

Article

Modelagem da Temperatura do Ar na Região do Distrito Federal – Brasil, por meio de Dados Atmosféricos do Sensor AIRS

Rodrigo Moura Pereira¹ , Tairone Paiva Leão¹, Delvio Sandri¹,
Gustavo Macedo de Mello Baptista², Luciano Soares da Cunha²

¹*Faculdade de Agronomia e Medicina Veterinária, Universidade de Brasília, Brasília, DF, Brasil.*

²*Instituto de Geociências, Universidade de Brasília, Brasília, DF, Brasil.*

Recebido em: 27 de Agosto de 2018 - Aceito em: 21 de Janeiro de 2019

Resumo

O sensoriamento remoto pode ser utilizado na estimativa de dados meteorológicos. A partir da utilização de imagens de variáveis atmosféricas obtidas pelo sensor AIRS (*Atmospheric Infrared Sounder*) a bordo do satélite Aqua, o presente estudo objetivou estimar as temperaturas máxima, mínima e média diária do ar na região do Distrito Federal – Brasil. Foram gerados modelos de regressão linear simples e múltipla tendo como variáveis explanatórias os dados do sensor AIRS de temperatura de superfície, umidade relativa do ar e vapor d'água atmosférico, obtidos em escala temporal de doze horas (diurno e noturno), durante o período compreendido entre janeiro de 2012 e dezembro de 2016. Como variáveis dependentes, foram utilizados valores observados de temperatura do ar em duas estações meteorológicas da região estudada. Os ajustes apresentaram $R^2 = 0,62$ e $RMSE = 1,64$ °C para os dados de temperatura máxima, $R^2 = 0,59$ e $RMSE = 1,50$ °C para os dados de temperatura mínima, e $R^2 = 0,76$ e $RMSE = 1,45$ °C para os dados de temperatura média. Conclui-se que os dados do sensor AIRS são adequados para o monitoramento da temperatura do ar na região do Distrito Federal.

Palavras-chave: Temperatura de superfície, sensoriamento remoto, regressão linear.

Air Temperature Modelling in Distrito Federal – Brazil Region with Atmospheric AIRS Sensor Data

Abstract

Remote sensing can be used to estimate meteorological data. Images of atmospheric variables obtained by the AIRS (*Atmospheric Infrared Sounder*) sensor aboard Aqua satellite, were used to estimate maximum, minimum and average daily air temperature in Federal District region – Brazil. Simple and multiple linear regression models were used with explanatory variables derived of diurnal and nocturnal AIRS data of surface temperature, relative air humidity and atmospheric water vapor over the period 2012-2016. The dependent variables were the maximum, minimum and daily average air temperature obtained by two meteorological stations located in the study region. The AIRS fittings showed $R^2 = 0.62$ and $RMSE = 1.64$ °C for the daily maximum air temperature, $R^2 = 0.59$ and $RMSE = 1.50$ °C for the minimum daily air temperature, and $R^2 = 0.76$ and $RMSE = 1.45$ °C for the daily average air temperature. Our results suggest that the AIRS data can yield accurate daily air temperature estimates for Distrito Federal – Brazil region.

Keywords: Surface temperature, remote sensing, linear regression.

1. Introdução

A possibilidade de utilização de dados de sensoriamento remoto no monitoramento da temperatura de superfície tem se sustentado em técnicas que permitem integrar

a heterogeneidade da superfície terrestre em diferentes resoluções espaciais, radiométricas e espectrais (Kalma *et al.*, 2008). Recentemente, a abordagem do sensoriamento remoto termal tem se voltado a questões com enfoque nas

ciências agrárias, especialmente em aplicações relacionadas com a evapotranspiração (Coaguila *et al.*, 2017; Santos *et al.*, 2010). A temperatura de superfície (LST) é uma variável importante, pois exerce influência em todos os termos do balanço de energia na superfície e, por consequência, na estimativa da evapotranspiração em escala regional (Bastiaanssen, 2000; Allen *et al.*, 1998).

A temperatura radiativa da superfície pode ser medida por sistemas sensores, tais como, Landsat, AVHRR, MODIS e AIRS (Kalma *et al.*, 2008; Rajab *et al.*, 2008). A temperatura de superfície estimada por sensores orbitais pode estar sujeita à interferência de fatores atmosféricos e da superfície, que geralmente estão associados à absorção da radiação infravermelha (Kalma *et al.*, 2008). Mesmo assim, os modelos de estimativa da LST têm apresentado eficiência e acurácia na predição da variação da temperatura do ar em diferentes regiões do Planeta (Najmaddin *et al.*, 2017; Rajab *et al.*, 2008).

O sensor AIRS (*Atmospheric Infrared Sounder*) consiste em um sistema passivo que utiliza dados hiperespectrais da região do infravermelho termal na medição da temperatura e umidade atmosférica. A densidade do perfil de gases que constituem a atmosfera é responsável pela absorção da radiação infravermelha e, então, utilizada como um fator de ponderação em cada um dos 2.378 canais do sensor situados entre os comprimentos de onda de 3,7 a 15,4 μm . A bordo do satélite Aqua, o sensor AIRS, juntamente com os sensores AMSU (*Advanced Microwave Sounding Unit*) e HSB (*Humidity Sounder for Brazil*), tem, desde o início de sua operação, fornecido dados de temperatura global com acurácia superior a 1 K na baixa troposfera, sob condições de céu claro a parcialmente nublado, em resolução temporal de 12 horas e resolução espacial de 1° (AIRS, 2018).

A região do Distrito Federal apresenta uma heterogeneidade da superfície com diferentes fitofisionomias de Cerrado, áreas urbanas e agrícolas. Em relação aos usos antrópicos do solo no Distrito Federal, destacam-se as áreas de cultivo (25,2% do território), pastagem (10,5%) e área urbana (10,5%) (Reis e Lima, 2015). Em relação à sazonalidade da temperatura, os sistemas de circulação atmosférica que atuam no Centro-Oeste, associados à posição geográfica do Distrito Federal, resultam em períodos que definem uma estação seca e outra úmida. Segundo Steinke *et al.* (2005), de maneira geral, o período compreendido entre os meses de maio a setembro (período seco) é caracterizado por intensa insolação, pouca nebulosidade, alta taxa de evaporação, baixa umidade relativa do ar, baixa precipitação e grande amplitude térmica. O inverso ocorre entre outubro e abril (período úmido), onde há redução da insolação, aumento da nebulosidade, diminuição da evaporação, aumento da umidade relativa, intensificação da precipitação e redução da amplitude térmica.

Diante do exposto, este trabalho avaliou modelos de regressão linear simples e múltipla para predição das

temperaturas máxima, mínima e média diária do ar na região do Distrito Federal – Brasil, utilizando como variáveis predictoras a temperatura de superfície diurna (TSD), umidade relativa diurna (RHD), vapor d'água atmosférico diurno (H2D), temperatura de superfície noturna (TSN), umidade relativa noturna (RHN) e o vapor d'água atmosférico noturno (H2N) obtidos pelo sensor AIRS.

2. Materiais e Métodos

O trabalho abrangeu o Distrito Federal situado na região Centro-Oeste do Brasil, com elevação média de 997 m. O clima da região, segundo Köppen-Geiger, é do tipo Aw caracterizado como tropical, com estação seca no inverno (Cardoso *et al.*, 2014). A precipitação média anual é de 1.360 mm, com temperaturas médias anuais máximas de 26,7 °C e mínimas de 16,1 °C. Os dados de temperatura do ar na superfície foram obtidos de três estações meteorológicas, sendo duas pertencentes à rede do Instituto Nacional de Meteorologia (INMET), localizadas nas coordenadas 15°55' S e 47°52' W (INMET_1) e 15°46'48" S e 47°55'48" W (INMET_2), e uma pertencente à Universidade de Brasília (UnB), localizada na fazenda Água Limpa (FAL) em 15°56' S e 47°56' W. A estação INMET_1 localiza-se em região de vegetação nativa do Cerrado. Já a estação INMET_2, encontra-se em área urbana próxima a fluxos intensos de trânsito com áreas adjacentes impermeabilizadas. Por fim, a estação FAL/UnB situa-se relativamente próxima às áreas urbana, de Cerrado e de cultivos voltados à pesquisa agrícola.

Os dados obtidos das estações foram: temperatura mínima diária, temperatura máxima diária e temperatura média diária, em um período de cinco anos, com início em janeiro de 2012 e término em dezembro de 2016. Os dados diários de temperatura do ano de 2017 da estação meteorológica automática FAL/UnB foram utilizados para a validação dos modelos de estimativa de temperatura construídos com os dados das estações do INMET. Os dados de sensoriamento remoto utilizados na análise consistiram de uma série temporal de dados diurnos e noturnos de temperatura de superfície (TSD e TSN), umidade relativa (RHD e RHN) e vapor d'água atmosférico (H2D e H2N) do produto Aqua AIRS/AMSU Level 3 *Standard Physical Retrieval* V006 (abreviação AIRX3STD) de 2012 a 2016 e com 1° de resolução espacial. Os dados de sensoriamento remoto utilizados na correlação com a temperatura média do ar consistiram na média dos dados diurnos e noturnos do produto AIRX3STD, sendo os dados diurnos obtidos a partir do movimento do satélite na direção do hemisfério sul ao hemisfério norte, com passagem na linha do equador às 13h30, e os dados noturnos a partir da direção hemisfério norte ao hemisfério sul com passagem na linha equatorial à 1h30, horário local. Posteriormente, os referidos dados orbitais do ano de 2017 foram obtidos para o procedimento de validação dos modelos de temperatura, o

qual foi realizado em conjunto com os dados diários de temperatura coletados pela estação UnB/FAL.

Para a modelagem da temperatura do ar, avaliou-se a relação das variáveis dependentes, temperaturas mínima, máxima e média diária do ar, com um conjunto de variáveis explanatórias obtidas de produtos atmosféricos do sensor AIRS, adotando modelos de regressão linear simples e múltipla. O método da análise de regressão consiste na busca de variáveis preditoras e na quantificação de sua eficiência em prever valores futuros das variáveis dependentes em questão. A análise de regressão estabelece uma equação matemática preditora da variável em análise com uma probabilidade associada, onde se mostra o quanto uma variável dependente pode ser afetada por uma ou mais variáveis independentes. Quando apenas uma variável independente é considerada, tem-se uma regressão linear simples. Caso existam duas ou mais variáveis independentes (explicativas), tem-se então uma análise de regressão múltipla (Kutner et al., 2004). A equação de regressão linear múltipla para a variável dependente Y_i com variáveis independentes x_1, x_2, \dots, x_n (onde n é o tamanho amostral) é descrita pela Eq. (1):

$$Y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \beta_3 x_{3i} + \dots + \beta_q x_{qi} + \varepsilon_i \quad (1)$$

em que, q denota as variáveis independentes x_1, x_2, \dots, x_q com valores observados $x_{1i}, x_{2i}, \dots, x_{qi}$, para $i = 1, \dots, n$; β_0 é a constante linear da equação de regressão; $\beta_1, \beta_2, \beta_3, \dots, \beta_q$ são as constantes angulares das variáveis independentes e ε_i o erro aleatório.

A escolha de cada modelo baseou-se em uma análise prévia que consistiu na verificação da independência entre as variáveis explanatórias com a aplicação da matriz de correlação ($p < 0,05$). Posteriormente, o primeiro modelo foi testado considerando aquelas variáveis explicativas que apresentaram o menor coeficiente de correlação entre si e significativamente correlacionadas com a variável dependente. Caso o modelo resultante não obtivesse um desempenho satisfatório em termos do valor de $R^2_{ajustado}$, incluiu-se um termo de interação entre as variáveis explanatórias e/ou do termo quadrático no modelo de regressão múltipla. A escolha dos melhores modelos de estimativa da temperatura do ar na superfície baseou-se na análise dos seguintes parâmetros: $R^2_{ajustado}$ - Eq. (2), teste F dos parâmetros do modelo - Eq. (4) (Kutner et al., 2004) e do fator de inflação de variância (VIF), utilizado para medir o efeito da colinearidade nos modelos de regressão múltipla - Eq. (5) (Biaggi et al., 2017).

A verificação de desvios de normalidade dos modelos baseou-se na análise do gráfico de dispersão dos resíduos de cada modelo. A análise do desempenho dos modelos de estimativa das temperaturas máxima, mínima e média foi realizada com base no coeficiente de determinação R^2 - Eq. (2) e do índice de eficiência de Nash & Sutcliffe (1971) - Eq. (3). Já no processo de validação,

realizou-se a análise do coeficiente de determinação entre valores preditos e observados, como índice de precisão, e da raiz do erro quadrático médio $RMSE$, como índice de acurácia - Eq. (6) (Najmaddin et al., 2017). Todas as análises foram processadas no software RStudio versão 1.3.014.

$$R^2 = \frac{SQR}{SQT} \quad (2)$$

$$E = 1 - \frac{\sum_{i=0}^N (x_i^{PR} - x_i^{OB})^2}{\sum (x_i^{OB} - \bar{X})^2} \quad (3)$$

$$F = \frac{QMR}{QME} \quad (4)$$

$$VIF = \frac{1}{(1 - R_j^2)} \quad (5)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i^{PR} - x_i^{OB})^2}{N}} \quad (6)$$

em que, SQR = soma dos quadrados da regressão; SQT = soma dos quadrados totais; QMR = quadrado médio da regressão; QME = quadrado médio dos erros; R_j^2 = coeficiente de determinação parcial de X_j em relação as demais variáveis X_j , (com $j = 1, 2, \dots, k$); X_i^{PR} = valores de temperatura obtidos pelos modelos; X_i^{OB} = valores de temperatura observados na superfície; \bar{X} = média dos valores de temperatura observados na superfície; N = número de valores em cada amostra.

3. Resultados e Discussão

A matriz de correlação demonstra a ocorrência de dependência linear entre as variáveis explanatórias (Tabela 1). Os valores dos coeficientes de correlação entre as variáveis indicam ocorrência de colinearidade entre as variáveis diurnas, noturnas e médias. Fox et al. (1992) afirmam que, na medida em que a correlação entre variáveis explicativas aumenta, o modelo torna-se mais

Tabela 1 - Matriz de correlação das variáveis explanatórias

	TSD	RHD	H2D	TSN	RHN	H2N	TM	RHM	H2M
TSD	1,00	-0,72	-0,38	0,54	-0,62	-0,25	0,74	-0,59	-0,31
RHD		1,00	0,89	-0,03*	0,71	0,66	-0,39	0,82	0,81
H2D			1,00	0,25	0,63	0,77	-0,11	0,76	0,94
TSN				1,00	-0,22	0,41	0,71	-0,08	0,35
RHN					1,00	0,75	-0,45	0,84	0,72
H2N						1,00	0,04*	0,71	0,94
TM							1,00	-0,65	-0,15
RHM								1,00	0,80
H2M									1,00

*correspondem a correlações não significativas ($p > 0,05$).

propício a apresentar coeficientes enviesados. Além disso, com o aumento da colinearidade, o desvio padrão e o intervalo de confiança dos coeficientes da regressão tornam-se maiores. Para avaliar a multicolinearidade na construção dos modelos, utilizou-se o valor de inflação da variância (*VIF*), onde, valores de *VIF* até 1,19 são indicativos de colinearidade fraca, o que resulta em baixa inflação da variância do modelo de regressão pela introdução de mais de uma variável explicativa (Biaggi *et al.*, 2017). Valores de *VIF* = 1 indicam ausência de multicolinearidade, valores iguais ou superiores a 10 indicam um efeito significativo da multicolinearidade na inflação da variância do modelo (Kutner *et al.*, 2004).

Os modelos de temperatura mínima e temperatura média (Tabela 2) baseados em regressões múltiplas, apresentaram valores de *VIF* inferiores a 5 (Tabela 3), o que indica pouca influência na inflação da variância com a inclusão de variáveis explicativas colineares. Nesse sentido, a correlação significativa observada entre as variáveis diurnas (TSD, RHD e H2D), deveu-se a valores de *VIF* de acima de 5 com a inclusão de mais de uma variável explicativa. Isso foi determinante para que os modelos envolvendo a temperatura máxima se resumissem em modelos lineares simples (Tabela 2).

As equações geradas para a modelagem das temperaturas com base nos dados de superfície obtidos em duas estações (INMET_1 e INMET_2), com os respectivos valores do coeficiente $R^2_{ajustado}$ de cada modelo, são apresentadas na Tabela 2. Os valores de $R^2_{ajustado}$ indicam que a associação das variáveis explanatórias com os dados observados na superfície foi menor nos modelos aplicados sobre os dados da estação INMET_2 (Tabela 2). Ainda assim, considerando os valores de R^2 nos modelos da estação INMET_1, a explicação da variação da temperatura do ar pela introdução dos dados AIRS variaram entre fraca

Tabela 2 - Equações representativas das temperaturas mínima, máxima e média diária, $R^2_{ajustado}$ e índice de eficiência *E* em duas estações meteorológicas localizadas no Distrito Federal – Brasil.

Variável (°C)	Equação	$R^2_{ajustado}$	<i>E</i>
Tmáxima (INMET_1)	2,139 + 0,973TSD	0,62***	0,88
Tmáxima (INMET_2)	2,645 + 0,954TSD	0,55***	0,79
Tmínima (INMET_1)	-3,751 + 0,902TSN + 0,040RHN	0,58***	0,58
Tmínima (INMET_2)	2,376 + 0,555TSN + 0,013H2N ²	0,34***	0,33
Tmédia (INMET_1)	6,120 + 0,619TM + 0,179H2M	0,41***	-0,10
Tmédia (INMET_2)	9,652 + 0,523TM	0,29***	-0,08

*** p < 0,001

** p < 0,01

* p < 0,05

ns.

Tabela 3 - Valores de F associados ao fator de inflação da variância (*VIF*) dos parâmetros dos modelos de estimativa das temperaturas máxima, mínima e média diária, obtidos por imagens do sensor AIRS em duas estações meteorológicas localizadas no Distrito Federal – Brasil.

Modelo	F/ <i>VIF</i>	F/ <i>VIF</i>
Tmax (INMET_1)	2114***	
Tmax (INMET_2)	1609***	
Tmin (INMET_1)	1619***/1,05	150***/1,05
Tmin (INMET_2)	516***/1,20	131***/1,20
Tmed (INMET_1)	922***/1,02	89***/1,02
Tmed (INMET_2)	602***	

*** p < 0,001

** p < 0,01

* p < 0,05.

($R^2 = 0,29$) e moderada ($R^2 = 0,68$), valores comumente encontrados considerando a magnitude da relação entre dados observados na superfície com dados observados por dados do sensor AIRS (Schreier e Suselj, 2016; WU *et al.*, 2006).

O índice de eficiência *E* foi aplicado para analisar o desempenho dos modelos no intuito de subsidiar a escolha do modelo apropriado ao processo de validação realizado com amostras independentes de dados do sensor AIRS e da estação FAL/UnB. O índice de eficiência *E* demonstra que, se o modelo linear for não enviesado, seu índice se situará no intervalo entre 0 e 1. Já em modelos enviesados, ou seja, aqueles que irão apresentar desvios sistemáticos da relação 1:1, o *E* pode apresentar valores negativos (McCuen *et al.*, 2006). Os modelos obtidos a partir da relação entre os dados AIRS e a estação INMET_1 apresentaram índices de eficiência *E* superiores aos modelos construídos com os dados da estação INMET_2 (Tabela 2). Já os modelos construídos para a estimativa da temperatura média apresentaram valores de *E* negativos tanto para a estação INMET_1 quanto para a estação INMET_2. O comportamento enviesado da estimativa da temperatura média é confirmado pela relação entre os dados preditos e observados com a reta 1:1 (Fig. 2C).

Alguns fatores explicam a diferença observada entre os modelos, tais como, as diferentes resoluções espaciais entre dados de superfície e de satélite, uma vez que as estações obtêm dados pontuais na superfície enquanto que a plataforma AIRS obtêm uma observação integrada de uma grande área que abrange diferentes condições de cobertura do solo. A homogeneidade da cobertura do solo é um fator que pode influenciar o desempenho da validação da temperatura de superfície obtida com dados AIRS. Rosas *et al.* (2017) observaram que a temperatura de superfície obtida por imagens Landsat, associada a dados de temperatura de perfil atmosférico obtidos com dados AIRS, apresentou boa correlação, principalmente em regiões com baixa mistura espectral e predominância de solo exposto. Nessa condição, os autores obtiveram $R^2 = 0,97$ e erro médio absoluto de 1,19 K.

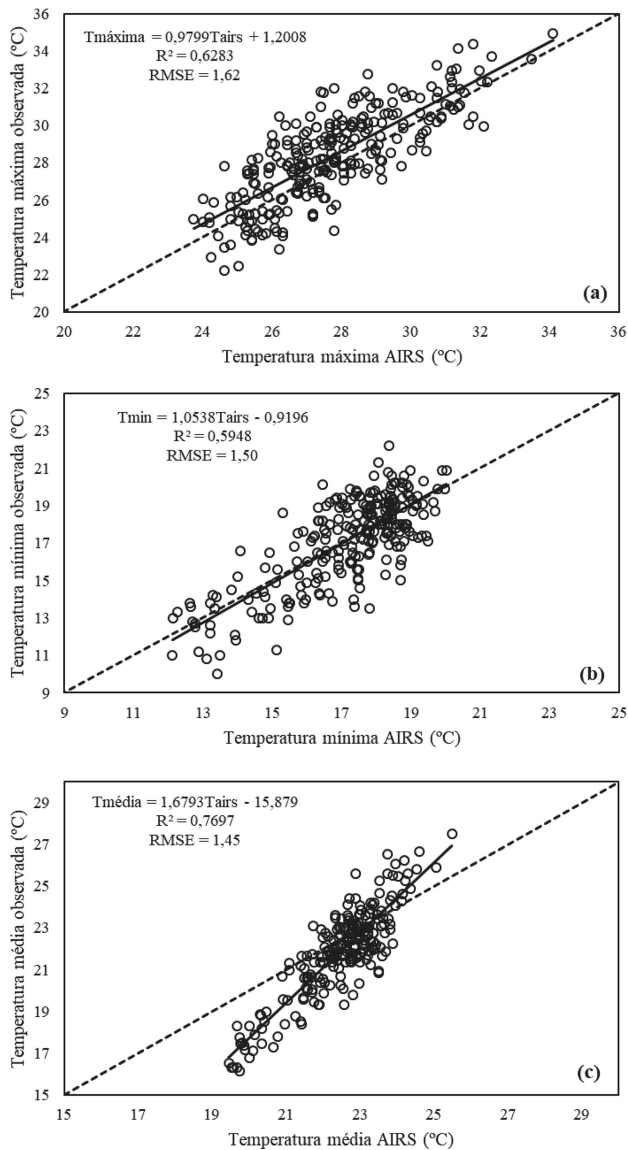


Figura 2 - Dígrama de correlação das temperaturas máxima (a), mínima (b) e média (c) diária medida na superfície comparadas com as mesmas temperaturas estimadas a partir dos modelos de regressão com dados AIRS durante o período de 2017 para a estação FAL/UnB. A linha tracejada indica a relação 1:1.

Outra questão que pode interferir na precisão dos modelos é a sazonalidade da temperatura, o que leva a um comportamento temporal dos dados. Prihodko e Goward (1997) levaram em consideração o efeito da sazonalidade da temperatura na magnitude dos erros em modelos de estimativa da temperatura por dados de sensoriamento remoto e verificaram que mesmo pequenos erros associados a uma ou mais variáveis explanatórias podem resultar em altas variações nos valores estimados de temperatura do ar. Os modelos obtidos pelos autores apresentaram valores de R^2 entre 0,55 e 0,77. Por outro lado, Najmaddin *et al.* (2017), ao modelarem a temperatura do ar estimada

com dados do sensor AIRS com quatro estações meteorológicas em uma região semiárida do Oriente Médio, obtiveram valores de R^2 entre 0,88 e 0,95. Nesse caso, a baixa oscilação temporal dos dados de temperatura e a homogeneidade da superfície na região foram fatores que auxiliaram no bom desempenho dos modelos.

Em estudos que relacionam a temperatura do ar com dados do sensor AIRS, deve-se levar em conta a quantidade de variáveis explicativas utilizadas na construção dos modelos de predição. Nesse sentido, como forma de melhoria da relação entre dados AIRS e a temperatura observada na superfície, têm-se utilizado a incorporação de variáveis explanatórias relacionadas à concentração de gases poluentes para a melhoria dos ajustes dos modelos. Rajab *et al.* (2008) correlacionaram dados obtidos pelo sensor AIRS relacionados a gases poluentes (CO , O_3 , CH_4) e vapor d'água com a temperatura do ar na região da península Malaia e verificaram alta correlação dos gases poluentes com a temperatura de superfície, com coeficientes de correlação entre 0,70 e 0,90 com dados mensais de temperatura.

Para os modelos de estimativa da temperatura mínima, foi necessário incorporar mais de uma variável explicativa, em comparação aos modelos de estimativa da temperatura máxima. No modelo Tmínima (INMET_1), foi necessária a introdução da variável relacionada à umidade relativa do ar noturna (RHN) e, no modelo Tmínima (INMET_2), introduziu-se a variável do vapor d'água atmosférico noturno (H2N). A modelagem da temperatura mínima é baseada na temperatura de superfície noturna, a qual apresenta limitações na sua estimativa, sendo que uma delas pode ser relacionada à ocorrência de cobertura de nuvens no período noturno. Ruzmaikin *et al.* (2017), ao estudarem o ciclo diurno da temperatura do ar estimada pelo sensor AIRS, observaram que, em períodos de maior nebulosidade noturna, as estimativas da variação diária da temperatura apresentam maior variabilidade quando comparados a situações de menor nebulosidade. Os modelos de temperatura AIRS da região do Distrito Federal consideraram os dados ao longo de todos os anos sem separação dos períodos de alta e baixa nebulosidade, de modo que o efeito da cobertura de nuvens no período noturno não foi quantificado no ajuste dos modelos de temperatura mínima diária.

A relação dos parâmetros dos modelos de estimativa da temperatura do ar é apresentada na Tabela 4 na qual se observa $p < 0,001$ em todos os modelos. O valor de F relaciona o quadrado médio da regressão ao quadrado médio dos resíduos, e é utilizado para verificar a hipótese de nulidade dos coeficientes do modelo ($H_0: \beta_1 = \beta_2 = \beta_i = 0$; $H_a: \beta_1 \neq \beta_2 \neq \beta_i \neq 0$), onde, maiores valores de F dão suporte à hipótese alternativa H_a e valores próximos a 1 embasam a hipótese nula H_0 (Kutner *et al.*, 2004). Com base nos resultados da Tabela 4, verifica-se que nenhum

coeficiente de regressão é nulo, tanto nos modelos de temperatura da estação INMET_1, quanto nos modelos gerados com os dados da estação INMET_2. Os parâmetros β_0 correspondem à intersecção dos modelos de regressão, os quais são as respostas dos modelos para valores nulos das variáveis explicativas.

Os parâmetros de inclinação (β_i) também são chamados de coeficientes parciais da regressão, pois refletem o efeito parcial de uma variável preditora quando outra variável preditora é incluída no modelo sob condição constante (Kutner *et al.*, 2004). Com base nesses conceitos, nos modelos de temperatura mínima, é possível observar que as variáveis relacionadas à umidade relativa do ar e ao vapor d'água, RHN e H2N, respectivamente, exercem pouca influência na oscilação da variável resposta. Por outro lado, a temperatura de superfície (TSD) tem a maior influência no comportamento da temperatura do ar.

Após a análise dos parâmetros dos modelos de estimativa da temperatura do ar, levou-se em consideração os pressupostos de aleatoriedade e ausência de tendências na distribuição dos resíduos. Nesse sentido, no modelo de estimativa da temperatura máxima para a estação INMET_2 (Fig. 1B), fica evidente a ocorrência do valor *outlier* influenciando a distribuição dos erros. Em relação aos modelos de estimativa da temperatura mínima, observa-se um efeito de *outlier* no modelo da estação INMET_1 (Fig. 1C) e fica evidente a distribuição aleatória dos erros no modelo INMET_2. Apesar disso, a amplitude de variação dos erros é menor no modelo INMET_1. Tendências de variações cíclicas foram observadas em todos os modelos de estimativa da temperatura, com maior indicação deste efeito nos modelos da estação INMET_2.

A variação cíclica é resultado de um comportamento temporal devido à sazonalidade da temperatura do ar na região do Distrito Federal (Steinke *et al.*, 2005). Esse desvio da aleatoriedade é relatado como um comportamento

periódico comum em dados climáticos, o qual pode ser compreendido de forma mais aprofundada a partir da aplicação de um modelo de regressão periódica (Queiroz *et al.*, 2001). Como o modelo INMET_1 apresentou índices de eficiência E maiores em relação às temperaturas máxima e mínima, considerou-se, assim, o modelo mais eficiente e próprio para o processo de validação realizado *a posteriori*. Além disso, a localização da estação INMET_1 foi o segundo critério adotado para a sua seleção, uma vez que ela se situa em área de uso do solo semelhante à estação FAL/UnB, a qual é composta por um mosaico de vegetação nativa de Cerrado e áreas de cultivo. Prakash *et al.* (2018) verificaram menor amplitude térmica ao longo dos meses do ano em dados de temperatura em estações situadas em áreas de mosaico de vegetação nativa e áreas de cultivo agrícola, quando comparadas com áreas compostas principalmente de agricultura.

Com a utilização de duas amostras independentes, verificou-se a eficiência dos modelos de predição adotados. Nesse sentido, foram correlacionadas as temperaturas máximas, mínimas e médias obtidas pelos modelos gerados com os dados AIRS do ano de 2017, com os dados de temperatura mínima, máxima e média observadas pela estação FAL/UnB do mesmo período. O processo de validação consistiu na análise de regressão linear simples entre os valores preditos pelos modelos e os observados pela estação meteorológica FAL/UnB.

Os valores de R^2 entre as medições na superfície e os dados derivados do sensor AIRS apresentaram, de maneira geral, valores de $R^2 > 0,50$ para as três estimativas de temperatura (Fig. 2). Na mesma figura, é possível observar que tanto as estimativas de temperatura máxima quanto de temperatura mínima apresentaram alta dispersão dos dados, porém com uma tendência de relação 1:1 entre os dados observados e os dados AIRS. Já no caso da estimativa da temperatura média existe um desvio elevado na intersecção do modelo em relação à reta 1:1. Na estimativa da temperatura média, a utilização dos dados AIRS subestimou as observações de temperaturas entre 19 e 23 °C. O RMSE é uma medida da diferença média total entre os valores observados e preditos, representando o erro intrínseco ao modelo, ou seja, o erro que pode ser previsto matematicamente (Noth *et al.*, 2011). Os valores de RMSE ficaram abaixo de 2 °C em todas as variáveis preditas, situando-se dentro da magnitude de erros observados em modelos de estimativa da temperatura de superfície com dados orbitais. Najmaddin *et al.* (2017) observaram RMSE entre 3,2 e 5,1 °C em estimativas de temperatura do ar em estações na região central do Iraque. Wan *et al.* (2004) utilizando medidas diurnas e noturnas do infravermelho termal do sensor MODIS com resolução espacial de 5 km, obtiveram medidas da temperatura de superfície com acurácia de ± 1 K. Coll *et al.* (2005) reportaram que a temperatura de superfície obtida pelo sensor MODIS, com aplicação do algoritmo split-window,

Tabela 4 - Coeficientes de regressão em cada modelo de estimativa das temperaturas máxima, mínima e média diária obtidos por imagens do sensor AIRS em duas estações meteorológicas localizadas no Distrito Federal – Brasil.

Modelo	β_0	β_{TSD}			
Tmáxima (INMET_1)	2,139***	0,973***			
Tmáxima (INMET_2)	2,645***	0,954***			
Modelo	β_0	β_{TSN}	β_{RHN}	β^2_{H2N}	
Tmínima (INMET_1)	-3,751***	0,902***	0,040***		
Tmínima (INMET_2)	2,376***	0,555***	0,013***	0,013***	
Modelo	β_0	β_{TM}	β_{H2M}		
Tmédia (INMET_1)	6,120***	0,619***	0,179***	-	
Tmédia (INMET_2)	9,652***	0,523***			

*** p < 0,001

** p < 0,01

* p < 0,05

ns.

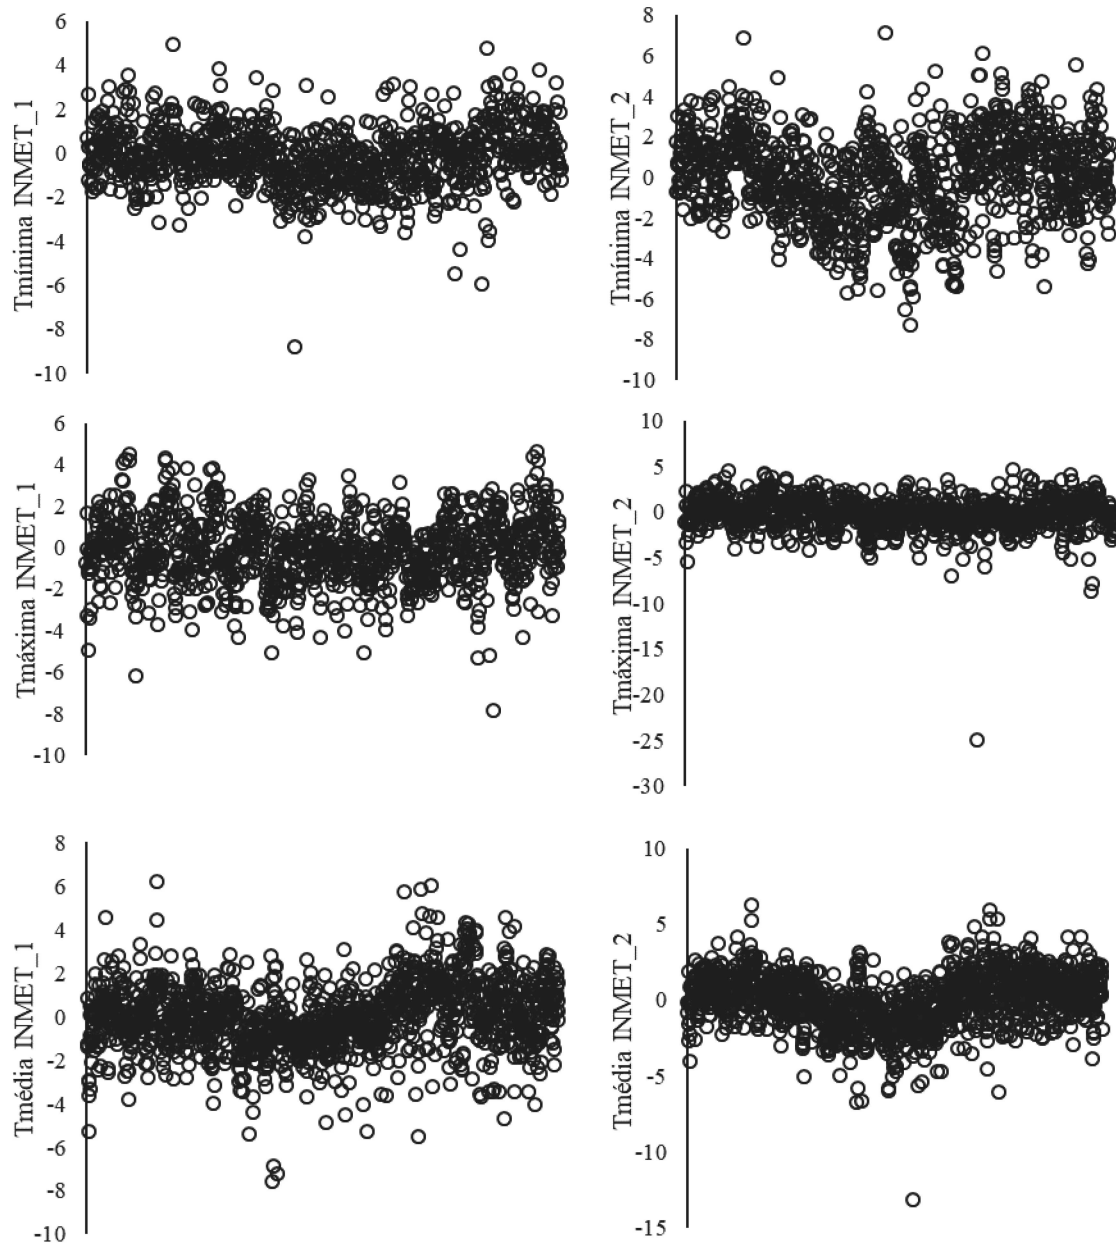


Figura 1 - Dispersão dos resíduos dos modelos de regressão de estimativa das temperaturas máxima, mínima e média diária obtidos com dados do sensor AIRS para as duas estações meteorológicas localizadas no Distrito Federal- Brasil.

apresenta um bom ajuste com medidas na superfície onde o desvio padrão das estimativas ficou próximo a $0,6\text{ }^{\circ}\text{C}$.

4. Conclusões

Os modelos de estimativa da temperatura do ar baseados nos dados AIRS indicam que as temperaturas de superfície diurna e noturna são as variáveis de maior influência na construção dos modelos de regressão, pois são responsáveis pela maior parte da variação da temperatura observada na superfície. A temperatura diurna estimada a partir de dados do sensor AIRS apresenta a maior

correlação com a temperatura máxima diária do ar observada na superfície. De maneira geral, os modelos possuem uma correlação moderada com os valores de temperatura do ar registrados na superfície por estações meteorológicas. Novos estudos devem ser realizados visando avaliar a potencialidade dos dados AIRS na predição e espacialização de variáveis meteorológicas.

Agradecimentos

Este trabalho foi desenvolvido pelo primeiro autor como Trabalho de Conclusão de Especialização (TCE) do I

Curso de Especialização em Recursos Hídricos, nível de pós-graduação lato sensu do Instituto de Geociências (IG), Universidade de Brasília (UnB).

Referências

- ALLEN, R.G.; PEREIRA, L.S.; RAES, D.; SMITH, M. **Crop evapotranspiration – guidelines for computing crop water requirements**. FAO irrigation and drainage paper 56, Roma, Itália, 1998.
- AIRS Science Team. Aqua AIRS Level 3 Daily Standard Physical Retrieval (AIRS + AMSU), Version 006; **NASA Goddard Earth Science Data and Information Services Center (GES DISC)**: Greenbelt, MD, USA, 2018. Disponível em: https://disc.gsfc.nasa.gov/datasets/AIRX3STD_006/summary acesso em 29 de junho de 2018.
- BASTIAANSEN, W.G. SEBAL-based sensible and latent heat fluxes in the irrigated Gediz Basin, Turkey. **Journal of Hydrology**, v. 229, p. 87-100, 2000.
- BIAGGI, M. L.S.; MEDVID, M.; ASSIS, C.M.C. Fator de inflação da variância e regressões auxiliares para diagnóstico do problema de multicolinearidade nos modelos de regressão. In: Anais XIX Congresso Brasileiro de Engenharia de Avaliações e Perícias, 2017, Foz do Iguaçu. p.1-26.
- CARDOSO, M.R.D.; MARCUZZO, F.F.N.; BARROS, J.R. Classificação climática de Köppen-Geiger para o Estado de Goiás e o Distrito Federal. **ACTA Geográfica**, v. 8, n. 16, p. 40-55, 2014.
- COAGUILA, D.N.; HERNANDEZ, F.B.T.; TEIXEIRA, A.H.C.; FRANCO, R.A.M.; LEIVAS, J.F. Water productivity using SAFER – Simple Algorithm for Evapotranspiration Retrieving in watershed. **Revista brasileira de Engenharia Agrícola e Ambiental**, v. 21, n. 8, p. 524-529, 2017.
- COLL, C.; CASELLES, V.; GALVE, J.M.; VALOR, E.; NICLOS, R.; SANCHEZ, J.M.; Ground measurements for the validation of land surface temperature derived from AATSR and MODIS data. **Remote Sensing of Environment**, v. 97, p. 288-300, 2005.
- FOX, J.M. Generalized collinearity diagnostics. **Journal of the American Statistical Association**, v.87, n.417, p.178-183, 1992.
- KALMA, J. D.; McVICAR, T.R.; McCABE, M.F. Estimating land surface evaporation: A review of methods using remotely sensed data. **Surveys in Geophysics**, v. 29, p. 421-469, 2008.
- KUTNER, M.H.; NACHTSHEIM, C.J.; NETER, J.; LI, W. **Applied linear statistical models**. McGraw-Hill, 2004, 1415p.
- McCUEN, R.H.; KNIGHT, Z.; CUTTER, A.G. Evaluation of the Nash-Sutcliffe efficiency Index. **Journal of Hydrologic Engineering**, v. 11, n. 6, p. 597-602, 2006.
- NAJMADDIN, P.M.; WHELAN, M.J.; BALZTER, H. Estimating daily reference evapotranspiration in a semi-arid region using remote sensing data. **Remote Sensing**, v. 9, n. 779, p. 1-20, 2017.
- NOTH, E.M.; HAMMOND, S.K.; BIGING, G.S.; TAGER, I.B. A spatial-temporal regression model to predict daily outdoor residential PAH concentrations in an epidemiologic study in Fresno, CA. **Atmospheric Environment**, v. 45, p. 2394-2403, 2011.
- PRAKASH, S.; SHATI, F.; NOROUZI, H.; BLAKE, R. Observed differences between near-surface air and skin-temperatures using satellite and ground-based data. **Theoretical and Applied Climatology**, <https://doi.org/10.1007/s00704-018-2623-1>, 2018.
- PRIHODKO, L.; GOWARD, S.N. Estimation of air temperature from remotely sensed surface observations. **Remote Sensing of Environment**, v. 60, p. 335-346, 1997.
- QUEIROZ, E.F.; SILVA, R.J.B.; OLIVEIRA, M.C.N. Modelo de análise de regressão periódica da precipitação mensal, da bacia atlântico sudeste, no Estado do Paraná. **Pesquisa Agropecuária Brasileira**, v. 36, n. 5, p. 727-742, 2001.
- RAJAB, J.M.; JAFRI, M.Z.M.; LIM, H.S.; ABDULLAH, K. Regression analysis in modeling of air surface temperature and factors affecting its value in Peninsular Malaysia. **Optical Engineering**, v. 51, n. 10, p. 1-13, 2008.
- REIS, A.M.; LIMA, J.E.F.W. Mapeamento do uso e ocupação do solo no Distrito Federal por unidade hidrográfica de gestão dos recursos hídricos. In: **Anais XXI Simpósio Brasileiro de Recursos Hídricos**, 2015, Brasília. p.1-8, disponível em: http://www.evolvedoc.com.br/sbrh/detalhes-997_mapeamento-do-uso-e-ocupacao-do-solo-no-distrito-federal-por-unidade-hidrografica-de-gestao-dos-recursos-hidricos Acesso em: 16 jul. 2018.
- RUZMAIKIN, A.; AUMANN, H.H.; LEE, J.; SUSSKIND, J. Diurnal cycle variability of surface temperature inferred from AIRS data. **Journal of Geophysical Research: Atmospheres**, v. 10, p. 928-938, 2017.
- SANTOS, C.A.C.; BEZERRA, B.G.; SILVA, B.B.; RAO, T.V.R. Avaliação da evapotranspiração real diária estimada com algoritmos SEBAL e S-SEBI na cultura do algodão. **Revista Brasileira de Meteorologia**, v. 25, n. 3, p. 383-392, 2010.
- SCHREIER, M.; SUSELJ, K. Analysis of collocated AIRS and MODIS data: a global investigation of correlations between clouds and atmosphere in 2004-2012. **International Journal of Remote Sensing**, v.37, n. 11, p. 2524-2540, 2016.
- STEINKE, E.C.; SOUZA, G.A.; SAITO, C.H. Análise da variabilidade da temperatura do ar e da precipitação no Distrito Federal no período de 1965-2003 e sua relação com uma possível alteração climática. **Revista Brasileira de Climatologia**, v. 1, n. 1, p. 131-145, 2005.
- WAN, Z.; ZHANG, Y.; ZHANG, Q.; LI, Z.; Quality assessment and validation of the MODIS global land surface temperature. **International Journal of Remote Sensing**, v. 25, p. 261-274, 2004.
- WU, W.; DESSLER, A. E.; NORTH, G. R. Analysis of the correlations between atmospheric boundary-layer and free-tropospheric temperatures in the tropics. **Geophysical Research Letters**, v. 33, p. 1-5, 2006.