ISSN:1984-2295

Revista Brasileira de Geografia Física

Homepage: <https://periodicos.ufpe.br/revistas/rbgf>

Precipitação e temperatura do ar simuladas pelo modelo ETA/CPTEC - HADCM3 para o estado do Rio de Janeiro

Fernanda da Silva Pinheiro¹; Ednaldo Oliveira dos Santos²; Gustavo Bastos Lyra³; Gilberto Fernando Fisch⁴; Henderson Silva Wanderley⁵

¹ Engenheira Florestal, Universidade Federal Rural do Rio de Janeiro, Rodovia BR 465, km 07, s/n Zona Rural, CEP 23897-000, Seropédica - RJ, (21) 99211-4197. nandaah_pinheiro@hotmail.com. ² Professor Associado (autor correspondente), Departamento de Ciências Ambientais, Instituto de Florestas, Universidade Federal Rural do Rio de Janeiro, Rodovia BR 465, km 07, s/n Zona Rural, CEP 23897-970, Seropédica - RJ, (21) 2681-4984. edmeteoro@hotmail.com. ³ Professor Associado, Departamento de Ciências Ambientais, Instituto de Florestas, Universidade Federal Rural do Rio de Janeiro, Rodovia BR 465, km 07, s/n Zona Rural, CEP 23897-970, Seropédica - RJ, (21) 2681-4984. gblyra@gmail.com. ⁴ Professor Titular, Universidade de Taubaté, Departamento de Ciências Agrárias, (12) 39364000, gilberto.fisch@unitau.br. ⁵ Professor Adjunto, Departamento de Ciências Ambientais, Instituto de Florestas, Universidade Federal Rural do Rio de Janeiro, Rodovia BR 465, km 07, s/n Zona Rural, CEP 23897-970, Seropédica - RJ, (21) 2681-4984. hendynho@gmail.com.

Artigo submetido em 20/12/2019 e aceite em 12/06/2020

RESUMO

O trabalho avaliou simulações de precipitação e temperatura do ar do modelo Eta-CPTEC para o Rio de Janeiro de 1961-1990. Nas simulações, considerou-se resolução espacial de 40 km para uma grade que compreendeu a América do Sul, com o Eta-CPTEC inicializado com o modelo HadCM3. As séries climáticas observadas das variáveis estudadas foram obtidas de estações meteorológicas do INMET distribuídas no estado do Rio de Janeiro. Estas séries foram comparadas com aquelas extraídas dos pontos de grade do modelo mais próximas das estações. Nas avaliações considerou-se o coeficiente de determinação (r^2) da regressão linear simples entre dados observados e simulados; o índice de concordância de Willmott (d), o índice de desempenho (c) e a Raiz do Quadrado Médio do Erro (RQME) e seus componentes sistemático (RQME_s) e não sistemático (RQME_u). As simulações de precipitação apresentaram r^2 menores do que 0,32, o que indicou baixa precisão, enquanto que a exatidão (d) foi superior a 0,50, com exceção de Bangu (0,16). A baixa precisão comprometeu o desempenho (c) das simulações, com $0,07 \leq c \leq 0,42$, classificados entre "péssimo" e "ruim". A RQME variou entre 76,2 e 133,4 mm, que correspondeu a um erro de 78,1 e 115,5% em relação à precipitação média. As simulações de temperatura do ar mostraram desempenho melhor do que a precipitação, com maior precisão ($0,39 \leq r^2 \leq 0,53$), exatidão ($0,50 \leq d \leq 0,79$) e desempenho ($0,36 \leq c \leq 0,52$). A RQME ficou entre 1,9 e 5,7°C, representando 9 e 26% da média da temperatura do ar. Na maior parte das estações, o RQME_s se sobressaiu em relação ao RQME_u, indicando que as simulações podem ser corrigidas usando técnicas estatísticas.

Palavras-chave: modelo climático, séries de dados meteorológicos, *downscaling*.

Precipitation and air temperature numerical simulations through ETA/CPTEC - HADCM3 model in Rio de Janeiro

ABSTRACT

The present study evaluated the precipitation and air temperature simulations of the Eta-CPTEC model for Rio de Janeiro state in 1961-1990. In the simulations, a spatial resolution of 40 km was considered for a grid that comprised South America, with Eta-CPTEC initialized with HadCM3 model. The observed climatic series of the studied variables were obtained from INMET meteorological stations distributed at Rio de Janeiro state. These series were compared with those extracted from the grid points of the model near to the stations. The coefficient of determination (r^2) of the simple linear regression between observed and simulated, Willmott's index of agreement (d), performance index (c), Root Mean Square Error (RQME) and their systematic (RQME_s) and unsystematic (RQME_u) components were considered in the evaluations. The precipitation simulations showed r^2 less than 0.32, which indicated low precision, while the accuracy (Willmott's d) was greater than 0.50, except for Bangu station. The low precision compromised the performance (index "c") of the simulations, with $0,07 \leq c \leq 0,42$, classified as "terrible" and "bad". The RQME varied between 76.2 and 133.4 mm, which corresponded error of 78.1 and 115.5% in relation to mean precipitation. The simulations of air temperature showed better performance than precipitation, with greater precision ($0,39 \leq r^2 \leq 0,53$), accuracy ($0,50 \leq d \leq 0,79$) and performance ($0,36 \leq c \leq 0,52$). The RQME was between 1.9 and 5.7°C, which represented respectively 9 and 26% for

average of air temperature. In most stations, $RQME_s$ were higher than the $RQME_u$, which indicated that simulators can be fitted using statistical techniques.

Keywords: climate model, meteorological dataset, downscaling.

Introdução

Em estudos climáticos, os Modelos de Circulação Global da Atmosfera (MCGA) são ferramentas capazes de caracterizar o cenário atual e futuro do clima global (Ambrizi et al., 2019). Contudo, por sua baixa resolução espacial (superior a 1° , equivalente a aproximadamente 100 km) é utilizada a técnica de transferência das informações de grande escala para escalas menores em busca de melhor representação do clima regional, as denominadas técnicas de *downscaling* (Lyra et al., 2018a). Existem diversas técnicas de refinamento da grade dos modelos (*downscaling*), entre eles o *downscaling* estatístico e o dinâmico (Sachindra et al., 2015; Vaittinada Ayar et al., 2016; Reboita et al., 2018). No refinamento dinâmico, as saídas dos MCGA são usadas para iniciar modelos atmosféricos regionais ou de área limitada (e.g. *Weather Research and Forecasting - WRF* e/ou o Modelo Eta) (Ambrizi et al., 2019).

Diversas pesquisas utilizam modelos regionais, em particular o Eta/CPTEC, por apresentarem simulações realísticas das variáveis meteorológicas em escalas sazonais e intrasazonais (Marengo et al., 2012; Chou et al., 2014; Silva et al., 2014; Oliveira et al., 2015; Ploszai et al., 2015; Mourão, Chou e Marengo, 2016; Holbig et al., 2018; Imbach et al., 2018; Lyra et al., 2018a; Ambrizi et al., 2019). Destacam-se estudos realizados nas regiões Sul e Sudeste do Brasil, que apresentam baixa previsibilidade dos *downscaling* dinâmicos que usam modelos regionais ou de área limitada iniciados os MCGAs, de *Regional Climate Models* (RCM) (Dereczynski et al., 2013; Silva et al., 2014; Cavalcanti et al., 2017; Lyra et al., 2018a) ou então de aplicações práticas para cidades litorâneas. Neste último caso, as cidades de Santos/SP e Rio de Janeiro/RJ apresentam geografia e topografia similares, sendo que as simulações climáticas podem ser úteis no delineamento de políticas públicas de ocupação e uso da terra, com a estimativa de riscos meteorológicos (Lyra et al., 2018a; Nunes et al., 2019).

Assim, pode ocorrer, nos *downscaling* dinâmicos iniciados com as simulações dos MCGAs, discrepâncias na diversidade de fenômenos atmosféricos projetados e entre os dados simulados e observados em estações de superfícies (Ambrizzi et al., 2019). Deste modo, os modelos numéricos podem apresentar simulações incertas, que se distanciam da realidade ou

apresentem erros inerentes às observações. Para avaliar essas incertezas, métodos estatísticos são utilizados para indicar índices de erros e possíveis limitações dos modelos (Santiago et al., 2016).

Essas incertezas preconizam o fato de que as projeções obtidas por modelos de simulações de clima, não devem ser utilizadas de forma direta antes de uma avaliação prévia para quantificar a exatidão e precisão de suas simulações. Portanto, esse entendimento torna-se fundamental para se compreender as mudanças climáticas, principalmente as de clima futuro (Marengo et al., 2010; PBMC, 2014).

Comumente as simulações dos modelos climáticos são comparadas com outras fontes de dados, como medições em estações meteorológicas de superfícies, imagens de satélites, dados de reanálise, medições de radiossondas (Aloysius et al., 2016; Palerme et al., 2017). Essa comparação busca verificar a capacidade dos modelos em reproduzir os estados médios climatológicos e os ciclos sazonais de elementos meteorológicos como a temperatura do ar e precipitação, assim como, a temperatura da superfície do mar, extensão do gelo do mar e termoclina equatorial, dentre outros (Rong et al., 2018). Tal verificação proporciona identificar possíveis vies existentes nos modelos, passíveis esses até de correções (Park et al., 2016; Silva et al., 2020).

Deste modo, surge a necessidade de avaliar as simulações obtidas pelos modelos climáticos, principalmente para o clima atual, com a finalidade de entender as proporções associadas à erros sistemáticos e não sistemáticos. Esse entendimento permite quantificar as incertezas entre o que foi simulado para o clima atual e os dados observados em estações meteorológicas por meio de correções (Oliveira et al., 2015; Almagro et al., 2020).

Portanto, o objetivo deste trabalho foi avaliar as simulações numéricas de precipitação e temperatura do ar do clima atual (1961-1990) do modelo climático regional Eta/CPTEC com resolução de 40 km, inicializado com o modelo global HadCM3, em relação aos dados observados em estações meteorológicas no estado do Rio de Janeiro no mesmo período. Assim, a hipótese deste trabalho é que as saídas do modelo descrito acima possam representar uma informação útil para os tomadores de decisão.

Material e métodos

Área de Estudo e Séries Climáticas

O estado do Rio de Janeiro localiza-se na região Sudeste do Brasil, entre as latitudes de 20° 45' a 23° 21' S; longitudes 40° 57' a 44° 53' W. O Estado limita-se a nordeste com o estado do Espírito Santo, a norte e noroeste com o estado de Minas Gerais, a sudoeste com São Paulo e a sul e leste com o Oceano Atlântico.

Com base na classificação de Köppen, o estado do Rio de Janeiro possui predominância de clima do tipo Aw, seguido do tipo Cwa, enquanto nas partes mais elevadas da serra do Mar e da Mantiqueira predominam Cfb e Cwb (Alvares et al., 2013). As altitudes variam desde o nível do mar a até 2.787 metros, no pico das Agulhas Negras. As precipitações anuais variam de 800 mm na região de Armação dos Búzios e Cabo Frio, a até mais de 2000 mm anuais nos domínios serranos e litoral sul (Lumbreras et al., 2003; Brito et al. 2017)

As séries climáticas de precipitação e temperatura do ar foram obtidas entre os anos de 1961-1990 nas estações meteorológicas do Instituto Nacional de Meteorologia (INMET), localizadas no estado do Rio de Janeiro. No tocante à precipitação, apenas estações com séries temporais superiores a 20 anos foram selecionadas. Com base nesse critério, foram identificadas 12 estações com séries mensais de precipitação inseridas no período de estudo (Figura 1, Tabela 1). Posteriormente, as séries climáticas dessas estações foram submetidas à análise de qualidade dos dados e preenchimento de falhas, quando necessário.

A análise de qualidade dos dados foi baseada na análise exploratória das séries mensais de precipitação (estatística descritiva e Box-plot), que permitiu identificar os *outliers* e, posteriormente, definir os dados espúrios, que foram retirados da série. Na definição dos dados espúrios, a série mensal da estação em análise (Y_i) foi comparada, por meio da regressão linear ($Y_i = \beta_0 + \beta_1.X_i$), com a série de referência (X_i).

Figura 1. Mapa da grade do modelo Eta/CPTEC delimitada para o estado do Rio de Janeiro e seu entorno e estações meteorológicas do INMET usadas nas avaliações das simulações.

*Círculos em vermelho no entorno (*buffer*) das estações INMET representam a distância (25 km) de abrangência considerada para definir o ponto de grade do modelo a ser avaliado. Fonte: elaborada pelos autores.

Tabela 1. Estações meteorológicas do Instituto Nacional de Meteorologia usadas no estudo suas coordenadas geográficas e altitude. A percentagem de falhas é apenas para a série de temperatura do ar.

Nome	Id	Latitude	Longitude	Altitude (m)	Falhas [±] (%)
Angra dos Reis*	1	23,00° S	44,32° W	3	21,4
Rio de Janeiro*	2	22,89° S	43,18° W	11	9,7
Bangu	3	22,87° S	43,45° W	124	-
Ecologia Agrícola	4	22,77° S	43,68° W	34	-
Resende*	5	22,48° S	44,45° W	440	16,1
Vassouras	6	22,42° S	43,67° W	438	-
Nova Friburgo	7	22,28° S	42,53° W	846	-
Cordeiro*	8	22,02° S	42,36° W	506	40,0
Santa Maria Madalena*	9	21,95° S	42,02° W	620	24,7
Carmo*	10	21,93° S	42,62° W	342	14,2
Campos dos Goytacazes*	11	21,75° S	41,33° W	11	1,9
Itaperuna*	13	21,20° S	41,90° W	124	55,8

* Estações com séries de temperatura do ar e precipitação. [±]percentagem de falhas das séries de temperatura do ar. Fonte: INMET.

A série de referência foi obtida pela média aritmética das séries de estações próximas a estação em análise, selecionadas pelos critérios: i) inseridas no mesmo grupo de precipitações homogêneas, ii) menor distância entre as estações e iii) coeficiente de correlação de *Pearson* entre as séries maior que 0,7 (Lyra et al., 2018b).

Os grupos de precipitações homogêneas foram determinados pela análise de agrupamento, usando o método aglomerativo de Ward, com medida de dissimilaridade a distância Euclidiana ao quadrado (Brito et al., 2017). Apenas estações que apresentaram valores de coeficiente de determinação da regressão (r^2) > 0,7 e $0,7 < \beta_1 < 1,3$ foram analisadas (Kite, 1988).

O intervalo do r^2 e β_1 proposto por Kite (1988), permite inferir que a série da estação em análise e a série de referência apresentam tendências regionais similares e, os métodos de análise de qualidade e preenchimento de falhas, baseados em regressão linear, podem ser aplicados. Quando foi determinada que a observação estava fora dos limites definidos pelo intervalo de confiança da regressão (95%), a mesma foi considerada discrepante e retirada da série.

Após terem sido realizadas as análises da qualidade dos dados de precipitação foram consideradas apenas 12 estações meteorológicas para o presente estudo. Para essas estações, quando da ocorrência de falhas, as mesmas foram preenchidas pelo método da regressão linear,

usando a regressão ajustada entre a série da estação em análise e a série de referência após a análise de qualidade dos dados (Lyra et al., 2018b). Todas as falhas foram preenchidas, de forma, a obter séries contínuas de 30 anos para as 12 estações em estudo.

As séries de temperatura do ar mensal não estavam disponíveis para todas as estações, então foram consideradas apenas oito estações para o estado do Rio de Janeiro com séries superiores a 15 anos e inseridas no período de 1961 a 1990.

Simulações do modelo Eta/CPTEC

As simulações das séries meteorológicas mensais para o clima atual (denominada de *baseline*), compreendido entre 1961 a 1990, foram geradas pelo modelo climático regional Eta/CPTEC-INPE, a partir das condições de fronteira do modelo global HadCM3, fornecidas pelo *Metoffice Hadley Centre* (MOHC) do Reino Unido (Marengo et al., 2012).

O modelo regional Eta é um modelo de ponto de grade com área limitada e desenvolvido na coordenada vertical Eta (η), resultando num sistema de coordenadas à superfície quasi-horizontal. As variáveis prognósticas pelo modelo são temperatura do ar, vento horizontal, umidade específica, pressão superficial, energia cinética turbulenta e hidrometeoros/nuvens (Chou et al., 2014). Em vista de sua dinâmica, ele é mais apropriado para ser usado em regiões com

orografia complexa, tais como àquelas existentes no estado do Rio de Janeiro. Também tem sido adotado em integrações de longo prazo (Pesquero et al., 2010; Marengo et al., 2012).

Nas simulações do Eta considerou-se uma resolução espacial de 40 km na horizontal e 38 camadas na vertical, sendo considerado o cenário de emissões A1B (IPCC, 2007). Ressalta-se que, mesmo baseado no 4th IPCC *Assessment Report*, foram usados estes dados porque trarão contribuições para o conhecimento dos ajustes usando técnicas estatísticas para melhorar exatidão e precisão das simulações de modelos. Outras características do modelo usado podem ser obtidas em Marengo et al. (2012) e Chou et al. (2014). O modelo HadCM3 é um MCGA, que tem sua componente atmosférica em 19 níveis, com uma grade horizontal global de 96 x 73 células (Marengo, 2007).

Os cenários climáticos gerados pelo modelo Eta compreenderam toda América do Sul, com simulações de dados diários de 42 variáveis para 20 níveis atmosféricos. Entretanto, as simulações de precipitação e temperatura do ar usadas nesta análise foram apenas informações de superfície e na escala mensal. As séries mensais de precipitação e temperatura do ar simuladas nos pontos de grade mais próximos das estações meteorológicas do INMET foram obtidos com auxílio do programa MétéoInfo (Wang, 2014).

Análises Estatísticas

Para a avaliação das simulações de precipitação e de temperatura de ar, as séries mensais observadas e simuladas dessas variáveis foram pareadas e, a partir delas foram obtidos índices estatísticos que permitiram inferir sobre a precisão e exatidão das simulações, como por exemplo: a Raiz do Quadrado Médio do Erro (RQME), o coeficiente de determinação (r^2) da regressão linear ($P_i = \beta_0 + \beta_1 \cdot O_i$) entre as séries mensais observadas (O_i) e simuladas (P_i), o índice de concordância de Willmott (d) e o índice de desempenho (c).

O RQME é uma medida de exatidão e quantifica a amplitude média dos erros estimados (Equação 1). O valor sempre será positivo e quando for zero representará uma previsão ideal. Conforme o valor do RQME se eleva, aumenta a diferença entre os valores simulados e observados.

$$RQME = \left[\frac{\sum_i^n (O_i - P_i)^2}{n} \right]^{1/2} \quad (\text{Eq. 1})$$

em que, O_i são valores observados e P_i os simulados e o índice subscrito representa a i-ésima observação avaliada.

O erro sistemático (RQMEs) e não-sistemático (RQMEu) foram determinados como segue (Willmott, 1981):

$$RQME_s = \left[\frac{\sum_i^n (\bar{P}_i - O_i)^2}{n} \right]^{1/2} \quad (\text{Eq. 2})$$

$$RQME_u = \left[\frac{\sum_i^n (P_i - \bar{P}_i)^2}{n} \right]^{1/2} \quad (\text{Eq. 3})$$

em que, $\bar{P}_i$ é o valor obtido pela regressão linear $\bar{P}_i = \beta_0 + \beta_1 \cdot O_i$ e β_0 e β_1 são os coeficientes linear e angular da regressão.

No caso de avaliação de modelos, o r^2 é uma forma de avaliar a precisão das simulações, sendo que quanto mais próximo de 1 seu valor, mais preciso (menor a dispersão dos dados) é o dado em grade (Willmott, 1981). O índice de concordância (d) de Willmott et al. (1985) expressa a exatidão das estimativas em relação aos valores observados, variando de zero (0) - nenhuma concordância, a 1 - perfeita concordância (exatidão). O valor (d) é dado pela equação abaixo:

$$d = 1 - \frac{\sum (P_i - O_i)^2}{\sum (|P_i - \bar{O}| + |O_i - \bar{O}|)^2} \quad (\text{Eq. 4})$$

em que, $\bar{O}$ é a média dos valores observados.

O índice de desempenho (c) proposto por Camargo e Sentelhas (1997) utiliza-se dos índices de precisão, indicado pelo coeficiente de correlação de Pearson (r), e exatidão, representada pelo d de Willmott para avaliar o desempenho dos métodos utilizados. Ele é determinado da seguinte forma:

$$c = r * d \quad (\text{Eq. 5})$$

Os parâmetros de avaliação do desempenho de modelos quanto ao índice de desempenho estão apresentados na Tabela 2 (Camargo e Sentelhas, 1997).

Tabela 2 - Análise do modelo com base no índice de desempenho (c).

Valor de c	Desempenho
> 0,85	Ótimo
0,76 a 0,85	Muito bom
0,66 a 0,75	Bom
0,61 a 0,65	Mediano
0,51 a 0,60	Sofrível
0,41 a 0,50	Mau
≤ 0,40	Péssimo

Fonte: Camargo e Sentelhas, 1997.

Resultados e discussão

Precipitação

As simulações da precipitação pelo modelo Eta/CPTEC em relação às observações das estações apresentaram baixa precisão, com valores de r^2 entre 0,05 (Rio de Janeiro) e 0,32 (Vassouras). O RQME variou entre 76,25 (Ecologia Agrícola) e 133,40 mm (Bangu), enquanto o coeficiente de concordância de Willmott (d), que permite inferir sobre a exatidão das simulações, foi superior a aproximadamente 0,5, com exceção da estação de Bangu (0,16). O baixo valor para a estação de Bangu deve-se ao fato de que esta localiza-se na parte baixa de uma Bacia aérea e/ou devido à distância e diferença latitudinal da estação e do ponto de grade.

Tabela 3 - Índices estatísticos usados na comparação dos dados de precipitação observada e simulada. Coeficiente de determinação (r^2), índice de concordância de Willmott (d), índice de desempenho (c), Raiz do Quadrado Médio do Erro (RQME, mm e %) e RQME sistemática (RQME_s, %) e não sistemática (RQME_u, %).

Nome	r^2	d	c	RQME(mm)	RQME(%)	RQME _s (%)	RQME _u (%)
Angra dos Reis	0,17	0,57	0,23	111,4	70,5	75,0	25,0
Bangu	0,20	0,16	0,07	133,4	115,5	81,6	18,4
Campos	0,10	0,51	0,16	103,4	127,7	31,6	68,4
Carmo	0,30	0,73	0,40	83,9	74,3	24,6	75,4
Cordeiro	0,29	0,60	0,33	92,3	86,4	83,5	16,5
Ecologia Agrícola	0,25	0,69	0,35	76,3	78,1	24,3	75,7
Itaperuna	0,27	0,67	0,35	78,1	81,3	61,4	38,6
Nova Friburgo	0,22	0,57	0,27	97,3	96,1	83,0	17,0
Resende	0,24	0,56	0,27	113,3	90,4	88,2	11,8
Rio de Janeiro	0,05	0,49	0,12	89,3	106,5	51,5	48,5
Santa Maria	0,29	0,72	0,39	84,7	71,6	34,9	65,1
Vassouras	0,32	0,74	0,42	78,3	75,4	34,8	65,2

Legenda: Índice de desempenho (c): ótimo (violeta), muito bom (azul-escuro), bom (azul claro), mediano (verde), sofrível (amarelo), mau (laranja), péssimo (vermelho).

O índice de desempenho (c) variou de 0,07 (Bangu) a 0,42 (Vassouras), o que indicou desempenhos de “mau” a “péssimo” (Tabela 3). Notou-se também que o RQME (%) em relação à média da precipitação mostrou erros superiores a 100%.

Assim, os índices indicaram que a precisão (r^2) das simulações foram baixas, enquanto a exatidão (d de Willmott) foi superior a precisão. De qualquer forma, as simulações precisam ser corrigidas ou avaliadas diferentes parametrizações do modelo Eta/CPTEC para melhor simular a precipitação no estado do Rio de Janeiro.

As estações de Bangu, Campos dos Goytacazes e Rio de Janeiro foram onde se observaram as maiores imprecisões das simulações, com valores de r^2 e de c menores ou iguais a 0,20 e RQME maior que 103 mm. A estação de Bangu também apresentou menor exatidão, com d de Willmott de 0,16 e índice de desempenho c igual a 0,07, que em relação à classificação desse índice (Tabela 2), encontra-se na faixa de desempenho “péssimo”. A estação de Vassouras foi aquela que teve melhor desempenho, ao apresentar os valores de r^2 e índice d mais próximos do ideal (1) e o valor c classificado como “mau” desempenho. Ressalta-se que todas as outras estações se encontraram na classe de desempenho “péssimo”.

De forma análoga aos resultados deste estudo, Santiago et al. (2016), para o estado de Pernambuco, observaram que os valores de precipitação modelados foram mais exatos (d) do que precisos (r^2), ou seja, o modelo não representou adequadamente a variabilidade da precipitação. Assim, estes autores concluíram que foi possível perceber que a precipitação é a variável comprometida em nível de incerteza das saídas do modelo, em que a simulação apresentou comportamento e valores distantes dos valores observados, para o período presente (1960-1990) na área estudada. Ambrizzi et al. (2007) verificaram que o modelo Eta/CPTEC apresentou baixo índice de correlação (0,49) em simular o ciclo sazonal da chuva no Nordeste do Brasil. Ambos autores ressaltaram que isso pode ser devido à complexidade da simulação desta variável, que é influenciada por diferentes fenômenos atmosféricos, além da diferença de escala espacial entre os valores simulados e observados, pois enquanto o modelo gera uma informação em grades de 40 x 40 km a estação meteorológica mede a precipitação pontualmente.

Adicionalmente, outros estudos assinalaram que os modelos climáticos globais ainda não conseguem reproduzir com alto grau de confiabilidade o padrão sazonal de precipitação que a climatologia observacional apresenta (Valverde e Marengo, 2010; Dereczynski et al., 2013). Recentemente, Almagro et al. (2020) fizeram uma análise similar a esta sobre o elemento climático precipitação para o bioma característico de Floresta Atlântica, que tem vegetação e topografias similares ao Rio de Janeiro. Além do mais, considerando-se que toda a técnica de regionalização ou *downscaling* contém erros derivados do modelo global, forçando o modelo regional, era de se esperar maior dificuldade do modelo em representar espacialmente a precipitação regional (Kharin et al., 2005; Ambrizzi et al., 2007; Ambrizzi et al., 2019; Chou et al., 2019).

Na maior parte das estações (Angra dos Reis, Bangu, Cordeiro, Itaperuna, Nova Friburgo, Resende e Rio de Janeiro), o erro sistemático representou a maior parcela do erro, sendo entre 51,5% (Rio de Janeiro) e 88,2% (Resende). No caso das estações onde o erro não sistemático se sobressaiu, a sua contribuição no RQME foi entre 65,1% (Santa Maria Madalena) e 75,7% (Ecologia Agrícola). Para as regiões, representadas pelas

estações avaliadas com maior contribuição do erro sistemático, as simulações podem ser corrigidas por métodos estatísticos para melhorar sua precisão e exatidão (Silva et al., 2020).

Nas Figuras 2b e 3f encontram-se as séries dos dados de precipitação das estações que apresentaram o pior (Bangu) e melhor desempenho (Vassouras). A série da estação de Bangu encontrou-se mais dispersa em relação à série da estação de Vassouras, o que significou que a precisão entre os dados simulados e observados foi menor para estação de Bangu. Em Vassouras, o modelo apresentou tendência de subestimar (superestimar) valores de precipitação superiores (inferiores) a aproximadamente 150 mm.

Similar à estação de Vassouras, em todas as outras estações o modelo mostrou tendências de subestimar (superestimar) valores de precipitação superiores (inferiores) a aproximadamente 35 mm (Cordeiro), 40 mm (Nova Friburgo), 50 mm (Resende), 65 mm (Itaperuna), 80 mm (Santa Maria Madalena e Angra dos Reis), 100 mm (Carmo), 110 mm (Rio de Janeiro), 130 mm (Vassouras), 140 mm (Ecologia Agrícola - Seropédica) e 160 mm (Campos de Goytacazes), conforme visualizadas nas Figuras 2 e 3. Bangu apresentou tendência inversa, e superestimativa (subestimativa) para valores menores (maiores) que 100 mm.

Os resultados acima obtidos estão de acordo com outros estudos realizados no Brasil e no Rio de Janeiro, que usaram o modelo Eta. Moura et al. (2010) avaliaram o desempenho do modelo Eta, utilizando o erro médio (EM) e a Raiz do Quadrado Médio do Erro (RQME) e, constataram que houve tendência de superestimativa (valores positivos do erro médio) da precipitação sobre a região Norte do Brasil.

Alves et al. (2004), ao avaliarem o desempenho e a evolução das previsões sazonais de precipitação previstas pelo Eta sobre o Brasil, verificaram que para a região Sudeste, o modelo global também superestima os valores de precipitação em praticamente toda a série, e levantaram a expectativa de que o modelo regional possa prever razoavelmente a distribuição temporal e espacial de dias com ou sem chuvas durante o mês. Chou et al. (2019) observaram que as simulações de precipitação usando o Eta com resolução de 5 km, iniciado com o HadGEM2-ES para região Sudeste do Brasil, geralmente mostram subestimativa durante a estação chuvosa e

superestimativa durante o inverno. Segundo os autores, esse resultado é herdado pelo modelo climático global HadGEM2-ES. As simulações conduzidas com o Era-Interim, como condições de contorno lateral não mostram essa mudança no

ciclo anual de precipitação. Resultados similares também foram observados por Almagro et al. (2020).

Figura 2. Comparação das séries de precipitação observadas e simuladas para o período de 1961-90 nas estações de (a) Angra dos Reis, (b) Bangu, (c) Campos dos Goytacazes, (d) Carmo, (e) Cordeiro e (f) Ecologia Agrícola no estado do Rio de Janeiro.

Figura 3. Comparação das séries de precipitação observadas e simuladas para o período de 1961-1990 nas estações de (a) Itaperuna, (b) Nova Friburgo, (c) Resende, (d) Rio de Janeiro, (e) Santa Maria Madalena e (f) Vassouras no estado do Rio de Janeiro.

No estado do Rio de Janeiro, especificamente, Silva et al. (2014, 2020) realizaram pesquisas acerca das mudanças de temperatura do ar e precipitação entre as condições do clima atual (1961-1990) e aqueles projetados para até o final do século XXI no estado do Rio de Janeiro ou na região da Floresta Atlântica por meio do modelo regional Eta-HadCM3, com resolução de 40 km. Os resultados mostraram que as projeções futuras para os períodos de 2011-2040, 2041-2070 e 2071-2100 diferem apenas em relação às magnitudes das diferenças dos indicadores comparadas ao clima atual (1961-1990), sempre mantendo o mesmo sinal de aumento ou diminuição. Além disso, os autores notaram que a faixa de variação entre aumento e diminuição dos índices de precipitação total anual (PRCPTOT), precipitação total anual em dias com precipitação > percentil 95% (R95p) e seus valores mínimo e máximo projetados pelo modelo é maior ao longo de todo o Estado. A região norte do Estado teve a maior variação, o que indicou valores variando de diminuição de PRCPTOT de -350 mm a aumento de 300 mm. Esta ampla faixa de variação sobre o Estado pode estar relacionada ao fato de que as variáveis meteorológicas deste tipo sofrem considerável influência de outros elementos climáticos e fatores geográficos.

Dereczynski et al. (2013) analisaram os índices extremos observados e projetados de precipitação para a cidade do Rio de Janeiro usando dados observacionais e o modelo regional Eta-HadCM3. As simulações do modelo Eta para as condições de clima atual (1961-1990) foram comparadas com os dados observacionais e verificou-se que o modelo Eta-HadCM3 não reproduziu a variabilidade interanual da precipitação, principalmente na estação do Alto da Boa Vista, localizada em altitude elevada, com eventos de chuvas intensas. Com respeito à precipitação simulada pelo modelo Eta para o clima atual, a maioria das tendências ficou oposta àquela observada. Segundo os autores, isso seria

possivelmente devido à dependência da precipitação sobre sistemas locais, tais como, circulações de brisas terrestres e marítimas, ou à limitação dos dados observacionais, com inúmeras falhas.

Temperatura do Ar

Nas simulações de temperatura do ar foram verificados melhores desempenhos do que as simulações de precipitação, conforme podem ser observados na Tabela 4, e visualizados nas Figuras 4 e 5. Os valores de r^2 variaram entre 0,39 (Santa Maria) e 0,53 (Rio de Janeiro), com o RQME de 1,9 (Santa Maria) a 5,7 °C (Resende) e o índice “c” com valores entre 0,42 (Resende) a 0,52 (Cordeiro), classificados, respectivamente com desempenho “mau” e “sofrível” (Tabela 2). As estações do Rio de Janeiro e Cordeiro obtiveram valores mais precisos, com r^2 igual a 0,53, boa exatidão com valores de “d”, respectivamente de 0,70 e 0,72, valor “c” na classe de sofrível e o RQME inferior a 2,7 °C.

Outro resultado obtido foi que a estação de Resende, apesar de boa precisão ($r^2 = 0,52$), foi a que apresentou o maior erro (RMSE = 5,7 °C), que representou 26% da média, menor exatidão, com o valor de “d” de 0,50 e o valor de “c” de 0,36, o que indicou desempenho classificado como “péssimo”.

Com exceção da estação de Santa Maria Madalena, onde o erro não sistemático contribuiu com a maior parcela da RQME (70,2%), nas demais, o erro sistemático foi responsável pela maior proporção da RQME. No caso da RMQE, sua contribuição foi entre 69,1% (Rio de Janeiro) e 93,1% (Resende). Para a temperatura, as correções estatísticas das simulações apresentam maior viabilidade do que para a precipitação, sendo necessária para isso, a análise dos erros sistemáticos proporcionais e aditivos (Willmott, 1981).

Tabela 4 - Índices estatísticos usados na comparação dos dados de temperatura do ar observada e simulada. Coeficiente de determinação (r^2), índice de concordância de Willmott (d), índice de desempenho (c), Raiz do Quadrado Médio do Erro (RQME, mm e %) e RQME sistemática (RQME_s, %) e não sistemática (RQME_u, %).

Nome	r^2	d	c	RQME(°C)	RQME(%)	RQME _s (%)	RQME _u (%)
Angra dos Reis	0,41	0,66	0,42	2,89	12,1	75,2	24,8
Campos	0,48	0,64	0,45	2,88	11,7	78,9	21,1
Carmo	0,52	0,65	0,47	3,40	14,4	82,4	17,6
Cordeiro	0,53	0,72	0,52	2,68	12,4	71,4	28,6
Itaperuna	0,49	0,63	0,44	3,24	13,4	81,3	18,7
Resende	0,52	0,50	0,36	5,73	25,6	93,1	6,9
Rio de Janeiro	0,53	0,70	0,51	2,34	9,8	69,1	30,9
Santa Maria	0,39	0,79	0,49	1,89	9,0	29,8	70,2

Legenda: Índice de desempenho (c): ótimo (violeta), muito bom (azul-escuro), bom (azul claro), mediano (verde), sofrível (amarelo), mau (laranja), péssimo (vermelho).

Figura 4. Comparação das séries de temperatura do ar observadas e simuladas nas estações de (a) Angra dos Reis, (b) Campos dos Goytacazes, (c) Carmo e (d) Cordeiro no estado do Rio de Janeiro.

Figura 5. Comparação das séries de temperatura do ar observadas e simuladas nas estações de (a) Itaperuna, (b) Resende, (c) Rio de Janeiro e (d) Santa Maria Madalena, no estado do Rio de Janeiro.

Para uma melhor representação dos resultados obtidos, nas Figuras 5b e 5c encontram-se as séries de dados de temperatura do ar das estações que apresentaram o pior (Resende) e melhor desempenho (Rio de Janeiro). Mesmo os dados da série de temperatura do ar da estação de Resende apresentaram-se menos dispersos que os de precipitação para a mesma estação, contudo distante da linha de tendência ideal (reta 1:1), enquanto que o da estação do Rio de Janeiro observou-se mais próximo da linha de tendência.

Ao analisar os resultados encontrados para as outras estações, verificou-se tendência similar de subestimativa para as séries de temperatura do

ar comparativas entre àquelas simuladas e observadas, que apresentaram menor e maior dispersão em relação à linha de tendência, conforme pode ser observado na Figura 4. Apenas a estação de Santa Maria Madalena apresentou tendência de superestimar (subestimar) os valores inferiores (superiores) a 21,6° C. Ressalta-se que neste caso apenas oito estações foram analisadas para esta variável, que foram justificadas no item “Área de Estudo e Séries Climáticas”.

Resultados análogos foram encontrados por Santiago et al. (2016), para o estado de Pernambuco, a qual identificaram que a temperatura do ar média apresentou coeficiente de

determinação (r^2) e índice de concordância (d) elevados para as simulações do modelo Eta-HadCM3, com precisão maior que 0,6 e exatidão superior a 0,7. Além disso, os resultados indicaram que o modelo tende a superestimar em todos os pontos, com relação aos dados observados. Deve ser ressaltado que as características geográficas e climáticas de Pernambuco são diferentes daquelas do Rio de Janeiro, por isso estes resultados são diferentes daqueles encontrados em nosso estudo.

Outros resultados análogos também foram registrados para diferentes locais no Brasil (Dereczynski et al., 2013; Chou et al., 2014). Dereczynski et al. (2013) mostraram que as simulações do modelo regional Eta tiveram tendências significativas de aquecimento quando comparadas com os dados observacionais (superestimativa) para o clima atual, porém ficou evidenciado que estas tendências eram mais intensas para a temperatura do ar média máxima anual do que para a temperatura do ar média mínima anual na cidade do Rio de Janeiro.

Chou et al. (2014) verificaram que a temperatura do ar média anual foi subestimada para todas as simulações feitas pelo modelo regional Eta e pelo MCGA, como também em todas as regiões no Brasil, na maior parte do ano. Além disso, os autores encontraram que as distribuições de frequência da temperatura do ar nas simulações do Eta e do MCGA contêm mais valores extremos do que os dados observados para o clima presente. Resultado similar foi obtido para a região Sudeste do Brasil por Chou et al. (2019) usando o Eta com grade de 5 km e iniciado com o HadGEM2-ES.

Conclusões

Pelas análises realizadas chegou-se às seguintes conclusões:

As simulações de precipitação mensal realizadas não demonstraram estimativas precisas e exatas em todas as estações analisadas, devido à alta variabilidade da chuva, quer seja por fatores geográficos (topografia complexa, proximidade do ambiente costeiro) e/ou climáticos (diversos fenômenos de subgrade e de circulações de mesoescala). No caso das simulações de temperatura do ar, estas apresentaram melhor desempenho, com maior exatidão e precisão.

As simulações climáticas regionais podem ser empregadas para diversos estudos de problemas relacionados ao tema de mudanças climáticas (e.g. secas, enchentes, desertificação, deslizamento de massas, inundações) no Rio de Janeiro, mas que,

ficou evidenciado que é necessário realizar correções, principalmente, no elemento climático de precipitação.

Agradecimentos

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ) pelo financiamento do Projeto (Processo No. 141.663) “Risco à Desertificação no Estado do Rio de Janeiro baseado em Índices Climáticos e Mudança do Uso e Ocupação do Solo: Cenário Atual e de Mudanças Climáticas” e ao Programa PIBIC/UFRRJ pela bolsa de iniciação científica da Fernanda da Silva Pinheiro. Além desses, agradecemos também ao Instituto Nacional de Meteorologia (INMET) por fornecer os dados observados e o INPE pela disponibilidade das simulações do Eta/CPTEC através do Dr. José A. Marengo.

Referências

- Aloysius, N.R., Sheffield, J., Saiters, J.E., Li, H., Wood, E.F., 2016. Evaluation of historical and future simulations of precipitation and temperature in central Africa from CMIP5 climate models. *Journal of Geophysical Research: Atmospheres* 121, 130-152. <https://doi.org/10.1002/2015JD023656>
- Alvares, C.A. et al., 2013. Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift* 22, 711-728. <https://doi.org/10.1127/0941-2948/2013/0507>
- Almagro, A., Oliveira, P.T.S., Rosolem, R., Hagemann, S., Nobre, C.A., 2020. Performance evaluation of Eta/HadGEM2-ES and Eta/MIROC5 precipitation simulations over Brazil. *Atmosphere Research* 244. <https://doi.org/10.1016/j.atmosres.2020.105053>
- Alves, L.M., Chou, S.C., Marengo, J.A. Avaliação das previsões de chuvas sazonais do modelo ETA climático sobre o Brasil. In: XIII Congresso Brasileiro de Meteorologia, 2004.
- Ambrizzi, T., Rocha, R.P., Marengo, J.A., Pissincheno, I., Nunes, L.A., Fernandez, J.P.R., 2007. Cenários regionalizados de clima no Brasil e América do Sul para o Século XXI: Projeções de clima futuro usando três modelos regionais. Ministério do Meio Ambiente, Brasília (Relatório 3: CPTEC/INPE; IAG/USP; FBDS. Secretaria de Biodiversidade e Florestas. Diretoria de Conservação da Biodiversidade).

- Ambrizzi, T., Reboitta, M.S., Rocha, R.P.D., Llopart, M., 2019. The state of the art and fundamental aspects of regional climate modeling in South America. *Annals of the New York Academy of Sciences* 1436, 98-120. <https://doi.org/10.1111/nyas.13932>
- Brito, T.T., Oliveira-Júnior, J. F., Lyra, G.B., Gois, G., Zeri, M., 2017. Multivariate analysis applied to monthly rainfall over Rio de Janeiro state, Brazil. *Meteorology and Atmospheric Physics* 129, 469-478. <https://doi.org/10.1007/s00703-016-0481-x>
- Camargo, A.P., Sentelhas, P.C., 1997. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no Estado de São Paulo, Brasil. *Revista Brasileira de Agrometeorologia* 5, 89-97.
- Cavalcanti, I.F.A., Marengo, J.A., Alves, L.M., Costa, D.F., 2017. Projections of Precipitation Changes in Two Vulnerable Regions of São Paulo State, Brazil. *American Journal of Climate Change* 6 (2), 268-293. <https://doi.org/10.4236/ajcc.2017.62014>
- Chou, S.C., Lyra, A., Mourão, C., Dereczynski, C.P., Pilotto, I.L., Gomes, J.L., Bustamante, J.F., Tavares, P. S., Silva, A., Rodrigues, D.C., Campos, D., Chagas, D., Medeiros G.S., Siqueira, G., Nobre, P., Marengo, J.A., 2014. Evaluation of the Eta simulations Nested in Three Global Climate Models. *American Journal of Climate Change* 3, 438-454. <https://doi.org/10.4236/ajcc.2014.35039>
- Chou, S.C., Marengo, J.A., Silva, A.J., Lyra, A.A., Tavares, P., Souza, C.R.G., Harari, J., Nunes, L.H., Greco, R., Hosokawa, E.K., Aragão, L.E.O.C., Alves, L.M., 2019. Projections of Climate Change in the Coastal Area of Santos, in: Nunes L., Greco R., Marengo J. (Eds.), *Climate Change in Santos Brazil: Projections, Impacts and Adaptation Options*. Springer, Cham, Heidelberg, pp. 59-73. https://doi.org/10.1007/978-3-319-96535-2_4
- Dereczynski, C., Silva, W.L., Marengo, J., 2013. Detection and Projections of Climate Change in Rio de Janeiro, Brazil. *American Journal of Climate Change* 2, 25-33. <https://doi.org/10.4236/ajcc.2013.21003>
- Holbig, C.A., Mazzonetto, A., Borella, F., Pavan, W., Fernandes, J.M.C., Chagas, D.J., Gomes, J.L., Chou, S.C., 2018. PROJETA platform: accessing high resolution climate change projections over Central and South America using the Eta model. *Agrometeoros* 26, 71-81.
- Imbach, P., Chou, S.C., Lyra, A., Rodrigues, D., Rodriguez, D., Latinovic, D., Siqueira, G., Silva A., Garofolo, L., Georgiou, S., 2018. Future climate change scenarios in Central America at high spatial resolution. *PLoS ONE* 13(4). <https://doi.org/10.1371/journal.pone.0193570>
- IPCC. Intergovernmental Panel on Climate Change, 2007. *Climate change 2007: The physical science basis*. IPCC, AR4, WGI Report. Cambridge Univ. Press.
- Kharin, V.V., Zwiers, F.W., Zhang, X., 2005. Intercomparison of Near-Surface Temperature and Precipitation Extremes in AMIP-2 Simulations, Reanalyses, and Observations. *Journal of Climate* 18, 5201-5223. <https://doi.org/10.1175/JCLI3597.1>
- Kite, G.W., 1988. *Frequency and Risk Analyses in Hydrology*. Water Resources Publications, Littleton, CO.
- Lumbreras, J.F., Naime, U.J., Carvalho Filho, A., Wittern, K.P., Shinzato, E., Dantas, M.E., Palmieri, F., Fidalgo, E.C.C., Calderano, S.B., Medina, A.I. M., Pimentel, J., Chagas, C.S., Goncalves, A.O., Martorano, L.G., Santos, L.C.O., Tôsto, S.G., Brandão, E.S., Anjos, G.T., Amaral, F.C.S., Lima, J.A.S., Valle, L.C.S., Pereira, N.R., Baruqui, A.M., Prado, R.B., Oliveira, R.P., Aglio, M.L.D., 2003. *Zoneamento agroecológico do Estado do Rio de Janeiro*. Embrapa Solos, Rio de Janeiro (Boletim de Pesquisa e Desenvolvimento, 33).
- Lyra, A., Tavares, P., Chou, S.C., Sueiro, G., Dereczynski, C.P., Sondermann, M., Silva, A., Marengo, J.A., Giarolla, A., 2018a. Climate change projections over three metropolitan regions in Southeast Brazil using the non-hydrostatic Eta regional climate model at 5-km resolution. *Theoretical and Applied Climatology* 132, 663-682. <https://doi.org/10.1007/s00704-017-2067-z>
- Lyra, G.B., Correia, T.P., Oliveira-Júnior, J.F., Zeri, M., 2018b. Evaluation of methods of spatial interpolation for monthly rainfall data over the state of Rio de Janeiro, Brazil. *Theoretical and Applied Climatology* 134, 955-965. <https://doi.org/10.1007/s00704-017-2322-3>
- Marengo, J.A., 2007. *Mudanças Climáticas Globais e seus Efeitos sobre a Biodiversidade- Caracterização do Clima Atual e Definição das Alterações Climáticas para o Território Brasileiro ao longo do Século XXI*. 2ª Ed., Brasília: Ministério do Meio Ambiente, V.1, p.214.

- Marengo, J.A., Rusticucci, M., Penalba, O., Renom, M., 2010. An Intercomparison of observed and simulated extreme rainfall and temperature events during the last half of the twentieth century: part 2: historical trends. *Climatic Change* 98, 509-529. <https://doi.org/10.1007/s10584-009-9743-7>
- Marengo, J.A., Chou, S.C., Kay, G., Alves, L.M., Pesquero, J.F., Soares, W.R., Santos, D.C., Lyra, A.A., Sueiro, G., Betts, R., Chagas, D.J., Gomes, J.L., Bustamente, J.F., Tavares, P., 2012. Development of Regional Future Climate Change Scenarios in South America Using the Eta CPTEC/HadCM3 Climate Change Projections: Climatology and Regional Analyses for the Amazon, São Francisco and the Parana River Basins. *Climate Dynamics* 38, 1829-1848. <https://doi.org/10.1007/s00382-011-1155-5>
- Moura, R.G., Herdies, D.L., Mendes, D., Mendes, M.C.D., 2010. Avaliação do Modelo Regional Eta utilizando as Análises do CPTEC e NCEP. *Revista Brasileira de Meteorologia* 25, 46-53. <https://doi.org/10.1590/S0102-77862010000100005>
- Mourão, C., Chou, S.C., Marengo, J., 2016. Downscaling Climate Projections over La Plata Basin. *Atmospheric and Climate Sciences* 6, 1-12. <https://doi.org/10.4236/acs.2016.61001>
- Nunes, L.H., Greco, R., Marengo, J.A., 2019. Climate Change in Santos, Brazil: projections, impacts and adaptation options. Springer Publisher, Switzerland. https://doi.org/10.1007/978-3-319-96535-2_4
- Oliveira, G.G., Pedrollo, O.C., Castro, N.M.R., 2015. As Incertezas associadas às Condições Climáticas obtidas pelo Modelo ETA CPTEC/HADCM3: Avaliação Comparativa entre os Dados Simulados e Observados de Precipitação, Evapotranspiração e Vazão na Bacia Hidrográfica do Rio Ijuí, Brasil. *Revista Brasileira de Meteorologia* 30, 101-121. <https://doi.org/10.1590/0102-778620140041>
- Palmer, C., Genthon, C., Claud, C., Kay, J.E., Wood, N.B., L'Ecuyer, T., 2017. Evaluation of current and projected Antarctic precipitation in CMIP5 models. *Climate Dynamics* 48, 225-239. <https://doi.org/10.1007/s00382-016-3071-1>
- Park, C., Min, S., Lee, D., Cha, D.H., Suh, M.S., Kang, H.S., Hong, S.Y., Lee, D.K., Baek, H.J., Boo, K.O., Kwon, W.T., 2016. Evaluation of multiple regional climate models for summer climate extremes over East Asia. *Climate Dynamics* 46, 2469-2486. <https://doi.org/10.1007/s00382-015-2713-z>
- PBMC. Painel Brasileiro de Mudanças Climáticas, 2014. Base científica das mudanças climáticas. Contribuição do Grupo de Trabalho 1 do Painel Brasileiro de Mudanças Climáticas ao Primeiro Relatório da Avaliação Nacional sobre Mudanças Climáticas, in: Ambrizzi, T., Araujo, M. (Orgs.), Rio de Janeiro, 464 pp.
- Ploszai, R., Mine, M.R.M., Fill, H.D.O.A., 2015. Comparação de métodos de correção de bias das chuvas geradas por modelos climáticos regionais, in: XXI Simpósio Brasileiro de Recursos Hídricos, Brasília.
- Pesquero, J.F., Chou, S.C., Nobre, C.A., Marengo, J.A., 2010. Climate Downscaling over South America for 1961 - 1970 Using the Eta Model. *Theoretical and Applied Climatology* 99, 75-93. <https://doi.org/10.1007/s00704-009-0123-z>
- Rong, X., Li, J., Chen, H., Xin, Y., Su, J., Hua, L., Zhou, T., Qi, Y., Zhang, Z., Zhang, G., Li, J., 2018. The CAMS Climate System Model and a Basic Evaluation of Its Climatology and Climate Variability Simulation. *Journal of Meteorological Research* 32, 839-861. <https://doi.org/10.1007/s13351-018-8058-x>
- Sachindra, D.A., Huang, F., Barton, A.F., Perera, B.J.C., 2015. Statistical Downscaling of General Circulation Model Outputs to Evaporation, Minimum Temperature and Maximum Temperature Using a Key-Predictand and Key-Station Approach. *Journal of Water and Climate Change* 6, 241-262. <https://doi.org/10.2166/wcc.2014.145>
- Santiago, G.A.C.F., Giarolla, A., Randow, C.V., Menezes, R.S.C., Ometto, J.P.H.B., Nóbrega, R.S., 2016. Avaliação de destreza e das projeções do cenário de mudanças climáticas A1B-Eta-HadCM3 para o estado de Pernambuco. *Revista de Geografia* 33, 29-45.
- Silva, W.L., Dereczynski, C.P., Chou, S.C., Cavalcanti, I., 2014. Future Changes in Temperature and Precipitation Extremes in the State of Rio de Janeiro (Brazil). *American Journal of Climate Change* 3, 353-36. <https://doi.org/10.4236/ajcc.2014.34031>
- Silva, J.G., Wanderley, H.S., Santos, E.O., Lyra, G.B., 2020. Avaliação e correção das simulações do modelo Eta/CPTEC - HADCM3 para o estado do Rio de Janeiro. *Revista Brasileira de Geografia Física* 13, 350-363. <https://doi.org/10.26848/rbgf.v13.1.p350-363>
- Vaittinada Ayar, P., Vrac, M., Bastin, S., Carreau, J., Déqué, M., Gallardo, C., 2016.

- Intercomparison of statistical and dynamical downscaling models under the EURO and MED-CORDEX initiative framework: Present climate evaluations. *Climate Dynamics* 46, 1301-1329. <https://doi.org/10.1007/s00382-015-2647-5>.
- Valverde, M.C., Marengo, J.A., 2010. Mudanças na circulação atmosférica sobre a América do Sul para cenários futuros de clima projetados pelos modelos globais do IPCC AR4. *Revista Brasileira de Meteorologia* 25, 125-145. <https://doi.org/10.1590/S0102-77862010000100011>
- Wang, Y.Q., 2014 MeteoInfo: GIS software for meteorological data visualization and analysis. *Meteorological Applications* 21, 360-368. <https://doi.org/10.1002/met.1345>
- Willmott, C.J., 1981 On the validation of models. *Physical Geography* 2, 184-194.
- Willmott, C.J., Ackleson, S.G., Davis, R.E., Davis, R.E., Feddema, J.J., Klink, K.M., Legates, D.R., O'Donnell, J., Rowe, C.M., 1985. Statistics for the evaluation and comparison of models. *Journal of Geophysical Research: Oceans* 90, 8995-9005. <https://doi.org/10.1029/JC090iC05p08995>