



## **WORKFLOW CIENTÍFICO APLICADO À MODELAGEM CARTOGRÁFICA PARA ESPACIALIZAÇÃO DA IRRADIAÇÃO SOLAR GLOBAL NO ESTADO DO RIO DE JANEIRO PELO MÉTODO DE HARGREAVES-SAMANI**

*Scientific workflow applied to cartographic modeling to spatializing global solar irradiation in the state of Rio de Janeiro through the Hargreaves-Samani method*

*Workflow científico aplicado al modelado cartográfico para espacializar la irradiación solar global en el estado de Rio de Janeiro por el método de Hargreaves-Samani*

Marciano da Costa Lima  

Programa de Pós-Graduação em Ciências Geodésicas, Universidade Federal do Paraná - UFPR

E-mail: marcianodacostalima@gmail.com

Gustavo Bastos Lyra  

Depto. de Ciências Ambientais, Instituto de Florestas, Universidade Federal Rural do Rio de Janeiro - UFRRJ

E-mail: gblyra@ufrj.br

Anderson Amorim Rocha Santos  

Programa de Pós-Graduação em Engenharia de Biosistemas - Universidade Federal Fluminense - UFF

E-mail: aamorimrs@gmail.com

**Resumo:** A disponibilidade de dados de irradiação solar global ( $H_g$ ) consistentes é restrita devido à baixa densidade espacial das estações que realizam medições de  $H_g$ , ou a degradação das redes de observações meteorológicas. Uma alternativa para este problema é a estimativa de  $H_g$  por meio de métodos empíricos baseados em outros elementos meteorológicos obtidos com maior frequência. Dentre esses métodos, destaca-se o de Hargreaves-Samani (1985) (HS) pela simplicidade e desempenho satisfatório em diversas condições climáticas. Este trabalho teve como objetivo avaliar o método de HS para espacialização de  $H_g$  no Estado do Rio de Janeiro (ERJ), utilizando-se de dados dos extremos de temperaturas do ar e  $H_g$  mensal de 17 estações meteorológicas automáticas (EMA) do Instituto Nacional de Meteorologia (INMET). Para isto, elaborou-se um *workflow* baseado em modelos de regressão e modelagem cartográfica para espacializar  $H_g$  pelo método de Hargreaves-Samani. Os valores de  $H_g$  espacializados foram comparados com dados observados nas EMA utilizadas, com base no coeficiente de determinação ( $r^2$ ), índice de concordância de Willmott (d), índice de confiança (c) e a raiz do

quadrado médio do erro (RQME). Observou-se que a aplicação do método apresentou estimativas com alta precisão ( $r^2 > 0,61$ ) e exatidão ( $d > 0,78$  e  $RQME > 1,02 \text{ MJ m}^{-2} \text{ d}^{-1}$ ) quando analisada a sazonalidade, porém em sua análise espacial o método apresentou precisão ( $r^2 > 0,03$ ) e exatidão inferiores ( $d > 0,53$  e  $RQME > 0,55 \text{ MJ m}^{-2} \text{ d}^{-1}$ ). O *workflow* proposto apresenta desempenho satisfatório para representar o padrão mensal de  $H_g$  no ERJ.

**Palavras-chave:** Radiação solar. Temperatura do Ar. Modelos de Regressão. Transmissividade Atmosférica.

**Abstract:** The availability of consistent global solar irradiance ( $H_g$ ) data is restricted due to the low spatial density of stations that perform  $H_g$  measurements and/or degradation of meteorological observation networks. An alternative to this problem is the estimation of  $H_g$  through empirical methods based on other meteorological elements obtained more frequently. Among these methods, the Hargreaves-Samani (1985) (HS) stands out for its simplicity and satisfactory performance in different climate conditions. This study aimed to evaluate the HS method for  $H_g$  spatialization in the State of Rio de Janeiro (Estado do Rio de Janeiro - ERJ), using data from air temperature extremes and monthly  $H_g$  from 17 automatic weather stations (EMA) of the Instituto Nacional de Meteorologia (INMET). For this, a workflow was developed based on regression models and cartographic modeling to spatialize  $H_g$  using the Hargreaves-Samani method. Spatialized  $H_g$  values were compared with data observed in the EMAs used, based on the coefficient of determination ( $r^2$ ), Willmott's concordance index ( $d$ ), confidence index ( $c$ ), and the root means square error (RQME). It was observed that the application of the method presented estimates with high precision ( $r^2 > 0.61$ ) and accuracy ( $d > 0.78$  and  $RQME > 1.02 \text{ MJ m}^{-2} \text{ d}^{-1}$ ) when seasonality was analyzed, but in its spatial analysis, the method showed lower precision ( $r^2 > 0.03$ ) and accuracy ( $d > 0.53$  and  $RQME > 0.55 \text{ MJ m}^{-2} \text{ d}^{-1}$ ). The proposed workflow presents satisfactory performance to represent the monthly  $H_g$  pattern in the ERJ.

**Keywords:** Solar radiation. Air Temperature. Regression Models. Atmospheric Transmissivity.

**Resumen:** La disponibilidad de datos consistentes de irradiancia solar ( $H_g$ ) global está restringida debido a la baja densidad espacial de las estaciones que realizan mediciones de  $H_g$  y/o la degradación de las redes de observación meteorológica. Una alternativa a este problema es la estimación de  $H_g$ , mediante métodos empíricos basados en otros elementos meteorológicos obtenidos con mayor frecuencia. Entre estos métodos, el de Hargreaves-Samani (1985) (HS) destaca por su sencillez y desempeño satisfactorio en diferentes condiciones climáticas. Este estudio tuvo como objetivo evaluar el método HS para la espacialización de  $H_g$  en el Estado de Río de Janeiro (ERJ), utilizando datos de temperaturas extremas del aire y  $H_g$  mensuales de 17 estaciones meteorológicas automáticas (EMA) del Instituto Nacional de Meteorología (INMET). Para ello se desarrolló un flujo de trabajo basado en modelos de regresión y modelado cartográfico para espacializar  $H_g$  utilizando el método de Hargreaves-Samani. Los valores de  $H_g$  espacializados se compararon con los datos observados en los EMA utilizados, con base en el coeficiente de determinación ( $r^2$ ), el índice de concordancia de Willmott ( $d$ ), el índice de confianza ( $c$ ) y la raíz del error cuadrático medio (RQME). Se observó que la aplicación del método presentó estimaciones con alta precisión ( $r^2 > 0.61$ ) y exactitud ( $d > 0.78$  y  $RQME > 1.02 \text{ MJ m}^{-2} \text{ d}^{-1}$ ) cuando se analizó la estacionalidad, pero en su análisis espacial, el método mostró menor precisión ( $r^2 > 0,03$ ) y exactitud ( $d > 0,53$  y  $RQME > 0,55 \text{ MJ m}^{-2} \text{ d}^{-1}$ ). El flujo de trabajo propuesto presenta un rendimiento satisfactorio para representar el patrón mensual de  $H_g$  en la ERJ.

**Palabras clave:** Radiación solar. Modelos de regresión de temperatura del aire. Transmisividad atmosférica.

Submetido em: 30/11/2021

Aceito para publicação em: 26/04/2022

Publicado em: 05/05/2022



## INTRODUÇÃO

Com o aumento da demanda por energias renováveis, com baixa emissão de Gases de Efeito Estufa (e.g. CO<sub>2</sub>, CH<sub>4</sub>) e, ou poluentes, a energia solar se destaca por tratar de recurso abundante. A energia solar pode ser transformada diretamente em energia elétrica por sistemas fotovoltaicos ou indiretamente por aquecimento de fluídos (ROSA et al., 2017). Além da aplicação para a geração de energia, a radiação solar, condiciona diversos processos do ambiente natural, como por exemplo, a fotossíntese, evapotranspiração, aquecimento do ar e do solo e a formação e manutenção de sistemas meteorológicos (ALLEN et al., 1998; PEREIRA; ANGELOCCI). Assim, o conhecimento da irradiação solar global –  $H_g$  (integral da irradiância solar no tempo) é essencial em diversos estudos nas áreas de meteorologia, climatologia, meio ambiente, agricultura, floresta, ecologia e energias renováveis.

No Brasil, a baixa densidade de estações meteorológicas e, ou solarimétricas que realizam observações contínuas de longo tempo de  $H_g$  e, ou a deterioração dos instrumentos de medida, e.g. actinógrafos e piranômetros, nas estações meteorológicas diminuiu a cobertura espacial, frequência e consistência dos dados de  $H_g$  (WEBER, 2011; LIMA et al., 2019; PESSANHA et al., 2021). Uma alternativa para obter séries contínuas de longo tempo de  $H_g$  distribuídas de forma regular no espaço é o uso de modelos matemáticos. Estes modelos podem estimar  $H_g$  sobre uma superfície horizontal plana em dada escala de tempo (horária, diária ou mensal), em função de elementos medidos com maior frequência em estações meteorológicas de superfície, como por exemplo, a duração de brilho solar, temperatura do ar ou precipitação (SANTOS et al., 2016; LIMA et al., 2019).

Na ausência ou restrição de dados de  $H_g$ , estes podem ser estimados por meio de modelos empíricos (BORGES et al., 2010; SANTOS et al., 2016; LIMA et al. 2019), que necessitam de menor número de dados de entrada. A Organização das Nações Unidas para Agricultura e Alimentação (*Food and Agriculture Organization* - FAO) em seu boletim Nº 56 de irrigação e drenagem, recomenda o modelo de Hargreaves e Samani (1985) na falta de observações de  $H_g$  (ALLEN et al., 1998; JERSZURKI; SOUZA, 2013). O modelo Hargreaves-Samani (HARGREAVES; SAMANI, 1985) é função apenas da amplitude térmica diária, da irradiação solar no topo da atmosfera e de um coeficiente empírico ( $K_r$ ). O modelo apresenta desempenho satisfatório para estimava de  $H_g$  no estado do Rio de Janeiro e na região Sudeste, com precisão e acurácia das estimativas similar ou superior a outros métodos baseados em temperatura do ar, e.g., Bristow-Campbell (MARTINS MONTEIRO; MARTINS, 2019; LIMA et al., 2019).

Os ambientes SIG (Sistema de Informações Geográficas), devido a sua capacidade analítica, podem ser associados com modelos para espacializar  $H_g$  em diversos tipos de clima, relevo e em escalas

de tempo e espaço variadas (WEBER, 2011). O uso da modelagem cartográfica para modelos climáticos estimados dentro de um ambiente SIG foi avaliado por diversos autores em diferentes latitudes e climas (SANTOS, 2016; DOS SANTOS et al., 2018; LIMA et al., 2019; MONTEIRO; MARTINS, 2019). Contudo, na modelagem cartográfica são utilizadas ferramentas de SIG de forma sequenciada, aplicadas a diversos mapas *raster* de entrada e, que para cada mapa *raster* de saída devem ser repetidas as sequências de operações, definidos parâmetros e outros, que demandam tempo e recursos humanos, além da possibilidade de erros no processamento.

A necessidade de realizar de forma eficiente, padronizada, sistematizada e controlada a execução de processos fez com que se popularizasse o uso de sistemas *workflow* (fluxo de trabalho) nas últimas décadas (DAVIDSON; FREIRE, 2008). O uso de *workflow* é difundido no meio administrativo, como forma de automatizar processos de negócios, entretanto com o avanço da informática ele se tornou uma poderosa ferramenta na automação de tarefas onerosas, nas quais o fator humano pode provocar falhas, como no caso de execução de tarefas repetitivas (WFMC, 2016). Assim, este trabalho visa propor um *workflow* científico em um ambiente SIG, utilizando o software QGIS para espacializar a irradiação solar global média mensal no estado do Rio de Janeiro pelo modelo de Hargreaves-Samani.

## METODOLOGIA

### Área de estudo e séries climáticas

O Estado do Rio de Janeiro (ERJ) localiza-se na região Sudeste (SE) do Brasil, entre as longitudes 40° 57' 59" e 44° 53' 18" W e as latitudes 20° 45' 54" e 23° 21' 57" S. O ERJ faz divisa com todos os estados que compõem a região SE, sendo limitado a norte por Minas Gerais (MG), a oeste por São Paulo (SP), a nordeste pelo Espírito Santo (ES) e a sul e a leste pelo Oceano Atlântico. Segundo a classificação climática de Thornthwaite, o Rio de Janeiro apresenta climas úmidos e subúmidos, com algumas regiões subúmidas secas e semiáridas (Norte, Noroeste e Baixadas), associadas a condições megatérmicas ou mesotérmicas (SANTOS et al., 2016). Nas áreas úmidas, é predominante durante todo o ano a ocorrência de chuvas. Nas subúmidas, quatro a seis meses do ano são secos, praticamente sem chuva durante este período. Nas subúmidas secas e semiáridas, são mais de sete meses com baixos (< 60 mm) totais de precipitação (CEPERJ, 2016). Os períodos secos coincidem com o inverno e meses de transição outono-inverno ou inverno-primavera (BRITO et al., 2017). Os climas mesotérmicos ocorrem nas regiões das serras do Mar, Órgãos e Mantiqueira, sendo observado nas demais regiões do ERJ clima megatérmico.

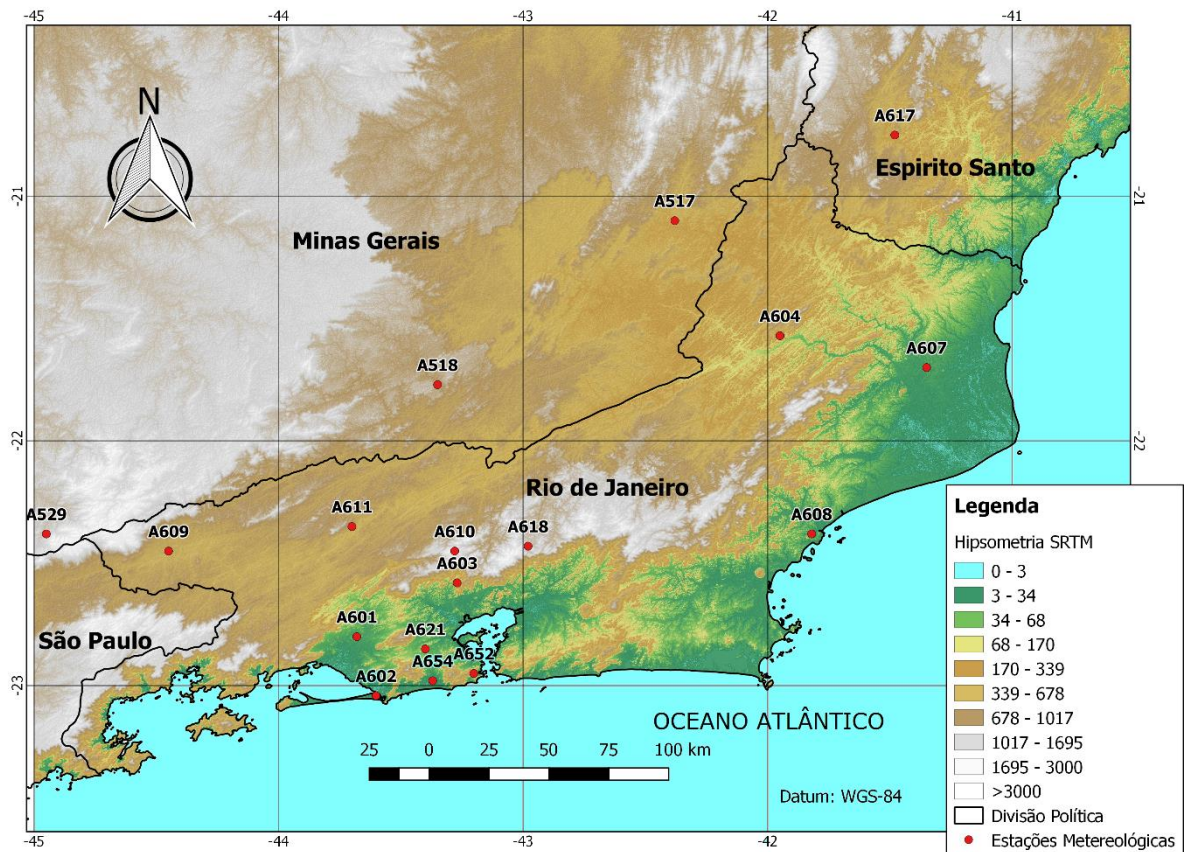
As séries climáticas diárias de temperatura do ar máxima ( $t_x$ , °C) e mínima ( $t_n$ , °C) e de irradiação solar global ( $H_g$ , MJ m<sup>-2</sup> d<sup>-1</sup>) foram obtidas na base de dados do Instituto Nacional de Meteorologia (INMET). Utilizaram-se séries de 17 estações meteorológicas automáticas (EMA), entre o período 2000 a 2013, e que apresentavam mais de cinco anos de observações (Tabela 1), as quais estavam distribuídas no estado do Rio de Janeiro (RJ), Espírito Santo (ES), São Paulo (SP) e Minas Gerais (MG). A distribuição espacial destas estações meteorológicas pode ser observada no mapa hipsométrico (Figura 1). Detalhes do tratamento das séries e análise de qualidade dos dados são descritos por Lima et al. (2019).

**Tabela 1** - Identificador (ID), nome, Unidade da Federação (UF), coordenadas geográficas das Estações meteorológicas do Instituto Nacional de Meteorologia (INMET) com período (início e fim) e falhas (%) das séries de irradiação solar global.

ID	Nome	UF	Latitude (°)	Longitude (°)	Altitude (m)	Início	Fim	Falhas (%)
A617	Alegre	ES	-20,75	-41,48	138	2006	2013	4
A517	Muriaé	MG	-21,01	-42,38	297	2006	2013	3
A518	Juiz de Fora	MG	-21,77	-43,35	950	2007	2013	4
A529	Passa Quatro	MG	-22,38	-44,95	1040	2007	2013	14
A601	Ecologia Agrícola	RJ	-22,08	-43,68	34	2000	2013	15
A602	Marambaia	RJ	-23,05	-43,06	10	2002	2013	22
A603	Xerém	RJ	-22,58	-43,27	33	2002	2013	28
A604	Cambuci	RJ	-21,57	-41,95	35	2002	2013	23
A607	Campos	RJ	-21,07	-41,35	25	2006	2013	4
A608	Macaé	RJ	-22,38	-41,82	32	2006	2013	6
A609	Resende	RJ	-22,45	-44,45	440	2006	2013	6
A610	Pico do Couto	RJ	-22,45	-43,28	1777	2006	2013	8
A611	Valença	RJ	-22,35	-43,07	367	2006	2013	7
A618	Teresópolis	RJ	-22,43	-42,98	980	2006	2013	2
A621	Vila Militar	RJ	-22,85	-43,04	45	2007	2013	13
A652	Copacabana	RJ	-22,98	-43,18	45	2007	2013	8
A654	Jacarepaguá	RJ	-22,98	-43,37	19	2007	2013	6

Fonte: Os autores (2022).

**Figura 1** - Mapa hipsométrico do Estado do RJ e distribuição espacial das estações meteorológicas.

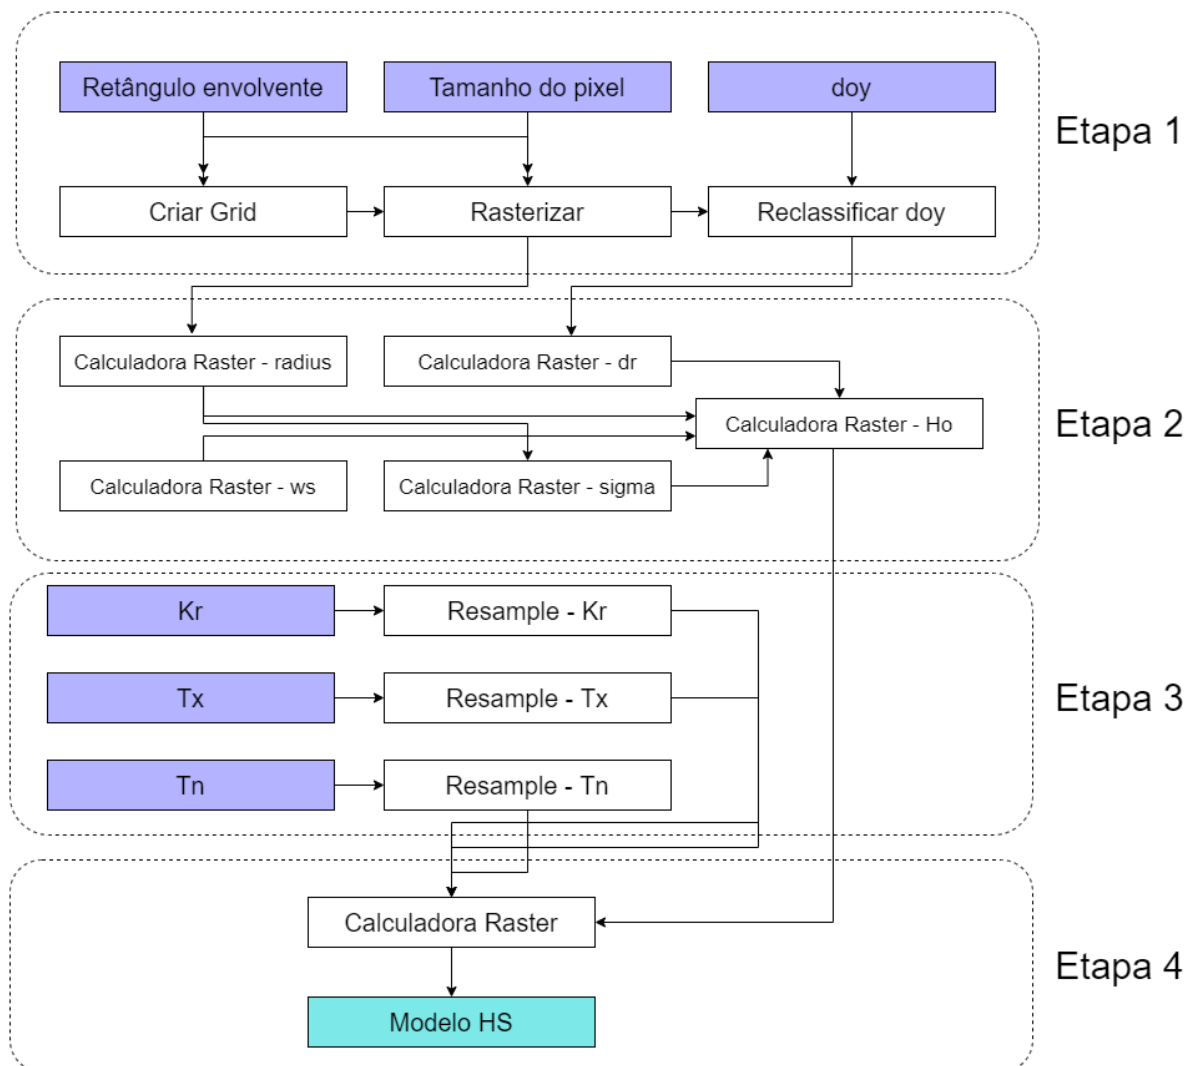


Fonte: Os autores (2022).

## Modelo Cartográfico

Para espacialização de  $H_g$  média mensal de forma manual, o trabalho humano demandado é maior, além de gerar grande volume de mapas intermediários em cada etapa realizada. Para a implementação do *workflow* científico, utilizou-se técnicas de álgebra de mapas por meio da ferramenta *graphical modeler* no software de SIG QGIS 2.18.3 (QGIS, 2018). O *workflow* científico proposto é apresentado na Figura 2, o qual foi particionado em quatro etapas para fins didático.

**Figura 2 - Workflow** utilizado na modelagem cartográfica, desenvolvido na ferramenta *Graphical Modeler* do QGIS.



Fonte: Os autores (2022).

**– Etapa 1 (definição da grade):**

Os dados de entrada, como constantes necessárias às equações implementadas e mapas *raster* estão representados por retângulos de cor lilás. As ferramentas utilizadas pelo QGIS, que realizam os processamentos dos dados, são representados pelos retângulos de cor branca. Por fim, o resultado final (mapa *raster*) é representado pelo retângulo azul.

Para a espacialização de  $H_g$  médio mensal por modelagem cartográfica, o método de Hargreaves-Samani foi resolvido em uma grade delimitada pela área de estudo, definida na Etapa 1 da Figura 2. Contudo, para solução do modelo, aplicou-se diversas análises intermediárias, realizadas por meio de diferentes ferramentas e diversos dados de entrada (Etapas 1 a 3 - Figura 2).

**– Etapa 2 (termos da radiação):**

O método de Hargreaves-Samani relaciona a amplitude térmica com a transmitância da atmosfera ( $H_g/H_o$ ) e, dessa forma, com a nebulosidade, pela relação (HARGREAVES; SAMANI, 1985):

$$H_g = H_o k_r (t_x - t_n)^{0,5} \quad (01)$$

em que:  $H_g$  ( $\text{MJ m}^{-2} \text{ d}^{-1}$ ) é a irradiação solar global;  $H_o$  ( $\text{MJ m}^{-2} \text{ d}^{-1}$ ) é a irradiação solar no topo da atmosfera;  $k_r$  é um coeficiente empírico adimensional; e  $t_x$  e  $t_n$  ( $^{\circ}\text{C}$ ) são a temperatura do ar máxima e mínima, respectivamente.

A irradiação solar no topo da atmosfera média mensal foi estimada como resultante da aplicação da lei do cosseno de Lambert, latitude ( $\phi$ ), declinação solar ( $\delta$ ), distância Terra-Sol, ângulo horário entre o nascer e do pôr do Sol ( $H$ ) e um fator de correção da distância Terra-Sol de acordo com o dia de ordem do ano, obtendo-se a Equação 02. Esta equação é desenvolvida pelo *workflow* dentro da Etapa 2 da Figura 2.

$$H_o = 37,60 \times \left(\frac{d}{D}\right)^2 \times \left[\left(\frac{\pi}{180}\right) H \sin(\phi) + \cos(\delta) \times \cos(\delta) \times \sin(H)\right] \quad (02)$$

Para o valor do coeficiente empírico  $k_r$ , Hargreaves (1994) propôs dois valores distintos, definindo-os entre regiões costeiras ( $0,190 \text{ }^{\circ}\text{C}^{-0,5}$ ) e regiões interioranas ( $0,162 \text{ }^{\circ}\text{C}^{-0,5}$ ). Entretanto, valores generalizados não descrevem com precisão o valor de  $k_r$  para certas localidades (LYRA et al. 2015; GOIS et al. 2016; LIMA et al., 2019), sendo para isso necessário o ajuste local deste coeficiente.

**– Etapa 3 (mapas de entrada do modelo):**

O mapa *raster* do coeficiente empírico  $k_r$  foi obtido pela solução do modelo polinomial de segundo grau proposto por Samani (2000) e ajustado para a região SEB por Lima et al. (2019), sendo este:

$$k_r = 0,3999 - 0,0406 \Delta T + 0,00160(\Delta T)^2 \quad (03)$$

em que: o valor de  $\Delta T$  é a diferença entre os mapas *raster* de temperatura do ar máxima e mínima anual obtidos pela Equação 04. Para solução da Equação 03 em ponto de grade (Etapa 2 - Figura 2), utilizou-se a ferramenta *raster calculator* do software QGIS, que permite realizar operações entre mapas *raster* e escalares.

$$T_i = A_0 + A_1 Z + A_2 Z^2 + A_3 \lambda + A_4 \lambda^2 + A_5 \varphi + A_6 \varphi^2 \quad (04)$$

Os valores médios mensais de  $t_n$  e  $t_x$  usados na Equação 01 foram espacializados, por meio do modelo de regressão múltipla (LYRA et al. 2011) (Equação 04), em que  $T_i$  são as temperaturas do ar



(máxima -  $t_x$ , mínima -  $t_n$  ou média -  $t_m$ ) mensais;  $\lambda$  é a longitude da estação em graus decimais (valores negativos);  $\phi$  é a latitude da estação em graus decimais (valores negativos);  $Z$  é a altitude da estação em metros; e  $A_n$  representam os coeficientes da equação de regressão a serem ajustados.

O modelo polinomial (Equação 04) foi previamente ajustado aos dados observados médios mensais de  $t_x$  e  $t_n$  das  $n$ -ésimas EMAs pelo método dos mínimos quadrados. O ajuste do modelo foi avaliado pelo coeficiente de determinação ( $r^2$ ) e pela análise de variância (ANOVA) a  $p < 0,05$ . Para os coeficientes do modelo aplicou-se o teste-t ( $p < 0,05$ ), sendo testada as hipóteses:  $H_0: A = 0$ ;  $H_a: A \neq 0$ .

Para espacializar a temperatura do ar da área de estudo (Etapa 4 – Figura 2), as regressões ajustadas para cada mês foram resolvidas com auxílio da ferramenta *raster calculator* do QGIS. Para isso, foi necessário gerar anteriormente mapas *raster* com a latitude e longitude para serem usados nas operações algébricas entre mapas e escalares, o que permitiu resolver os modelos ajustados (Equação 04). Os mapas de latitude e longitude foram obtidos por meio da ferramenta *create grid*, no software QGIS. Esta etapa foi realizada anteriormente, pois estes dados eram necessários como dados de entrada no modelo *workflow* proposto, estando, portanto, fora do modelo apresentado na Figura 2.

#### – Etapa 4 (resolução):

O modelo foi resolvido em grade com auxílio da ferramenta *raster calculator* (Etapa 4 - Figura 2) no ambiente de desenvolvimento do *workflow*. A altitude foi representada pelo Modelo Digital de Elevação (MDE) elaborado pelo projeto *Shuttle Radar Topography Mission* (SRTM) (VALERIANO; ROSSETTI, 2012). Realizou-se o mosaico das cenas do SRTM, no formato geotiff (*raster*), para a área de estudo usando o QGIS (QGIS, 2018). Posteriormente, o mosaico na resolução de 90 m foi reamostrado pelo método do vizinho mais próximo (*resampling*) para uma resolução de 5 km, conforme método utilizado por Lyra et al. (2011). Dessa forma, os mapas de temperatura do ar apresentaram resolução de 5 km e por consequência, os mapas do modelo de Hargreaves-Samani.

## Análise Estatística

Para a avaliação do método de estimativa de irradiação solar global ( $H_g$ ) como parte do *workflow* científico desenvolvido, foram extraídos dados dos mapas mensais interpolados no ponto de coordenada das estações meteorológicas com auxílio da ferramenta *v.sample* do SIG-GRASS e disponível por *plugin* no QGIS. Nesta etapa foram consideradas apenas as 17 estações localizadas no estado do Rio de Janeiro.

Foi aplicada a análise de regressão linear simples ( $Y = \beta_0 + \beta_1 X$ ) entre  $H_g$  estimada pelo workflow científico (Y) e a observada pela EMA (X) e o seu coeficiente de determinação ( $r^2$ ). O teste t de Student foi aplicado para avaliar estatisticamente o intercepto ( $H_0: \beta_0 = 0$ ;  $H_a: \beta_0 \neq 0$ ) e a inclinação da reta ( $H_0: \beta_1 = 0$ ;  $H_a: \beta_1 \neq 0$ ) da regressão linear,  $Y = X$ .

Avaliou-se a medida da qualidade do ajuste da regressão com base no coeficiente de determinação ( $r^2$ ). Esse coeficiente fornece um resultado entre zero e um, sendo 1 o ajuste perfeito dos valores estimados com os valores observados, ou seja, a correlação entre esses dados será máxima.

$$r^2 = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (05)$$

em que: n é o número de observações,  $y_i$  é o valor observado,  $\hat{y}_i$  é o valor estimado (especializado) e  $\bar{y}$  é a média das observações. Para a realização da medida da precisão dos resultados foi utilizado a Raiz do Quadrado Médio do Erro (RQME), o qual calcula o erro médio quadrático da diferença entre a estimativa e o valor observado.

$$RQME = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (06)$$

O valor de RQME é sempre positivo, e varia de zero até um número infinito, sendo quanto maior este resultado, maior a diferença entre os valores estimados e observados, sendo zero a previsão perfeita. Assim, quanto menor o valor de RQME, melhor o ajuste realizado.

A exatidão entre valores observados e preditos foi representado pelo índice de concordância (d) proposto por Willmott et al. (1981). Este índice apresenta valor adimensional, sendo o ajuste nulo ( $d = 0$ , nenhuma concordância) ou completo ( $d = 1$ , concordância perfeita).

$$d = 1 - \left[ \frac{\sum (Y_i - X_i)^2}{\sum (|Y_i - \bar{X}| + |X_i - \bar{X}|)^2} \right] \quad (07)$$

em que:  $\bar{X}$  é a média dos valores de  $H_g$  estimados pelo *workflow* e  $X_i$  os valores observados.

Uma nova abordagem foi desenvolvida por Camargo e Sentelhas (1997), utilizando o índice d de Willmott (concordância) e o coeficiente de correlação (r), analisando o desempenho do modelo com base no valor dado. Este índice foi denominado índice de confiança (c), com variação de 0 a 1, em que 0 é valor que indica confiança nula e 1 o valor de confiança perfeita.

$$c = r \times d \quad (08)$$

Como este índice é resultado de outros dois índices de avaliação (correlação, r; e concordância, d), ele é diretamente proporcional aos valores dos mesmos, logo, quanto maior a correlação e a

concordância, maior será também a confiança. Camargo e Sentelhas (1997) propuseram também um critério de interpretação do desempenho do método de forma qualitativa, conforme Tabela 2.

**Tabela 2-** Critério de interpretação do desempenho do método pelo índice c de Camargo e Sentelhas (1997).

Valor de c	Desempenho
Acima de 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 0,6	Sofrível
0,41 a 0,5	Mau
Abaixo de 0,4	Péssimo

Fonte: Camargo e Sentelhas (1997).

## DESENVOLVIMENTO

Os resultados obtidos pelo *workflow* científico proposto, aplicando-se o modelo de Hargreaves-Samani dentro de um ambiente SIG, foram analisados estatisticamente sazonal e espacialmente utilizando como referência os dados observados de  $H_g$  médio mensal das estações do INMET. Os dados observados utilizados no presente trabalho foram os mesmos utilizados por Lima et al. (2019) ao ajustar a Equação 03.

## Análise Espacial

Para a análise espacial, compararam-se os valores de  $H_g$  de todas as estações meteorológicas para cada mês, com os valores obtidos pela espacialização de  $H_g$  mensal gerada pelo modelo de Hargreaves-Samani nas coordenadas destas estações. Assim foram analisados para cada mês os valores observados das 17 estações do INMET estudadas versus os valores espacializados.

O coeficiente de determinação ( $r^2$ ) para a análise espacial mostrou que os meses com maiores precisões das estimativas foram maio (0,47), janeiro e fevereiro, ambos com  $r^2 = 0,45$ , e os meses de menor precisão foram abril (0,03) e junho (0,11) (Tabela 3). Para o índice d de concordância de Willmott, as análises espaciais indicaram que os meses de maior exatidão das estimativas foram maio (0,81) e dezembro (0,69), e os menores foram junho, setembro e novembro, estes com 0,53.

**Tabela 3-** Coeficientes linear ( $\beta_0$ ), angular ( $\beta_1$ ) e de determinação ( $r^2$ ) da regressão linear simples entre as estimativas de irradiação solar pelo modelo de Hargreaves-Samani em relação aos dados observados da análise espacial dos dados. Raiz do Quadrado Médio do Erro (RQME), Raiz do Quadrado Médio do Erro Percentual (RQME%), índice de concordância de Willmott (d) e de desempenho de Camargo e Sentelhas (c)

Mês	$\beta_0$ (MJ m <sup>-2</sup> d <sup>-1</sup> )	$\beta_1$	$r^2$	RQME (MJ m <sup>-2</sup> d <sup>-1</sup> )	RQME (%)	d	c
Janeiro	12,37	0,46	0,45	2,51	13,27	0,62	0,42
Fevereiro	9,26	0,51	0,45	1,94	8,80	0,64	0,43
Março	13,74	0,24	0,11	1,42	7,89	0,58	0,20
Abril	13,27	0,12	0,03	1,23	8,04	0,55	0,09
Mai	5,14	0,60	0,47	0,55	4,27	0,81	0,56
Junho	10,10	0,17	0,11	1,10	9,35	0,53	0,18
Julho	10,13	0,20	0,21	1,21	9,57	0,64	0,29
Agosto	11,10	0,27	0,29	1,27	8,56	0,65	0,35
Setembro	12,10	0,31	0,39	1,71	10,70	0,53	0,33
Outubro	11,49	0,42	0,22	1,56	8,79	0,60	0,28
Novembro	15,17	0,23	0,12	2,26	12,88	0,53	0,18
Dezembro	11,95	0,45	0,38	1,87	9,69	0,69	0,43

Fonte: Os autores (2022).

É desejável que o coeficiente  $\beta_0$  seja o mais próximo de 0 possível. Para a análise espacial encontraram-se os melhores resultados atendendo esse parâmetro para os meses de maio (5,14) e fevereiro (9,26), e os piores resultados aos meses de novembro (15,17), março (13,74) e abril (13,27), respetivamente. Espera-se que o coeficiente  $\beta_1$  seja o mais próximo de 1. Observou-se pela análise espacial que os meses que melhor atenderam esta característica foram abril (0,12) e junho (0,17), enquanto os meses que se afastaram mais do valor ideal foram maio (0,60) e fevereiro (0,51).

Para as análises espaciais, os menores RQME foram para os meses de maio (0,55 MJ m<sup>-2</sup> d<sup>-1</sup>) e junho (1,10 MJ m<sup>-2</sup> d<sup>-1</sup>) e os de maiores erros foram observados para os meses de janeiro (2,51 MJ m<sup>-2</sup> d<sup>-1</sup>) e novembro (2,26 MJ m<sup>-2</sup> d<sup>-1</sup>). Para o RQME percentual, que por ser o erro relativo à média expressa visualmente os resultados em percentagem, verificou-se variação de 4,27% para maio (menor variação) à 13,27% para janeiro (maior variação).

Por fim, foram categorizados os dados obtidos para o índice c de Camargo e Sentelhas (1997), em que para a análise espacial, maio (c = 0,56) apresentou o melhor resultado, classificado com desempenho “Sofrível” (0,51 ≤ c ≤ 0,60), os meses de janeiro (c = 0,42), fevereiro (c = 0,43) e dezembro (c = 0,43) apresentaram desempenho “Mau” (0,41 ≤ c ≤ 0,50), e os demais meses apresentaram desempenho “Péssimo” (c ≤ 0,40).

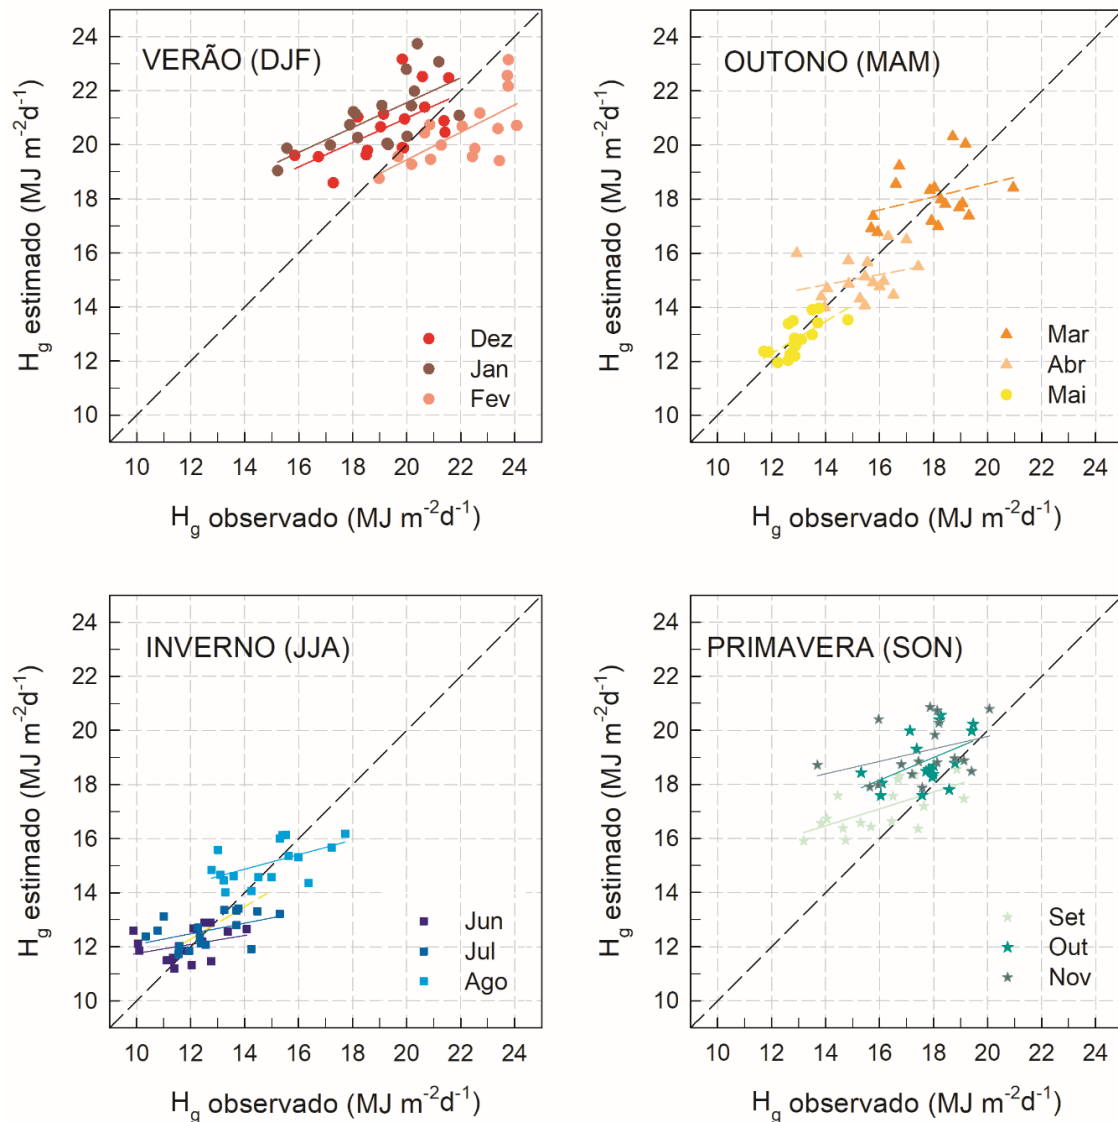




A baixa precisão ( $r^2$ ), principalmente do modelo em representar a distribuição espacial de  $H_g$ , pode estar relacionado a baixa precisão na espacialização dos extremos de temperatura do ar (resultados não apresentados). Nas condições de relevo complexo do ERJ, com regiões de baixadas próximas ao ambiente costeiro, que alternam com serras e montanhas de altitude superiores 1500 m, os modelos de regressão não conseguem representar adequadamente a distribuição espacial de  $t_x$  e  $t_n$ . De qualquer forma, os valores de  $r^2$  foram similares aos obtidos por Pessanha et al. (2021) ao espacializar  $H_g$  mensal pelo método da Krigagem ordinária ( $r^2 < 0,47$ ) para o ERJ, contudo inferiores aos métodos do inverso do quadrado da distância e do *spline tension* ( $r^2 > 0,90$ ). No caso, da RQME os valores obtidos no presente trabalho foram no intervalo dos observados por Pessanha et al. (2021) para todos os métodos avaliados por esses autores e entre 3,4 e 10,1%.

Os gráficos de dispersão dos resultados obtidos nas análises estatísticas mês a mês são apresentados na Figura 3. Neles estão representados os pontos com relação aos eixos das abcissas (valores observados) e das ordenadas (valores estimados). A reta tracejada um para um (1:1) representa o ajuste perfeito entre os valores observados e estimados. Quando os pontos se localizam acima da reta 1:1, indica superestimativa do modelo, caso contrário, abaixo da reta, subestimativa.

**Figura 3** - Relação entre a irradiação solar global ( $H_g$ ) observada e interpolada para os meses das estações do ano a) verão, b) outono, c) inverno e d) primavera.



Fonte: Os autores (2022).

Em parte do verão (dezembro e janeiro) o método de interpolação mostrou tendência de superestimar a maioria dos valores de  $H_g$ , enquanto em fevereiro observou-se padrão de subestimativa de todos os valores de  $H_g$  (Figura 3). Similar a dezembro e janeiro, nos meses de primavera (SON) observou-se superestimativa de  $H_g$ . Nos meses de outono e inverno, a tendência foi de subestimar os menores valores de  $H_g$  e superestimar os maiores. A análise do gráfico de dispersão confirmou a baixa precisão na estimativa dos dados, sendo que em nenhum mês as estimativas apresentaram  $r^2$  maior do que 0,5. Isto pode ser explicado devido a uma série de fatores (e.g. relevo complexo, efeito continentalidade/maritimidade), que caracterizam o estado do Rio de Janeiro e a distribuição das estações meteorológicas do INMET, além dos próprios erros agregados ao modelo utilizado. Ademais,

foi utilizado no *workflow* (Figura 02) o modelo de  $k_r$  (Equação 03) ajustado por Lima et al. (2019) para toda a região Sudeste do Brasil e não especificamente para a área de estudo do presente trabalho.

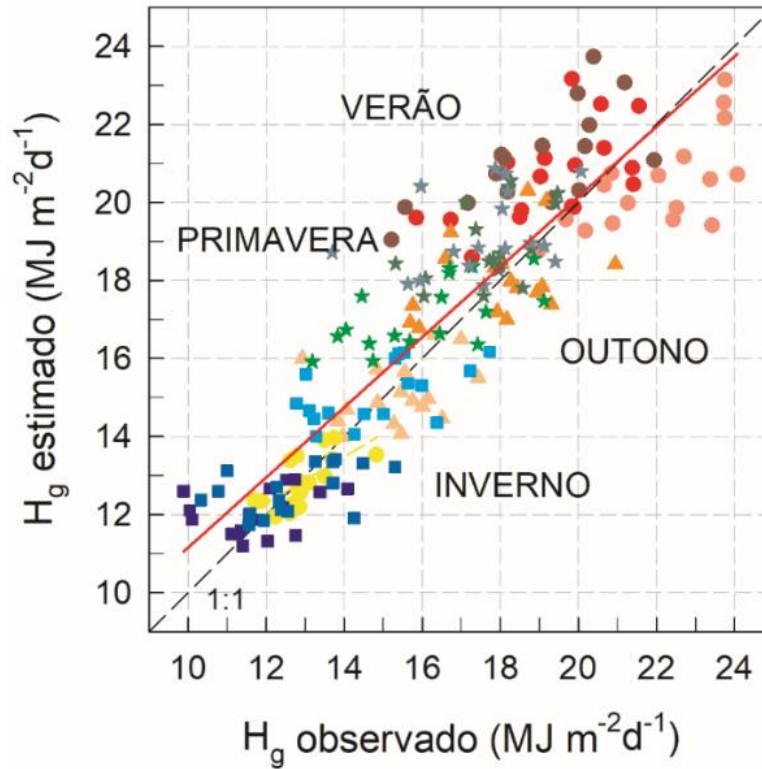
Lima (2016) destacou ainda que, para o modelo de estimativa do coeficiente  $k_r$  proposto para a região Sudeste, apenas no estado do Rio de Janeiro foram observados valores de  $k_r$  superiores a 0,200, nas estações das regiões subúmidas secas e semiáridas situadas em zonas costeiras e com temperatura do ar média anual elevada, além de apresentar maior amplitude nos valores deste coeficiente pelo método proposto. Pessanha et al. (2021) estudaram diferentes métodos de interpolação espacial (inverso do quadrado da distância, Krigagem ordinária e *spline tension*) aplicados à média mensal de  $H_g$  diário no Estado do RJ. Os autores observaram que em condições de distribuição heterogênea de estações, baixa densidade de estações e terreno complexo, como é o caso do RJ, o método da Krigagem não produziu interpolação espacial precisa para  $H_g$  mensal.

A distribuição heterogênea das estações meteorológicas do INMET, com altitudes variando de 19 a 1777 metros, além da baixa quantidade de estações no estado do Rio de Janeiro, pode ser um fator determinante para a baixa precisão de estimativa dos dados. Santos (2016) analisou para o estado do Rio de Janeiro um método de estimativa de outra variável climática (evapotranspiração), que também se utiliza das temperaturas máximas e mínimas do ar e obteve  $r^2$  para os meses do ano variando entre 0,12 (outubro) e 0,53 (julho). Santos (2016) associou esses resultados aos diversos fatores fisiográficos do Estado, como relevo complexo e continentalidade/oceanidade. Mazzarella et al. (2019) apontam em seu estudo que o modelo de Hargreaves-Samani para estimativa de  $H_g$  média mensal no Estado do RJ, utilizando o coeficiente proposto por Hargreaves (1994) em relação ao calibrado por Allen (1995), apresenta estimativas mais precisas, entretanto possui ressalvas para a região costeira. Outro fator apontado por Silva e Vieira (2016) indica que nos períodos de transição entre estações do ano, modelos de estimativas sazonais tendem a apresentar resultados abaixo do esperado.

Quando considerado todos os meses e estações na análise de regressão e nos índices estatísticos, o  $r^2$  (0,79) e o  $d$  (0,93), foram superiores ao observado para os meses separadamente, o que, segundo Willmott (1981) pode estar relacionado ao maior número de observações avaliadas e a maior amplitude dos dados, o que resulta em maiores  $r^2$  (Figura 4). O RQME foi de 1,64 MJ m<sup>2</sup> d<sup>-1</sup> em valores absolutos e de em torno de 10 %, em termos de valores relativos à média. A precisão e exatidão do método proposto no presente trabalho foi inferior ( $r^2 > 0,83$  e RQME  $< 7,87$  %) ao observado por Pessanha et al. (2021) para interpolação de  $H_g$  no estado do Rio de Janeiro pelos métodos do inverso do quadrado da distância, *spline* e Krigagem ordinária para todos os modelos de semivariograma

(Gaussiano, exponencial e esférico) avaliados.

**Figura 4** - Relação entre a irradiação solar global ( $H_g$ ) observada e interpolada pelo *workflow* para todos os meses do ano.



Fonte: Os autores (2022).

## Análise Sazonal

Para a análise sazonal, obtiveram-se os valores de  $H_g$  para as coordenadas de cada uma das 17 estações do INMET. Assim, para cada estação meteorológica, foram comparados os valores mensais observados de  $H_g$  com os valores espacializados para todos os meses. Os resultados encontrados estão dispostos na Tabela 4, onde cada linha apresenta as análises estatísticas sazonal de cada estação meteorológica do INMET.



**Tabela 4-** Coeficiente linear ( $\beta_0$ ), angular ( $\beta_1$ ) e de determinação ( $r^2$ ) da regressão linear simples entre as estimativas de irradiação solar pelo modelo de Hargreaves-Samani em relação aos dados observados da análise sazonal dos dados. Raiz do Quadrado Médio do Erro (RQME), Raiz do Quadrado Médio do Erro Percentual (RQME%), índice de concordância de Willmott (d) e de desempenho de Camargo e Sentelhas (c).

Estações	$\beta_0$ (MJ m <sup>-2</sup> d <sup>-1</sup> )	$\beta_1$	$r^2$	RQME (MJ m <sup>-2</sup> d <sup>-1</sup> )	RQME (%)	d	c
A517	0,73	0,93	0,88	1,09	6,35%	0,96	0,90
A518	-1,29	1,18	0,81	2,13	13,30%	0,85	0,77
A529	-3,83	1,23	0,87	1,27	7,24%	0,95	0,88
A601	-0,65	1,04	0,89	1,02	6,42%	0,97	0,91
A602	1,60	0,88	0,92	1,10	6,42%	0,97	0,93
A603	-0,49	1,11	0,83	1,68	11,39%	0,91	0,83
A604	3,75	0,78	0,79	1,59	9,93%	0,94	0,83
A607	-0,24	1,06	0,91	1,38	7,88%	0,96	0,92
A608	-0,91	1,13	0,90	1,89	11,00%	0,93	0,88
A609	0,01	1,04	0,86	1,34	8,17%	0,95	0,88
A610	-1,11	1,07	0,61	1,70	10,77%	0,86	0,67
A611	2,75	0,82	0,86	1,35	8,17%	0,96	0,88
A617	-0,06	0,93	0,90	1,70	9,15%	0,92	0,87
A618	-0,01	1,12	0,64	2,47	16,88%	0,78	0,63
A621	3,31	0,85	0,89	1,59	10,07%	0,95	0,89
A652	4,91	0,81	0,92	2,24	13,86%	0,92	0,88
A654	4,57	0,76	0,93	1,43	8,81%	0,96	0,92

Fonte: Os autores (2022).

Para os dados obtidos da análise sazonal, verificou-se com maiores precisões ( $r^2$ ), as estações A654 (0,93) e A602 (0,92), e menores precisões as estações A610 (0,61) e A618 (0,64). As maiores exatidões (d) obtidas foram 0,97 (estações A601 e A602) e a menor foi para a estação A618 (0,78).

A maior precisão e exatidão na análise sazonal em relação a espacial foi devido ao padrão sazonal ser bem definido na região, com os maiores totais de  $H_g$  nos meses de verão (DJF) e os menores nos meses de inverno (JJA), enquanto o padrão espacial é influenciado pelo relevo complexo do ERJ, com regiões próximas ao ambiente costeiro e elevado gradiente altitudinal, o que induz a elevada variabilidade espacial de  $H_g$  na região.

Os resultados para o coeficiente linear ( $\beta_0$ , MJ m<sup>-2</sup> d<sup>-1</sup>) que melhor atenderam foram os obtidos para as estações A609 (0,01), A618 (-0,01) e A617 (-0,06) (Tabela 4), enquanto as que pior atenderam foram as estações A652 (4,91) e A654 (4,57), respectivamente. Em relação ao coeficiente angular ( $\beta_1$ ), as estações com melhores índices obtidos foram a A609 (1,04) e A601 (1,04), e as de piores índices foram

as A654 (0,76), A529 (1,23) e A604 (0,78).

Os menores valores da RQME encontrados foram para as estações A601 ( $1,02 \text{ MJ m}^{-2} \text{ d}^{-1}$ ) e A517 ( $1,09 \text{ MJ m}^{-2} \text{ d}^{-1}$ ). Os de maiores resultados foram encontrados para as estações A618 ( $2,47 \text{ MJ m}^{-2} \text{ d}^{-1}$ ) e A518 ( $2,13 \text{ MJ m}^{-2} \text{ d}^{-1}$ ). Para a RQME percentual, o erro relativo à média, apresentou variação de 6,35% (A517) à 16,88% (A618).

O desempenho das interpolações apresentado pela maioria das estações foi classificado como “Ótimo” ( $c > 0,85$ ). Apenas as estações A604 ( $c = 0,83$ ), A603 ( $c = 0,83$ ) e A518 ( $c = 0,77$ ) foram classificadas com o desempenho “Muito Bom” e a estação A618 ( $c = 0,63$ ) foi classificada como “Mediano”.

## CONSIDERAÇÕES FINAIS

O modelo Hargreaves-Samani é amplamente utilizado para estimar a irradiação solar global em situações de ausência de dados observados desta variável, sendo inclusive utilizado para a estimativa de outras variáveis, como a evapotranspiração. A dificuldade e o custo de trabalho para espacialização de séries mensais de irradiação solar global pelo modelo cartográfico proposto é a principal justificativa para a aplicação de um *workflow* em ambiente SIG para gerar esses resultados.

Como ferramenta de gerenciamento dos processos, o *workflow* desenvolvido atende as expectativas propostas, visto que permite espacializar a irradiação solar global mensal com base no modelo de Hargreaves-Samani e técnicas de modelagem cartográfica. Técnicas de álgebra de mapas por meio da aplicação direta da calculadora *raster* de qualquer software SIG demandam diversas etapas intermediárias para realizar análises espaciais, o que exige maior trabalho humano e tempo despendido, além de estar passível a erros humanos durante todo o processo. O uso do *workflow* desenvolvido na ferramenta *Graphical Modeler* do QGIS não só tornou viável o estudo para este caso, como também pode ser reproduzível para outras localidades, alterando-se os dados de entrada para cada região a ser estudada.

O desempenho geral do método proposto para espacialização de  $H_g$  (modelagem cartográfica + modelo de Hargreaves-Samani) apresenta resultados satisfatórios para a descrição da variação sazonal de  $H_g$ , enquanto para a distribuição espacial observa-se baixa precisão, com exatidão moderada. Por ser uma região de estudo onde o padrão sazonal é bem definido, os resultados neste aspecto de avaliação propuseram melhor desempenho quando comparados ao aspecto espacial. Isto pode ser atribuído as características com alta heterogeneidade de relevo e a sua localização costeira.



O *workflow* desenvolvido neste trabalho na ferramenta *Graphical Modeler* do QGIS 2.8, assim como os dados utilizados e os resultados gerados, estão disponíveis no repositório do Github: [https://github.com/marcianolima/workflow\\_HS](https://github.com/marcianolima/workflow_HS).

## AGRADECIMENTOS

Ao Instituto Nacional de Meteorologia (INMET) por disponibilizar os dados meteorológicos. O segundo autor agradece ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa de produtividade em pesquisa (No 311.656/2015-3) e a Fundação de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ) pela bolsa de Jovem Cientista do Nosso Estado (No E-26/201.501/2014).

## REFERÊNCIAS

- ALLEN, Richard G. et al. Crop Evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56. **Fao, Rome**, v. 300, n. 9, p. D05109, 1998.
- BORGES, Valéria P. et al. Avaliação de modelos de estimativa da radiação solar incidente em Cruz das Almas, Bahia. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n. 1, p. 74-80, 2010.
- CAMARGO, AP de; SENTELHAS, Paulo C. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no Estado de São Paulo, Brasil. **Revista Brasileira de agrometeorologia**, v. 5, n. 1, p. 89-97, 1997.
- CEPERJ. **O Estado do Rio de Janeiro e seu Ambiente: Fundação Centro Estadual de Estatísticas, Pesquisas e Formação de Servidores Públicos do Rio de Janeiro**. Disponível em: <[http://www.ceperj.rj.gov.br/ceep/info\\_territorios/ambiente.html](http://www.ceperj.rj.gov.br/ceep/info_territorios/ambiente.html)>. Acesso em: 10 nov. 2017.
- DAVIDSON, Susan B.; FREIRE, Juliana. Provenance and scientific workflows: challenges and opportunities. In: **Proceedings of the 2008 ACM SIGMOD international conference on Management of data. 2008**. p. 1345-1350.
- DOS SANTOS, Janaina Cassiano et al. Séries climáticas em grade de precipitação e temperatura do ar em região de relevo complexo. **Revista Brasileira de Climatologia**, v. 23, 2018.
- DE GOIS, Givanildo et al. Models to estimate incident solar radiation on Seropédica, Rio de Janeiro. **Bioscience Journal**, v. 32, n. 2, 2016.
- HARGREAVES, George H. Defining and using reference evapotranspiration. **Journal of irrigation and drainage engineering**, v. 120, n. 6, p. 1132-1139, 1994.
- HARGREAVES, George H.; SAMANI, Zohrab A. Reference crop evapotranspiration from temperature. **Applied engineering in agriculture**, v. 1, n. 2, p. 96-99, 1985.

JERSZURKI, Daniela; SOUZA, Jorge Luiz Moretti de. Parametrização das equações de Hargreaves & Samani e Angström-Prescott para estimativa da radiação solar na região de Telêmaco Borba, estado do Paraná. **Ciência Rural**, v. 43, n. 3, p. 383-389, 2013.

LIMA, Allana Oliveira et al. Assessment of monthly global solar irradiation estimates using air temperature in different climates of the state of Rio de Janeiro, Southeastern Brazil. **SN Applied Sciences**, v. 1, n. 9, p. 1-14, 2019.

LYRA, Gustavo Bastos et al. Espacialização da temperatura do ar anual no estado de Alagoas com diferentes modelos digitais de elevação e resoluções espaciais. **Ciência Florestal**, 21, 275-287, 2011.

LYRA, Gustavo Bastos et al. Estimation of monthly global solar irradiation using the Hargreaves–Samani model and an artificial neural network for the state of Alagoas in northeastern Brazil. **Theoretical and Applied Climatology**, v. 125, n. 3, p. 743-756, 2016.

MARTINS MONTEIRO, Ana Flávia; MARTINS, Fabrina Bolzan. Global solar radiation models in Minas Gerais, southeastern Brazil. **Advances in Meteorology**, v. 2019, 2019.

MAZZARELLA, Desirre Santos et al. Métodos baseados em temperatura do ar para estimativa de radiação solar incidente diária no Estado do Rio de Janeiro. **Revista Brasileira de Geografia Física**, v. 12, n. 06, p. 2325-2338, 2019.

MOURA, Ada Ravana Costa et al. Evapotranspiração de referência baseada em métodos empíricos em bacia experimental no estado de Pernambuco - Brasil. **Revista Brasileira de Meteorologia**, [s.l.], v. 28, n. 2, p.181-191, jun. 2013. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0102-77862013000200007>.

PEREIRA, Antonio Roberto; ANGELOCCI, Luiz Roberto; SENTELHAS, Paulo Cesar. **Meteorologia Agrícola**. 2007. Disponível em: <[http://wp.ufpel.edu.br/agrometeorologia/files/2014/08/MeteorAgricola\\_Apostila2007.pdf](http://wp.ufpel.edu.br/agrometeorologia/files/2014/08/MeteorAgricola_Apostila2007.pdf)>. Acesso em: 01 nov. 2017.

PESSANHA, Mariane Santos et al. Interpolation methods applied to the spatialisation of monthly solar irradiation in a region of complex terrain in the state of Rio de Janeiro in the southeast of Brazil. **Modeling Earth Systems and Environment**, v. 7, n. 3, p. 1565-1578, 2021.

QGIS. **QGIS User Guide. Release 2.18**. QGIS Project, 2018. [Software]. Disponível em: <<http://docs.qgis.org/2.18/pdf/en/QGIS-2.18-UserGuide-en.pdf>>. Acesso em: 14 nov. 2018.

ROSA, Ana Paula et al. QUAL A ACEITABILIDADE DA COMUNIDADE EM GERAL AO CONCEITO DE ENERGIAS RENOVÁVEIS. **Revista GEDECON-Gestão e Desenvolvimento em Contexto**, v. 5, n. 1, p. 122-126, 2017.

SAMANI, Z. Estimating solar radiation and evapotranspiration using minimum climatological data. **Journal of Irrigation and Drainage Engineering**, Reston, v. 126, n. 4, p. 265-267, 2000.

SANTOS, Christiane Nascimento. **Evapotranspiração De Referência Estimada Com Séries Climáticas Em Grade Do The Global Historical Climatology Network (Ghcn) para O Estado Do Rio De Janeiro**. 2016. 73 f. Dissertação (Mestrado) - Curso de Mestrado em Engenharia de Biosistemas, Universidade Federal Fluminense, Niterói, 2016.





SANTOS, Anderson Amorim Rocha et al. Evapotranspiração de referência em função dos extremos da temperatura do ar no estado do Rio de Janeiro. **Irriga**, v. 21, n. 3, p. 449-449, 2016.

VALERIANO, Márcio de Morisson; ROSSETTI, Dilce de Fátima. Topodata: Brazilian full coverage refinement of SRTM data. **Applied Geography**, v. 32, n. 2, p. 300-309, 2012.

WEBER, Eliseu José. **Estimativa e mapeamento da radiação solar incidente em superfícies com topografia heterogênea na zona de produção vitivinícola Serra Gaúcha**. 2011. 145 f. Tese (Doutorado) - Curso de Programa de Pós-graduação em Fitotecnia, Faculdade de Agronomia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.

WFMC. **Workflow Management Coalition: Terminology & Glossary**. Disponível em: <[http://www.wfmc.org/docs/TC-1011\\_term\\_glossary\\_v3.pdf](http://www.wfmc.org/docs/TC-1011_term_glossary_v3.pdf)>. Acesso em: 15 nov. 2017.

WILLMOTT, Cort J. Some Comments on the Evaluation of Model Performance. **Bulletin Of the American Meteorological Society**, [s.l.], v. 63, n. 11, p.1309-1313, nov. 1982. American Meteorological Society. [http://dx.doi.org/10.1175/1520-0477\(1982\)0632.0.co;2](http://dx.doi.org/10.1175/1520-0477(1982)0632.0.co;2).