh	5	umidade relativa	%
u; v	5	componentes <i>u</i> e <i>v</i> do vento	m/s
sea_press	0	pressão atmosférica ao nível do mar	hPa
zitheta	0	altura da camada limite	sigma
accon	0	precipitação convectiva acumulada	mm
rv2m	0	taxa de vapor d'água 2 m	g/kg
td2m	0	temperatura do ponto de orvalho 2 m	°C
tveg2	0	temperatura da vegetação	°C
theta	5	temperatura potencial	K
precip	0	precipitação acumulada total	mm liq
le	0	fluxo de calor latente	W/m ²
rshort	0	radiação onda curta	W/m ²
rlong	0	radiação onda longa incidente	W/m ²
albedt	0	albedo	
rlongup	0	radiação onda longa refletida	W/m ²
press2m	0	pressão em 2 m	hPa
geo	5	altura geopotencial	m
press	5	pressão atmosférica	hPa
cape	0	cape (índice de instabilidade - tempestade)	J/kg
cine	0	cine (índice de instabilidade - tempestade)	J/kg
dewptc	5	temperatura do ponto de orvalho	°C
sst	0	temperatura superfície do mar	°C
totpep	0	precipitação total	mm liq
rh2m	0	umidade relativa 2 m	%
pcpr	0	taxa de precipitação	mm/h

1.3 Índices de avaliação

O Viés (eq. 5) é conhecido como erro médio, mostra o desvio médio (ou tendência) do modelo em relação a uma variável. Pode apresentar resultados positivos (superestima) ou negativos (subestima). Quanto mais próximo de zero, melhor o resultado (Wilks, 2006). Nas equações 5 e 6 p_n é o dado previsto e o_n observado.

$$Viés = \frac{1}{N} \sum_{n=1}^N (p_n - o_n) \quad (5)$$

A Raiz do Erro Quadrático Médio (REQM), na equação 6, é uma medida de precisão, eleva ao quadrado a diferença entre os valores previstos e observados, é mais sensível a erros. Será sempre um valor positivo. Trata igualmente os resultados positivos e negativos, pois eleva as diferenças ao quadrado. O valor zero indica uma previsão perfeita e este valor aumenta conforme aumenta a diferença entre valores de previsão e observação (Wilks, 2006).

$$REQM = \sqrt{\frac{1}{N} \sum_{n=1}^N (p_n - o_n)^2} \quad (6)$$

Tanto o Viés quanto o REQM apresentam os resultados nas mesmas unidades das variáveis que estão sendo testadas. O *Skill Score* (SS) é calculado para refletir a percentagem de melhora do modelo ajustado sobre o não ajustado (eq. 7) (Wilks, 2006).

$$SS = \left(\frac{Erro_{modelo} - Erro_{corrigido}}{Erro_{modelo}} \right) * 100 \quad (7)$$

1.4 Equações do modelo estatístico

Os dados do modelo BRAMS e do TRMM utilizados para calcular o erro da previsão da chuva são os do ponto de grade mais próximo ao da estação automática do INMET instalada no município de Bagé (RS).

Foram selecionados os modelos (equações de regressão linear) que utilizavam até três preditores, pois um número maior dificultou a construção da equação de regressão. Algumas vezes a solução, com mais de três preditores, utilizando os dados de teste, não apresentavam a mesma eficácia do que a gerada com os dados de treinamento. Foram realizados os testes para identificar a presença da multicolinearidade, os coeficientes da equação de regressão, os testes t ($\alpha = 0,05$) e o p-valor, que indicam o impacto de cada variável preditora, foram excluídas aquelas que apresentaram p-valor > 0,05. Também foram calculados os coeficientes de determinação (r^2) e o de determinação ajustado (r_{aj}^2) e foram feitas as análises dos gráficos de probabilidade normal dos resíduos e resíduos contra valores preditos. Todos os testes mencionados anteriormente foram realizados para assegurar a qualidade da equação de ajuste do modelo.

Nas equações geradas com os dados observados foram utilizados os seguintes preditores: taxa de precipitação, componente v do vento em 200 hPa, umidade relativa em 700 hPa, e umidade relativa em 500 hPa. Nas do TRMM foram: taxa de precipitação, cape, componente v do vento em 200 hPa, componente v do vento em 850 hPa e umidade relativa em 500 hPa.

3. RESULTADOS E DISCUSSÕES

Os resultados da

Tabela 2 foram calculados em relação aos dados observados na estação do INMET. O modelo BRAMS foi simulado para previsão de 24h. Na linha TRMM é feita a comparação dos dados estimados pelo algoritmo 3B42 em relação aos observados. No MOC da estação o erro da previsão (eq. 1) da chuva foi calculado em relação aos dados da estação meteorológica e no MOC TRMM foi em relação aos dados estimados pelo algoritmo 3B42.

Primeiro foi realizado o teste F para comparar as variâncias, todas as quatro séries apresentaram variâncias diferentes dos dados observados, o p-valor é muito menor que 0,05 e os resultados dos testes F maiores do que o F_{tabela} (1,270307).

Embora o modelo BRAMS tenha apresentado resultados satisfatórios (

Tabela 2) com Viés igual -0,42 mm/h e a REQM igual 1,97 mm/h. Quando foi feito o teste Z, para comparar as médias, os resultados indicaram ao nível de significância (α) de 0,05 que as médias são diferentes. O $Z_{calculado}$ (2,848) é maior que o Z_{tabela} (1,9599). e o p-valor (0,0044) é menor que α (0,05). O Z_{tabela} é o mesmo para todos os testes, pois o tamanho da amostra é o mesmo (191). Os testes Z realizados são bicaudal para testar a hipótese nula (H_0) que as médias são iguais e H_1 diferentes. Para uma maior acurácia nos resultados da chuva prevista para uma hora pelo modelo BRAMS se faz necessária a utilização de alguma metodologia para aperfeiçoar a previsão.

O TRMM (3B42) é subestimado em 0,17 mm/h (

Tabela 2). Viana et al. (2011) e encontraram para o Rio Grande do Sul o valor médio do Viés superestimado em 0,5 mm/dia. Essa diferença pode-se dar pelo tamanho da amostra, o período de teste ou os pontos em que foram testados. O coeficiente de Pearson foi 0,79, o que representa que existe correlação entre os dados testados. Isso pode ser comprovado pelo $Z_{calculado}$ e p-valor. O $Z_{calculado}$ foi igual a 0,671 que é menor que o Z_{tabela} (1,9599). O p-valor é 0,5, que é maior que o nível de significância de 0,05, assim pode-se aceitar hipótese nula (H_0) de igualdade das médias. Com

base nesses resultados foi possível utilizar os dados do TRMM como se fossem os dados observados para gerar as equações do MOC.

O *Skill Score* (SS) obtido pelo MOC estação foi 2,52%, o que demonstra que o método melhorou a saída do modelo. O Viés foi subestimado (-0,19 mm/h) e a REQM foi 1,92 mm/h o que pode ser considerado satisfatório. Mesmo o *r* sendo 0,28, correlação fraca, o teste F e o *p*-valor, ao nível de significância de 5%, indicam que a hipótese nula pode ser aceita.

O MOC TRMM, calculado com os dados estimados pelo algoritmo 3B42, apresentou o SS igual 36,49% e um Viés subestimado em 0,05. Esses resultados obtidos com a variável chuva são promissores, mesmo que pontualmente. Ao nível de significância de 0,05 é possível aceitar a hipótese nula de igualdade das médias, pois o $Z_{\text{calculado}}$ é menor que o tabelado e o *p*-valor é maior que o nível de significância.

Tabela 2 – Resultados dos testes estatísticos em relação aos dados observados.

	Viés	REQM	SS	Teste F	p-valor	Teste Z	p-valor	r
BRAMS	-0,42	1,97		59,108	0,0000	2,848	0,0044	0,31
TRMM	-0,17	1,88		2,156	0,0000	0,671	0,5016	0,79
MOC estação	-0,19	1,92	2,52%	16,713	0,0000	1,262	0,2067	0,28
MOC TRMM	-0,05	1,25	36,49%	18,823	0,0000	1,153	0,2489	0,37

A Figura 2 mostra a previsão de chuva do modelo BRAMS para o período de teste em comparação aos dados observados na estação do INMET para o mesmo período. Nela é possível verificar que o modelo tem dificuldade para prever os picos de chuva.

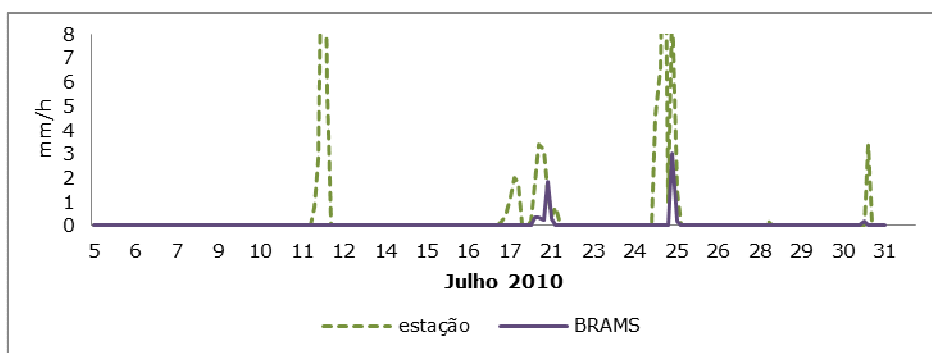


Figura 2 – Comparação entre o modelo BRAMS e os dados da estação do INMET em Bagé (RS) em Julho de 2010

A chuva estimada pelo algoritmo 3B42 do TRMM acompanha o comportamento da chuva na estação (Figura 3). Pode-se observar que existe uma tendência em subestimar valores, conforme é observado no Viés (

Tabela 2). Mesmo sendo uma estimativa, pela análise do gráfico, verifica-se que é possível utilizar esses dados em substituição a dados observados. Outros trabalhos, já citados, corroboram com essa constatação.

O MOC estação (Figura 4) conseguiu acompanhar os eventos de chuva após o dia 15. Entre os dias 11 e 12 de Julho a correção não indicou chuva, assim como o BRAMS (A Figura 2). Nota-se que tanto o BRAMS quanto o MOC estação não conseguiram estimar a quantidade de chuva ocorrida nos eventos maiores que quatro mm/h.

Na Figura 5 observa-se que o MOC TRMM conseguiu corrigir o modelo para prever o primeiro evento de chuva, no dia 11/7. Assim como o MOC estação também indicou a ocorrência de chuva nas outras datas e também subestimou a quantidade de chuva.




Figura 3- Comparação entre as estimativas de chuva do algoritmo 3B42 do TRMM e os dados da estação do INMET em Bagé (RS) em Julho de 2010

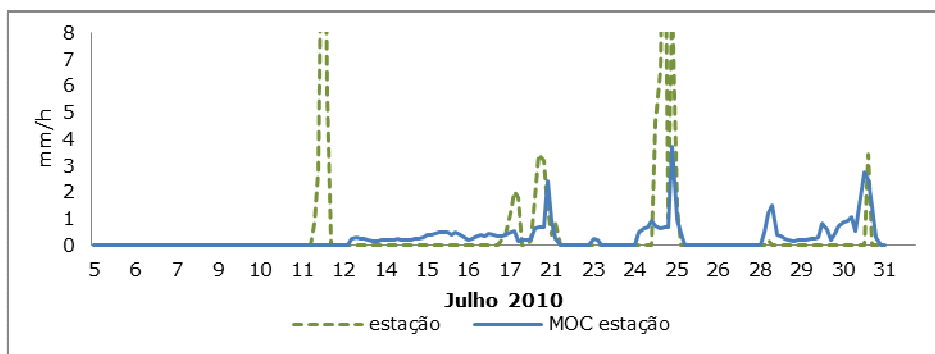


Figura 4 – Comparação entre a previsão corrigida utilizando os dados observados e os dados da estação do INMET em Bagé (RS) em Julho de 2010




Figura 5 - Comparação entre a previsão corrigida utilizando os dados do algoritmo 3B42 do TRMM e os dados da estação do INMET em Bagé (RS) em Julho de 2010

4. CONCLUSÕES

Neste trabalho se avaliou a possibilidade de utilizar os dados de chuva estimados pelo algoritmo 3B42 do TRMM no lugar de dados observados utilizados em modelos estatísticos para apurar a previsão de modelos numéricos de previsão do tempo.

Os resultados demonstram que o *Model Output Calibration* corrigido com o TRMM apresentou resultados plenamente satisfatórios. Os testes estatísticos comprovam a qualidade dos resultados obtidos com a correção. O *Skill Score* foi 36,49%, bem superior ao resultado obtido com os dados observados, essa diferença se deve às equações geradas que são diferentes para os dois métodos. Com a abrangência dos dados do TRMM será possível a aplicação do *Model Output Calibration* em localidades onde não se tenha dados observados. Sugere-se que o método seja aplicado em previsões de médio prazo (até uma semana).

REFERÊNCIAS

- ADLER, R. F.; A. J. NEGRI, A., Satélite infrared technique to estimate tropical convective and stratiforme rainfall. , **J. Appl. Meteorol**, v. 27, n. 1, p. 31-51, 1988.
- BAARS, J. A. AND C. F. MASS, 2005: Performance of National Weather Service forecasts compared to operational, consensus, and weighted model output statistics. **Weather and Forecasting**, 1034-1047, Dec 2005.
- BRUNET, N.; VERRER, R.; YACOWAR, N. An objective comparison of model output statistics and perfect prog system in producing numerical weather element forecasts. **Weather and Forecasting**, v. 3, p. 273–283, 1998.
- CHOU, S. C.; SOUZA, C. R. d.; GOMES, J. L.; EVANGELISTA, E. F.; OSÓRIO, C.; CATALDI, M. Refinamento estatístico das previsões horárias de temperatura a 2m do modelo ETA em estações do nordeste do brasil. **Revista Brasileira de Meteorologia**, v. 22, n. 3, p. 287–296, 2007.
- COLLISCHONN, B.; ALLASIA, D.; COLLISCHONN, W.; TUCCI, C.E.M. Desempenho do satélite TRMM na estimativa de precipitação sobre a bacia do Paraguai superior. **Revista Brasileira de Cartografia**, 59. 2007.
- FERREIRA, S. P. **Estudo comparativo entre o modelo dinâmico BRAMS e os modelos estatísticos MOS e MOC**. Dissertação de Mestrado, CEPSSRM/UFRGS, Porto Alegre RS, 2011.
- FREITAS, S.R.; LONGO, K. M.; SILVA DIAS, M. A. F. The Coupled Aerosol and Tracer Transport model to the Brazilian developments on the Regional Atmospheric Modeling System (CATT-BRAMS) – Part I: Model description and evaluation. **Atmos. Chem. Phys.**, 9, 2843–2861, 2009.
- GLAHN, H. R.; LOWRY, D. A. Use of model output statistics (MOS) in objective weather forecasting. , **J. Appl. Meteorol**, v. 11, n. 8, p. 1203–1211, Dec 1972
- GNEITING, T.; RAFTERY, A. E.; III, A. H. W.; GOLDMAN, T. Calibrated probabilistic forecasting using ensemble model output statistics and minimum crps estimation. **Monthly Weather Review**, v. 133, p. 1098–1118, 2005.
- HAND, L. M.; SHEPHERD, J. M. An investigation of warm season spatial rainfall variability In Oklahoma city: possible linkages to urbanization and prevailing wind. **J. Appl. Meteorol. Climatol.**, 48 (2), p. 251-269, 2009
- HART, K. A.; STEENBURGH, W. J.; ONTON, D. J.; SIFFERT, A. J. An evaluation of mesoscale model based model output statistics (mos) during the 2002 olympic and paralympic winter games. **Weather and Forecasting**, v. 19, p. 200–218, 2004.
- KIM, I. S.; CALVETTI, L.; PRESTES, S. D.; SIMONETTI, C. Aplicação do mos para previsão da temperatura mínima até 72 horas no estado do rio grande do sul. In: **Anais do X Congresso Brasileiro de Meteorologia**. [S.l.]: SBMET, 1998.
- KIM, I. S.; QUADRO, M. F. L. d.; MARENGO, J. A. Sobre interpretação estatística da saída do modelo numérico. In: **Anais do X Congresso Brasileiro de Meteorologia**. [S.l.]: SBMET, 1998.
- KLEIN, B.; LEWIS, M.; ENGER, I. Objective prediction of 5 day mean temperature during winter. **Journal of Meteorology**, v. 16, n. 6, p. 672–682, 1959.
- LEIVAS, Janice Freitas et al . Avaliação dos prognósticos de precipitação simulada pelo modelo BRAMS na Amazônia Ocidental na estação chuvosa. **Acta Amaz.**, Manaus, v. 41, n. 3, 2011.
- MAO, Q.; MCNIDER, R. T.; MUELLER, S. F.; JUANG, H.-M. H. An optimal model output calibration algorithm suitable for objective temperature forecasting. **Weather and Forecasting**, v. 14, n. 2, p. 190–202, 1999.
- MONTGOMERY, D. C.; PECK, E. A.; VINING, G. G. **Introduction to Linear Regression Analysis**. 3. ed. [S.l.]: Wiley-Interscience, 2001. 641 p.
- NETER, J.; KUTNER, M.; NACHTSHEIM, C.; LI, W. **Applied Linear Statistical Models**. 5. ed. New York: Mc Graw-Hill/Irwin, 2004. 1396 p.
- SILVEIRA, R. B. d.; MOL, J. M. D. Alternativa para determinar acurácia da previsão do MBAR utilizando Índice de brier. In: **Anais do XIV Congresso Brasileiro de Meteorologia**. [S.l.]: SBMET, 2006.
- SUGAHARA, S. Uma experiência com modelo estatístico (MOS) para a previsão da temperatura mínima diária do ar. **Revista Brasileira de Geofísica**, scielo, v. 18, p. 3–12, 2000.
- VIANA, D. R.; FERREIRA, N. J.; CONFORTE, J. C. Avaliação das estimativas de precipitação 3B42 e 3B43 do satélite TRMM na Região Sul do Brasil. In: **Anais do XVI Congresso Brasileiro de Meteorologia**, 16., 2010, Belém, PA. Anais... 2010.
- VISLOCKY, R. L.; YOUNG, G. S. The use of perfect prog forecasts to improve model output statistics forecasts of precipitation probability. **Weather Forecasting**, v. 4, p. 203–209, 1989.

WALKO, R., BAND, L., BARON, J., KITTEL, F., LAMMERS, R., LEE, T., OJIMA, D., PIELKE, R., TAYLOR, C., TAGUE, C., TREMBACK, C., AND VIDALE, P. Coupled atmosphere-biophysics-hydrology models for environmental modeling, **J. Appl. Meteorol.**, 39, 6, 931–944, 2000.

WILKS, D. **Statistical Methods in the Atmospheric Sciences**. 2. ed. [S.l.]: Academic Press, 2006. 627 p. (International Geophysics Series, v. 59).