



## PREVISÃO DA PRODUTIVIDADE DO CAFÉ COM BASE EM DADOS AGROCLIMÁTICOS E APRENDIZAGEM DE MÁQUINA

## FORECASTING COFFEE YIELD BASED ON AGROCLIMATIC DATA AND MACHINE LEARNING

João Antonio LORENÇONE<sup>1</sup>

<https://orcid.org/0000-0002-4561-6760>

Lucas Eduardo de Oliveira APARECIDO<sup>2</sup>

<https://orcid.org/0000-0002-1950-4853>

Pedro Antonio LORENÇONE<sup>3</sup>

<https://orcid.org/0000-0001-6831-3992>

José Reinaldo da Silva Cabral de MORAES<sup>4</sup>

<https://orcid.org/0000-0002-8567-4893>

**Resumo:** Objetivou-se prever da produtividade do café com modelos regressivos usando dados meteorológicos em diferentes tipos de solo. O trabalho foi realizado em 15 localidades produtoras de C.arabica do Paraná. Os dados climáticos foram coletados por meio da plataforma NASA/POWER de 1989 e 2020 e os dados de produtividade do Coffea Arabica (sacas/ha) foram obtidos pela CONAB de 2003 a 2018. Para o calcula da evapotranspiração de referência (ET<sub>o</sub>) foi utilizado o método de Penman e Monteith, e o balanço hídrico climatológico (BH) de Thornthwaite e Mather (1955). Na modelagem dos dados, foi utilizado a regressão linear múltipla, em que a produtividade do C.arabica foi a variável dependente e as variáveis independentes foram temperatura do ar, precipitação, radiação solar, déficit hídrico, excedente hídrico e armazenamento de água no solo. Modelos de regressão linear múltipla são capazes de prever a produtividade do cafeeiro arábica no estado do Paraná com dois a três meses de antecedência a colheita. O elemento meteorológico que mais influencia o cafeeiro é a temperatura máxima do ar, principalmente durante a formação do fruto (março). Temperaturas máximas do ar em março de 31.01°C reduzem a produção do cafeeiro. Os modelos podem ser usados para previsão da produtividade do cafeeiro arábica auxiliando no planejamento dos cafeicultores da região do norte do Paraná.

**Palavras-Chave:** Coffea arábica; Temperatura do ar; Déficit hídrico.

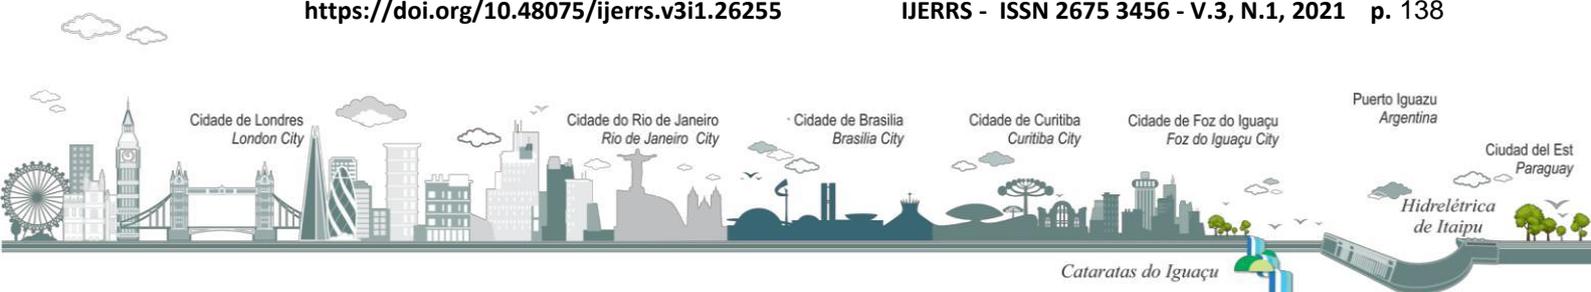
**Abstract:** The objective was to predict coffee productivity with regressive models using meteorological data on different types of soil. The work was carried out in 15 producing locations of C. arabica in Paraná. Climatic data were collected using the NASA / POWER platform from 1989 and 2020 and the Coffea Arabica productivity data (bags / ha) were obtained by CONAB from 2003 to 2018. For the reference

<sup>1</sup> Graduando em Agronomia pelo Instituto Federal de Mato Grosso do Sul, Naviraí, Mato Grosso do Sul, Brasil. [joao.lorencone@estudante.ifms.edu.br](mailto:joao.lorencone@estudante.ifms.edu.br)

<sup>2</sup> Prof. Dr. do Instituto Federal de Mato Grosso do Sul, departamento de agrometereologia, Naviraí, Mato Grosso do Sul, Brazil. [lucas.aparecido@ifms.edu.br](mailto:lucas.aparecido@ifms.edu.br)

<sup>3</sup> Graduando em Agronomia pelo Instituto Federal de Mato Grosso do Sul, Naviraí, Mato Grosso do Sul, Brasil. [pedro.lorencone@estudante.ifms.edu.br](mailto:pedro.lorencone@estudante.ifms.edu.br)

<sup>4</sup> Msc. Doutorando em Produção Vegetal pela Universidade estadual de São Paulo – Unesp, campus Jaboticabal, Jaboticabal, São Paulo, Brazil. [jose.moraes@unesp.br](mailto:jose.moraes@unesp.br)





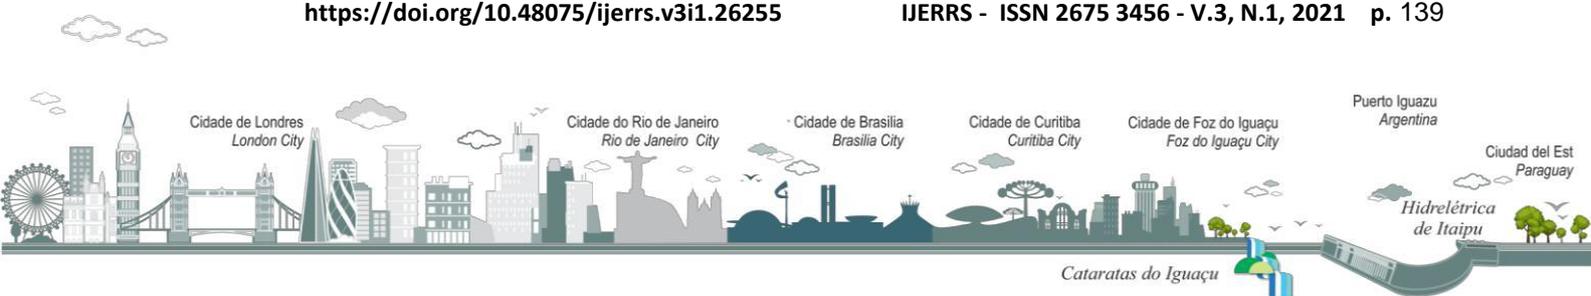
evapotranspiration calculation (ET<sub>o</sub>) it was used the Penman and Monteith method, and the climatological water balance (BH) of Thornthwaite and Mather (1955). In the modeling of the data, multiple linear regression was used, in which *C. arabica* productivity was the dependent variable and the independent variables were air temperature, precipitation, solar radiation, water deficit, water surplus and water storage in the soil. Multiple linear regression models are able to predict the productivity of Arabica coffee in the state of Paraná two to three months before harvest. The meteorological element that most influences the coffee tree is the maximum air temperature, mainly during the formation of the fruit (March). Maximum air temperatures in March of 31.01 ° C reduce coffee production. The models can be used to predict the productivity of Arabica coffee, assisting in the planning of coffee growers in the northern region of Paraná.

**Keywords:** Coffea arábica; Air temperature; Water deficit.

## INTRODUÇÃO

O cafeeiro é um arbusto de crescimento contínuo, pertencente à família das Rubiaceae (CARVALHO; CARVALHO; SOUZA, 2019; DA GAMA et al., 2017), sendo originário da Etiópia, em altitudes entre 1600 a 2000 m, tornando-se atualmente uma das commodities mais comercializadas no mundo (HAJJAR et al., 2019; WTO, 2020). As duas espécies mais cultivadas são *C. arabica* e *C. canephora*, presentes principalmente no Brasil, que representa 37% de toda produção mundial de café (VOLSI et al., 2019, ICO, 2020). A maior parte das lavouras de café arábica, se concentram nos estados de Minas Gerais, São Paulo, Espírito santo, Bahia e Paraná (IBGE, 2018).

O estado do Paraná se localiza na região sul do Brasil e destaca-se por ser o maior produtor de café da região (SERRA, 2018). O rendimento médio do estado na safra de 2019 foi de 25,83 sc/ha (CONAB, 2019; HAMEED; HUSSAIN; SULERIA, 2020) e conhecer esse valor antecipadamente por meio de previsões é útil para o planejamento agrícola (BARBOSA et al., 2020). No Brasil para realizar a previsão da produtividade agrícola é utilizado um sistema baseado em opiniões de técnicos e economistas das áreas, o que acaba tornando-se um método subjetivo, tendo em vista que não permite uma análise quantitativa dos erros envolvidos (MORETO; ROLIM, 2015); (ROSA et al., 2010). Uma alternativa é a utilização de modelos de regressões para estimar o desenvolvimento e produtividade das culturas agrícolas (JAYAKUMAR;



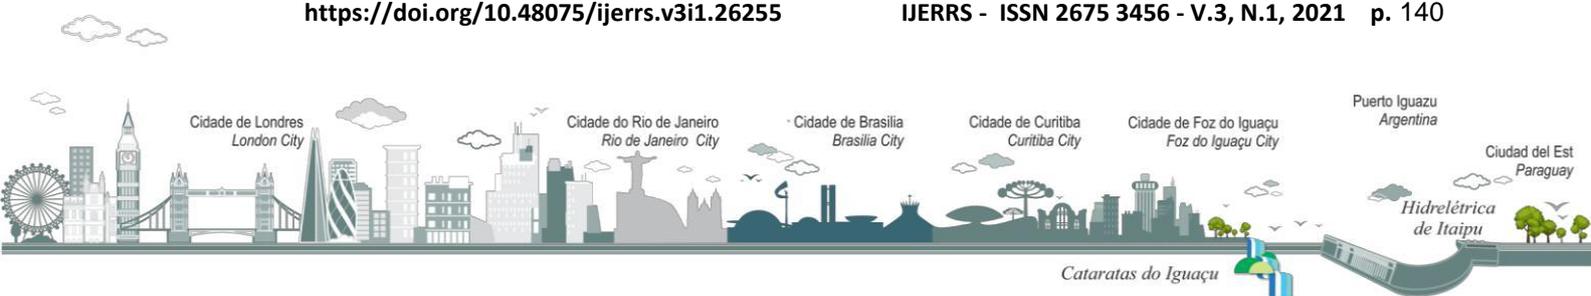


RAJAVEL; SURENDRAN, 2016; MERLE et al., 2020).

Uma forma de melhorar as estimativas de produtividade é com a utilização de variáveis climáticas nos modelos de previsão (CAMARGO et al., 1999; IIZUMI et al., 2018). O clima influencia diretamente e indiretamente a agricultura, sendo o principal responsável por baixas e altas produções (LÄDERACH et al., 2017; MONTEIRO et al., 2017). Dentre os elementos climáticos, a temperatura do ar e a precipitação apresentam maior influência no desenvolvimento do cafeeiro (DAMATTA et al., 2018; DOORENBOS; KASSAM, 1979; TAVARES et al., 2018)

A faixa ideal de temperatura do ar para o cafeeiro situa-se entre 19 a 22°C, sendo que temperaturas do ar superiores a 25°C podem acarretar em amarelecimento das folhas, além de propiciar condições ideais para a incidência de diversa pragas e doenças (ACEVES-NAVARRO et al., 2020; MUHARAM et al., 2017; RODRIGUES et al., 2018). A água pode ser considerada o elemento fundamental para a sobrevivência das plantas (HERNANDEZ-ESPINOZA; BARRIOS-MASIAS, 2020), pois atua em diversos processos metabólicos (SANCHES et al., 2019). Sendo assim, o cafeeiro apresenta uma exigência para precipitação pluvial de 1200 a 1800 mm anuais bem distribuídos durante o ano (CARR, 2001). O estresse hídrico pode reduzir drasticamente a produção do cafeeiro, pois acarreta no fechamento dos estômatos, reduzindo a taxa fotossintética da planta (TAIZ, L et al., 2017); (RIBEIRO et al., 2018).

O conhecimento prévio da produtividade auxilia os cafeicultores, facilitando suas tomadas de decisão e o planejamento para a colheita futura, evitando custos desnecessários e perdas durante a colheita (BROWN et al., 2018). No Brasil diversos trabalhos de estimativa de produtividade são encontrados na literatura (MARTINS et al., 2018; MONTEIRO et al., 2017; PAGANI et al., 2017), porém são raras as previsões que usam os elementos climáticos. Com isso, o objetivo desse trabalho foi prever a produtividade do café com modelos regressivos usando dados meteorológicos em diferentes tipos de solo.



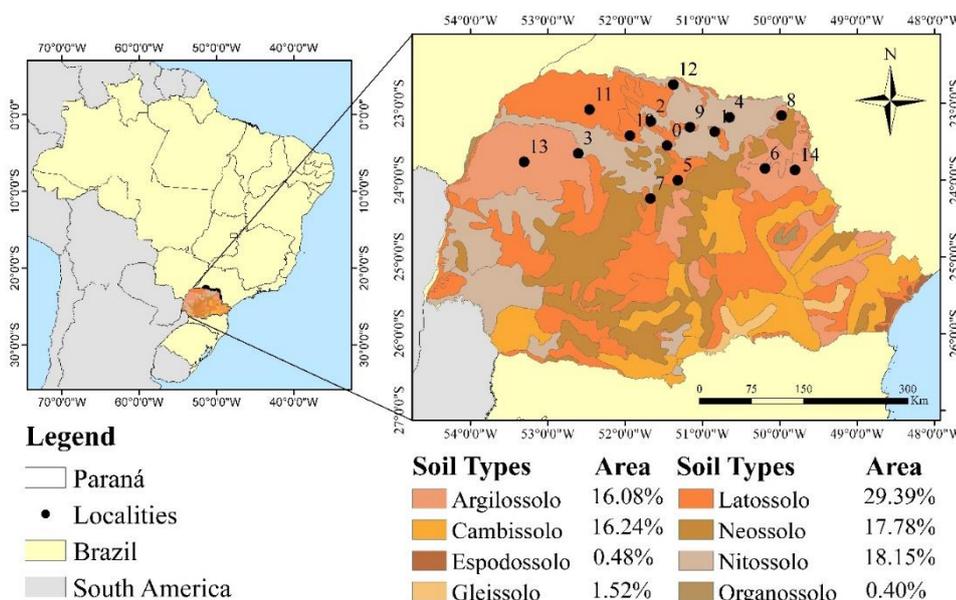


## MATERIAL E MÉTODOS

O estudo foi realizado no estado do Paraná, correspondendo a 199.315 km<sup>2</sup>. O tipo climático segundo o método Köppen predominante no estado é o Cfa (Úmido subtropical, clima oceânico) (APARECIDO et al., 2016). Foram utilizadas séries históricas de dados climáticos de 15 anos (2003 - 2018) dos 15 municípios do estado, de modo que apresentam alta produção de *C. arabica* (IBGE, 2018) (Figura 1).

Os dados climáticos foram obtidos pela plataforma National Aeronautics and Space Administration/Prediction of World Wide Energy Resources – NASA/POWER (STACKHOUSE et al., 2015). Os elementos coletados foram precipitação pluviométrica (mm), temperatura do ar máxima e mínima (°C), umidade relativa (%), velocidade do vento (m s<sup>-1</sup>) e radiação solar (MJ m<sup>-2</sup> d<sup>-1</sup>). Os dados de produtividade do *Coffea Arabica* (sacas/ha) foram obtidos pela CONAB (2019) de 2003 a 2018.

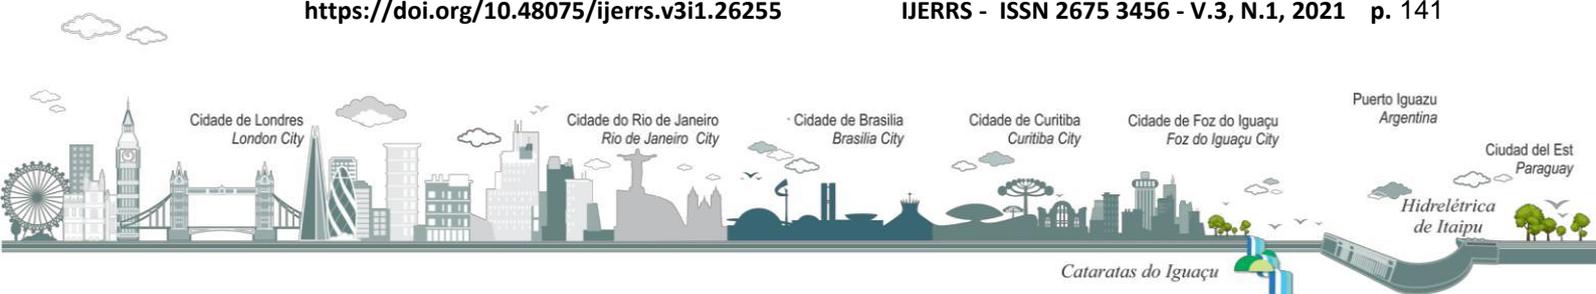
Figura 1. Localidades utilizadas neste trabalho e tipos de solos presentes no estado do Paraná.  
1.Apucarana, 2. Assaí, 3.Astorga, 4.Cianorte, 5.Cornélio Procópio, 6.Faxinal, 7.Ibaiti, 8.Ivaiporã, 9.Jacarezinho, 10.Londrina, 11.Maringá, 12.Paranavaí, 13.Porecatu, 14.Umuarama, 15.Wenceslau Braz



Fonte: Próprio do autor

<https://doi.org/10.48075/ijerr.v3i1.26255>

IJERRS - ISSN 2675 3456 - V.3, N.1, 2021 p. 141





Para o cálculo da evapotranspiração de referência (ET<sub>o</sub>) foi utilizado o método de Penman e Monteith (ALLEN, et al., 1998), conforme as Equações 1-4.

$$ET_o = \frac{0.408 \times s \times (Rn - G) + \frac{\gamma \times 900 \times u_2 \times (e_s - e_a)}{T + 273}}{s + \gamma \times (1 + 0.34 \times u_2)} \quad (1)$$

$$s = \frac{4098 \times e_s}{(T + 273)^2} \quad (2)$$

$$e_a = \frac{RH \times e_s}{100} \quad (3)$$

$$e_s = 0.6108 \times e^{\frac{17.27 \times T}{237.3 + T}} \quad (4)$$

em que  $Rn$  é a radiação líquida ( $\text{MJ m}^{-2} \text{ day}^{-1}$ );  $RH$  é umidade relativa;  $G$  é o fluxo de calor no solo igual a 0 ( $\text{MJ m}^{-2} \text{ day}^{-1}$ );  $T$  é a temperatura do ar ( $^{\circ}\text{C}$ );  $\gamma$  é a constante psicométrica igual a 0,063  $\text{kPa } ^{\circ}\text{C}^{-1}$ ;  $s$  é a declividade da curva da pressão de vapor versus temperatura ( $\text{kPa } ^{\circ}\text{C}^{-1}$ );  $u_2$  é a velocidade do vento ( $\text{m s}^{-1}$ ) na altura de 2 m;  $e_s$  é a pressão da saturação de vapor ( $\text{kPa}$ );  $e_a$  é a pressão de vapor atual ( $\text{kPa}$ ).

O balanço hídrico climatológico (BH) foi calculado pelo método de Thornthwaite e Mather (1955). Nós utilizamos uma capacidade de água disponível (CAD) de 100 mm para todas as localidades (BORTOLOTTO et al., 2011; DUARTE; SENTELHAS, 2020). Os cálculos do balanço hídrico estão descritos nas Equações 5 a 10.

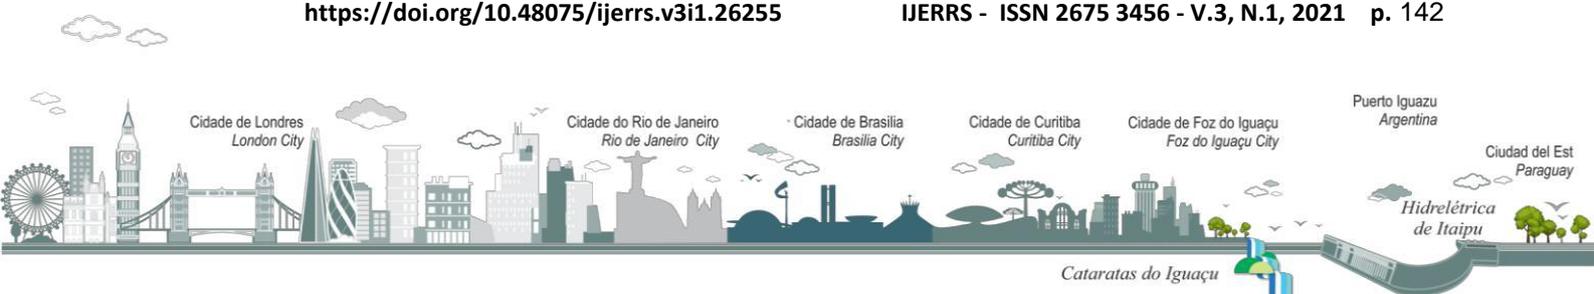
$$\text{if } (P - PET)_i < 0 = \begin{cases} NAC_i = NAC_{i-1} + (P - PET)_i \\ STO_i = WC e^{\frac{(NAC_i)}{WC}} \end{cases} \quad (5)$$

$$\text{if } (P - PET)_i \geq 0 = \begin{cases} STO_i = (P - PET)_i + STO_{i-1} \\ NAC_i = WC \ln \frac{(STO_i)}{WC} \end{cases} \quad (6)$$

$$ALT_i = STO_i - STO_{i-1} \quad (7)$$

$$AET_i = \begin{cases} P + |ALT_i| & , \text{if } ALT < 0 \\ PET_i & , \text{if } ALT \geq 0 \end{cases} \quad (8)$$

$$DEF = PET - AET \quad (9)$$





$$SUR_i = \begin{cases} 0 & , if WC < 0 \\ (P - PET)_i - ALT_i & , if WC = 0 \end{cases} \quad (10)$$

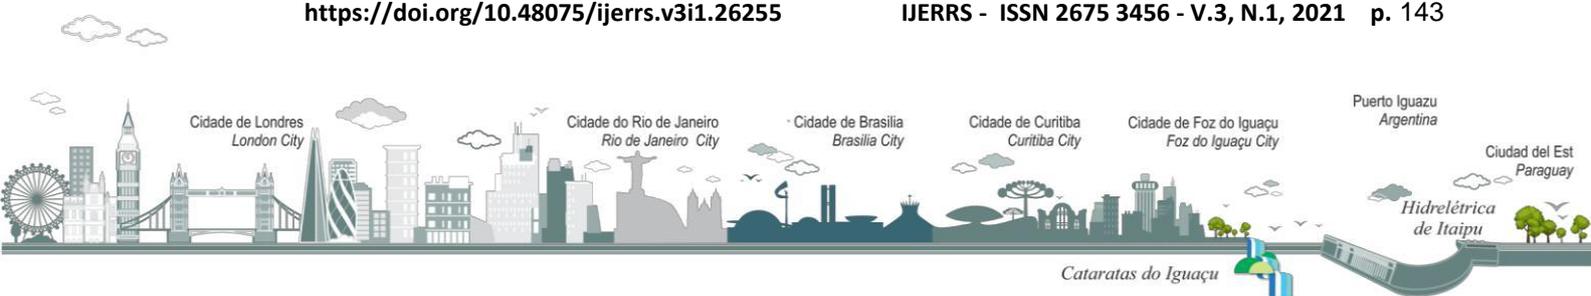
onde AWC é a capacidade de armazenamento de água do solo (mm), SWS é o armazenamento de água no solo (mm), SUR é o excedente hídrico (mm), DEF é o déficit hídrico no sistema solo-planta-atmosferas (mm), NAC é o número de acumulados negativos, P é a precipitação pluvial (mm), ETo é a evapotranspiração potencial (mm), ETR é a evapotranspiração real (mm), ALT é a alteração no armazenamento de água do solo (mm), e  $i$  é o número de meses.

A produtividade do *C. arabica* foi estimada por meio de um modelo de regressão linear múltipla (RLM), em função das variáveis, temperatura mínima do ar (TMin), temperatura máxima do ar (TMax), precipitação pluviométrica (P), radiação solar (QJ), armazenamento de água no solo (SWS), déficit hídrico (DEF) e excedente hídrico (EXC), sendo estas as variáveis independentes e a produtividade do *C. arabica* a variável dependente (Equação 12). O período das variáveis utilizadas foi de janeiro-abril do ano produtivo de acordo com Aparecido et al., (2018)

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_i X_i + e_i \quad (12)$$

onde  $Y$  é a variável dependente ou prevista;  $X_1, X_2, X_3, \dots, X_i$  são as variáveis independentes e  $\beta_0, \beta_1, \beta_2, \beta_3, \dots, \beta_i$  são os coeficientes de regressão. Assim, a partir de um conjunto de  $n$  valores da variável  $Y$ , associados às  $n$  observações correspondentes das  $i$  variáveis independentes pode-se definir os coeficientes da regressão pelo método dos mínimos quadrados.

A seleção do melhor modelo calibrado foi realizada utilizando-se índices estatísticos de precisão e acurácia. A precisão foi avaliada pelo coeficiente de determinação ajustado ( $R^2$  ajustado) (Equação 13), sendo esta a capacidade do modelo de repetir a estimativa, já a acurácia foi avaliada pelo Erro Quadrático Médio





(RMSE) (Equação 14), demonstrando o quanto a estimativa está próxima do valor real (CORNELL; BERGER, 1987).

$$R^2 \text{ adj} = \left[ 1 - \frac{(1-R^2) \times (N-1)}{N-k-1} \right] \quad (13)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_{est_i} - y_{obs_i})^2}{N}}$$

(14)

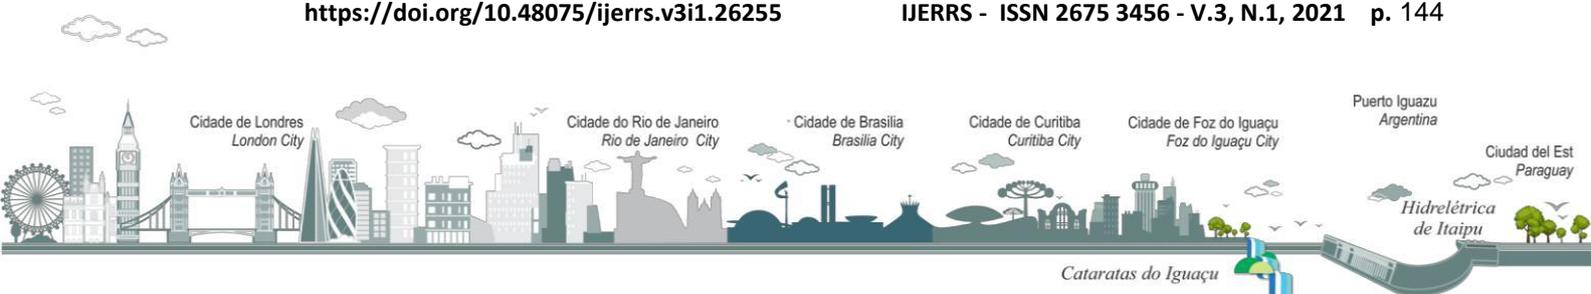
onde  $y_{est_i}$  é a variável estimada,  $y_{obs_i}$  é a variável observada,  $N$  é o número de pontos de dados e  $k$  é o número de variáveis independentes na regressão.

A partir dos resultados dos modelos calibrados da estimativa da produtividade do C. arábica, os dados foram interpolados para a região norte estado do Paraná, utilizando o sistema de informações geográficas (SIG), e usando o método de krigagem (KRIGE, 1951), com o modelo esférico, um vizinho e resolução de 0,25°.

## RESULTADOS E DISCUSSÃO (OU OUTRO TÓPICO)

A dinâmica hídrica das localidades foi semelhante, apresentando maior umidade em janeiro e fevereiro e seca durante o agosto e setembro (Figura 2). O excedente hídrico (EXC) anual médio das localidades foi de 487.16 (+-79,37) mm, sendo 30% do volume concentrado apenas em janeiro e fevereiro. O déficit hídrico (DEF) apresentou uma média anual de 290,03 (+-43.95) mm, 57.83 mm distribuídos apenas em agosto e setembro. O DEF é um dos elementos climáticos que mais influencia o desenvolvimento das culturas agrícolas (ABRECHT; CARBERRY, 1993; CAMARGO, 2010; RAPOPORT et al., 2012)

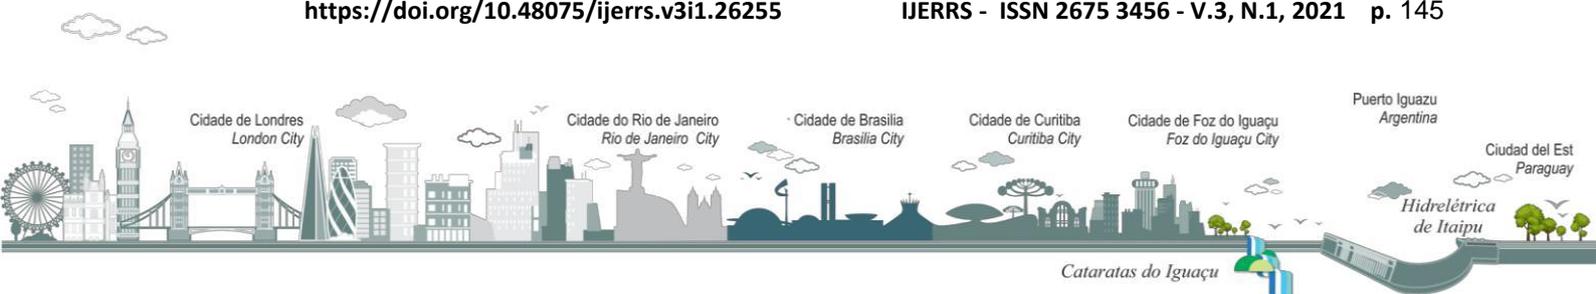
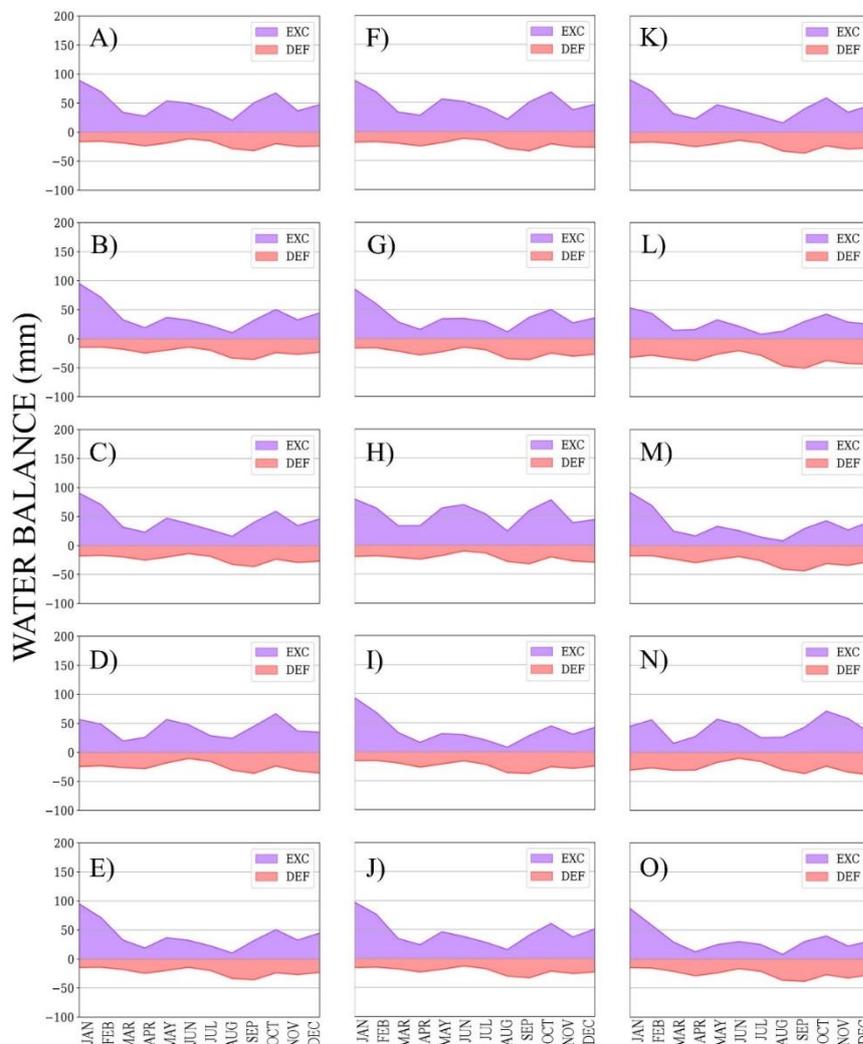
Dentre as localidades Apucarana, Faxinal e Ivaiporã apresentaram os maiores volumes de EXC, com médias de 577.75 mm; 582,09 mm e 633.24 mm, respectivamente (Figura 2 AGH). Já Paranavaí (Figura 2 N), destaca-se por possuir o





maior DEF entre as localidades, com acúmulo anual de 422.34 aproximadamente três vezes acima do recomendado para o cultivo do cafeeiro arábico. Essa localidade apresenta um rendimento médio em 2018 e 2019 de 19.75 sc ha<sup>-1</sup>, 37.97% abaixo da média nacional (CONAB, 2019), devido ao impacto negativo do DEF sobre o desenvolvimento do cafeeiro (SESSA FIALHO et al., 2010).

Figura 2 - Balanço Hídrico das 15 localidades utilizadas neste trabalho. Legenda A). Apucarana, B) Assaí, C) Astorga, D) Cianorte, E) Cornélio Procópio, F) Faxinal, G) Ibaiti, H) Ivaiporã, I) Jacarezinho, J) Londrina, K) Maringá, L) Paranavaí, M) Porecatu, N) Umuarama, O) Wenceslau Braz.





Fonte: Próprio do autor

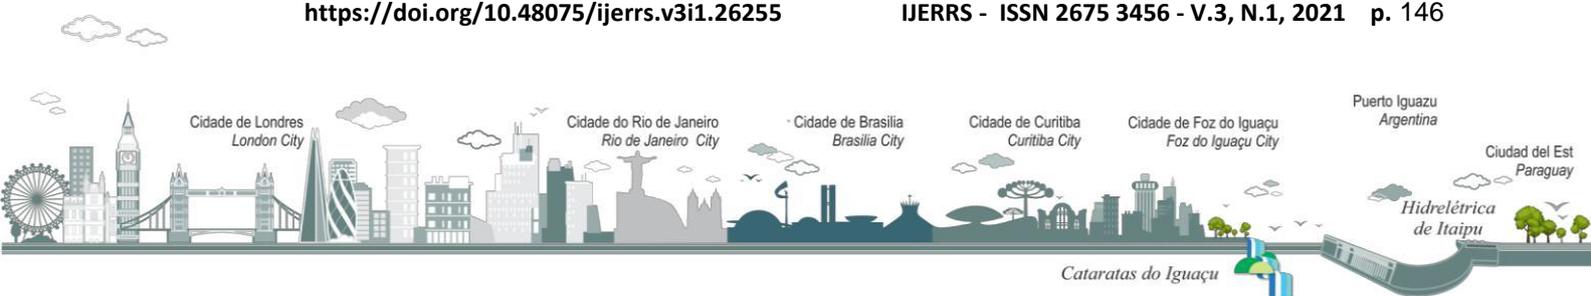
Os modelos foram separados para cada tipo de solo das regiões estudadas. A maior parte das localidades apresentou solo do tipo latossolo (Figura 1), os modelos calibrados para essas localidades apresentaram a melhor acurácia entre os tipos de solo, com média de RSME de 2.68 sc há<sup>-1</sup> e uma média para R<sup>2</sup>adj de 0,51 (Tabela 1). Os modelos calibrados para as localidades que possuem o tipo argissolo demonstraram os maiores RSME com valores de 6.47 sc há<sup>-1</sup>. As duas localidades que apresentam o tipo de solo nitossolo também teve bom desempenho, com média de R<sup>2</sup>adj e RSME de 0.55 e 4.27 sc há<sup>-1</sup>. O desempenho dos modelos foi superior aos calibrados por Jayakumar et al. (2016), para a o estado de Kerala, Índia.

Os melhores modelos calibrados para cada tipo de solo foram para as localidades de Ibaiti (argissolo), Paranavaí (latossolo) e Cornélio Procópio (nitossolo), com média para R<sup>2</sup>adj de 0.83, 0.82 e 0.65, respectivamente e RSME 3.24 sc ha<sup>-1</sup>, 1.45 sc ha<sup>-1</sup> e 3.74 sc ha<sup>-1</sup> (Tabela 1). Esses modelos demonstraram bons resultados para o teste realizado com dados de 2015 a 2018, com média para R<sup>2</sup>adj de 0.84, 0.90 e 0.87, respectivamente. Esses 3 modelos evidenciaram que a temperatura máxima (TMAX) é uma variável de grande importância, sendo que para Ibaiti foi a TMAX de janeiro (época fenológica de expansão e formação do grão), para Paranavaí TMAX de fevereiro (formação do grão) e TMAX de abril (maturação do café) para Cornélio Procópio. A TMAX foi a variável com maior coeficiente nos modelos com valores de -9.11, -1.83 e -1.23, respectivamente, demonstrando uma influência negativa na produtividade do café, como também relatado por Craparo et al. (2015), os autores destacam que o aumento de 1°C na temperatura média anual resultará em perdas de 137 (+-16.87) kg ha<sup>-1</sup>.

Todos os modelos foram capazes de prever o rendimento do cafeeiro com dois meses de antecedência à colheita, com exceção de Umuarama, Astorga, Faxinal, Ivaporã e Porecatu que podem prever o rendimento do café com três meses de antecedência. Segundo Aparecido et al. (2017) esses resultados são muito

<https://doi.org/10.48075/ijerr.v3i1.26255>

IJERRS - ISSN 2675 3456 - V.3, N.1, 2021 p. 146





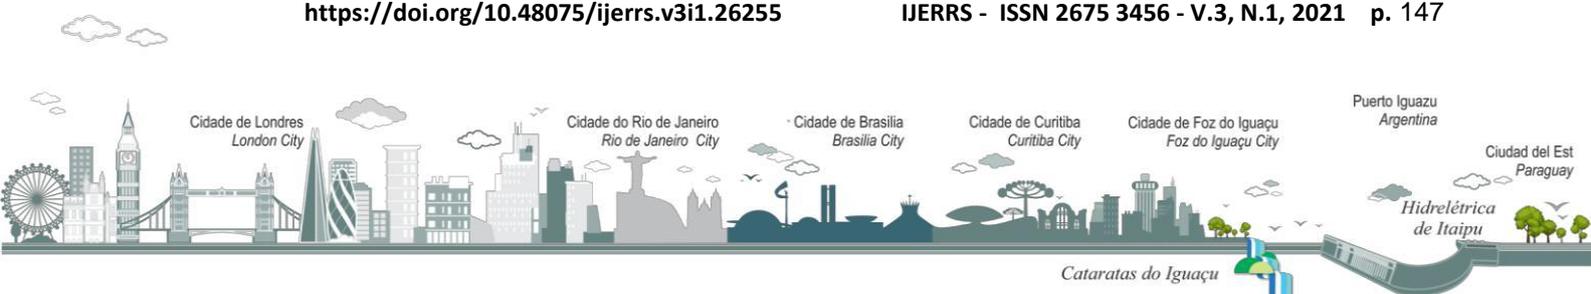
satisfatórios para previsão do rendimento do cafeeiro, podendo ser utilizados nestas localidades, auxiliando os cafeicultores com sua tomada de decisão. Kogan et al. (2013) conseguiram prever o rendimento da cultura do trigo (*Triticum sp.*), também com três meses de antecedência a colheita, e destacaram que esse é um período essencial para o planejamento das operações da colheita como pós-colheita.

Tabela 1. Modelos calibrados para estimativa da produtividades do C.arabica para as 15 localidades produtoras de café.

REGION	MODELS	CALIBRATION		TEST		FORECASTING
		RSME (sc ha-1)	R <sup>2</sup> ADJ	RSME (sc ha-1)	R <sup>2</sup> ADJ	MONTHS
<b>Argissolo</b>						
Cianorte	1.16ARMMAR - 0.29TMaxMAR - 0.73DEFMAR - 0.3TMaxABR + 0.1TMaxFEV - 77.50	3.51	0.48	5.70	0.01	2
Ibaiti	-3.68TMinAPR + 0.55TMaxFEV + 0.94QRFEV - 0.15PJAN - 9.11TMaxJAN + 342.72	3.06	0.83	3.24	0.66	2
Jacarezinho	0.07PJAN + 1.23QGJAN - 0.08EXCJAN - 1.74TMinAPR - 2.25TMaxAPR + 85.09	4.63	0.60	4.23	0.40	2
Umuarama	0.82SWSMAR + 0.44DEFMAR + 0.12TMaxMAR + 0.04PMAR + 0.01PFEV - 66.57	2.78	0.75	5.96	0.84	3
Wenceslau Braz	0.76QGJAN + 0.04PJAN - 8.15TMaxAPR + 4.05TMaxMAR - 0.05EXCJAN + 111.82	4.70	0.61	13.21	0.07	2
AVERAGE		3.73	0.65	6.47	0.39	
<b>Latossolo</b>						
Apucarana	-0.82TMinAPR - 1.26DEFVEV - 0.87TMaxAPR - 1.75TMaxFEV - 1.54SWSFEV + 257.20	3.27	0.66	3.37	0.73	2
Assaí	-1.32DEFVEV - 1.01SWSFEV + 0.35TMinAPR + 4.88TMaxFEV - 1.23TMaxAPR + 12.60	2.23	0.82	6.23	0.02	2
Astorga	0.05PMAR + 2.09TMaxFEV - 0.30DEFVEV - 0.08SWSFEV + 0.12DEFMAR - 40.06	1.69	0.56	4.88	0.02	3
Faxinal	0.47DEFVEV - 0.61SWSFEV - 0.70QGMAR - 0.09DEFJAN + 93.13	2.37	0.25	5.17	0.61	3
Ivaiporã	-1.33TMaxFEV + 0.02DEFMAR - 0.22TMaxMAR + 0.02QGFEV + 1.18TMaxJAN + 25.51	2.27	0.33	9.18	0.04	3
Londrina	-4.90TMinAPR + 1.92QGJAN - 0.43DEFJAN + 2.77TMaxAPR - 6.30	3.33	0.50	3.61	0.33	2
Maringá	-1.55TMinAPR + 0.05QGJAN + 48.70	5.51	0.09	7.17	0.43	2
Paranavaí	7.08TMinAPR + 1.34SWSFEV - 6.04TMaxFEV - 1.83TMaxAPR - 0.34EXCFEV + 1.36DEFVEV - 2.81QGFEV + 12.58TMaxMAR + 0.01PAPR + 0.53PFEV - 415.74	0.78	0.89	1.45	0.90	2
AVERAGE		2.68	0.51	5.13	0.39	
<b>Nitossolo</b>						
Cornélio Procópio	-1.19DEFVEV - 1.21SWSFEV - 0.03EXCJAN - 0.01PJAN - 0.32TMinAPR + 150.03	3.28	0.65	3.74	0.87	2
Porecatu	0.06EXCFEV - 0.02PFEV + 1.09QGFEV + 0.15EXCMAR - 0.03DEFVEV - 5.01	3.98	0.45	4.79	0.05	3
AVERAGE		3.61	0.55	4.27	0.46	

Fonte: Próprio do autor

## CONSIDERAÇÕES FINAIS





Modelos de regressão linear múltipla são capazes de prever a produtividade do cafeeiro arábica no estado do Paraná com dois a três meses de antecedência a colheita. Os modelos calibrados para as localidades que apresentam argissolo, demonstram as maiores médias de acurácia, RSME de 2.68 sc ha<sup>-1</sup>.

Os melhores modelos calibrados são para a localidade de Paranavaí (latossolo), com RSME de 0.78 sc ha<sup>-1</sup> e R<sup>2</sup>adj de 0.89, e Ibaiti (argissolo) com RSME e R<sup>2</sup>adj de 3.09 sc ha<sup>-1</sup> e 0.83, respectivamente. Paranavaí possui diferença média entre o rendimento real e estimado do cafeeiro de apenas 0.86 sc ha<sup>-1</sup>. Os modelos podem ser usados para previsão da produtividade do cafeeiro arábica auxiliando no planejamento dos cafeicultores da região.

## REFERÊNCIAS

ABDELAZIZ, A. et al. A machine learning model for improving healthcare services on cloud computing environment. **Measurement**, v. 119, p. 117–128, abr. 2018.

ABRECHT, D. G.; CARBERRY, P. S. The influence of water deficit prior to tassell initiation on maize growth, development and yield. **Field Crops Research**, v. 31, n. 1, p. 55–69, 1 jan. 1993.

ACEVES-NAVARRO, L. A. et al. Impact of climatic change on the adaptation of coffee (*Coffea arabica* L.) crops in Tabasco, Mexico. **Agroproductividad**, v. 13, n. 4, p. 53–58, 2020.

ALLEN, R. G. et al. Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56. v. 300, n. 9, p. D05109, 1998.

APARECIDO, L. E. DE O. et al. Agrometeorological Models for Forecasting Coffee Yield. **Agronomy Journal**, v. 109, n. 1, p. 249–258, 2017.

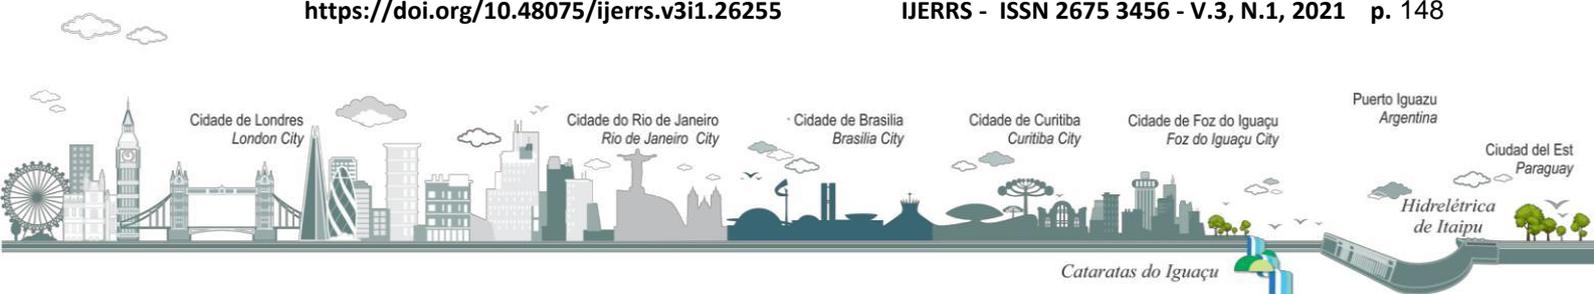
APARECIDO, L. E. DE O. et al. Köppen, Thornthwaite and Camargo climate classifications for climatic zoning in the State of Paraná, Brazil. **Ciência e Agrotecnologia**, v. 40, n. 4, p. 405–417, ago. 2016.

BARBOSA, A. et al. Modeling yield response to crop management using convolutional neural networks. **Computers and Electronics in Agriculture**, v. 170, p. 105197, mar. 2020.

BORTOLOTTI, R. P. et al. Soil profile internal drainage for a central pivot fertigated coffee crop. **Revista Ceres**, v. 58, n. 6, p. 723–728, dez. 2011.

BROWN, J. N. et al. Seasonal climate forecasts provide more definitive and accurate crop yield predictions. **Agricultural and Forest Meteorology**, v. 260–261, p. 247–254, out. 2018.

CAI, Y. et al. Integrating satellite and climate data to predict wheat yield in Australia using machine





learning approaches. **Agricultural and Forest Meteorology**, v. 274, p. 144–159, ago. 2019.

CAMARGO, Â. P. D.; CAMARGO, M. B. P. D. Definition and layout of phenological phases of Arabica coffee in tropical conditions in Brazil. **Bragantia**, v. 60, n. 1, p. 65–68, 2001.

CAMARGO, A. P. Zoning climatic fitness for Arabica and Robusta coffee farming in Brazil. In: BRAZILIAN GEOGRAPHY AND STATISTICAL INSTITUTE FOUNDATION. Natural resources, environment and pollution: contribution of a cycle of debates. Rio de Janeiro: SUPREN, v.1, p.68-76, 1977.

CAMARGO, M. B. P. D. et al. Agrometeorological model of yield estimation for the Valencia orange cultivar. **Bragantia**, v. 58, n. 1, p. 171–178, 1999.

CAMARGO, M. B. P. DE. The impact of climatic variability and climate change on arabic coffee crop in Brazil. **Bragantia**, v. 69, n. 1, p. 239–247, 2010.

CAMARGO, M. B. P. DE; BRUNINI, O.; MIRANDA, M. A. C. DE. Agrometeorological model for estimating productivity for soybean cultivation in the State of São Paulo. **Bragantia**, v. 45, n. 2, p. 279–292, 1986.

CARR, M. K. V. The Water Relations And Irrigation Requirements of Coffee. **Experimental Agriculture**, v. 37, n. 1, p. 1–36, jan. 2001.

CARVALHO, C. F.; CARVALHO, S. M.; SOUZA, B. Coffee. In: SOUZA, B.; VÁZQUEZ, L. L.; MARUCCI, R. C. (Eds.). **Natural Enemies of Insect Pests in Neotropical Agroecosystems**. Cham: Springer International Publishing, 2019. p. 277–291.

CORNELL, J. A.; BERGER, R. D. Factors that Influence the Value of the Coefficient of Determination in Simple Linear and Nonlinear Regression Models. **Phytopathology**, v. 77, n. 1, p. 63, 1987.

CRAPARO, A. C. W. et al. Coffea arabica yields decline in Tanzania due to climate change: Global implications. **Agricultural and Forest Meteorology**, v. 207, p. 1–10, jul. 2015.

CRISOSTO, C. H.; GRANTZ, D. A.; MEINZER, F. C. Effects of water deficit on flower opening in coffee (*Coffea arabica* L.). **Tree Physiology**, v. 10, n. 2, p. 127–139, 1 mar. 1992.

DA GAMA, T. C. P. et al. Foliar anatomy, physiology and productivity of coffee trees at different levels of fertilization. **Coffee Science**, v. 12, n. 1, p. 42, 30 mar. 2017.

DAMATTA, F. M. et al. Physiological and Agronomic Performance of the Coffee Crop in the Context of Climate Change and Global Warming: A Review. **Journal of Agricultural and Food Chemistry**, v. 66, n. 21, p. 5264–5274, 30 maio 2018.

DAMATTA, F. M.; RAMALHO, J. D. C. Impacts of drought and temperature stress on coffee physiology and production: a review. **Brazilian Journal of Plant Physiology**, v. 18, n. 1, p. 55–81, mar. 2006.

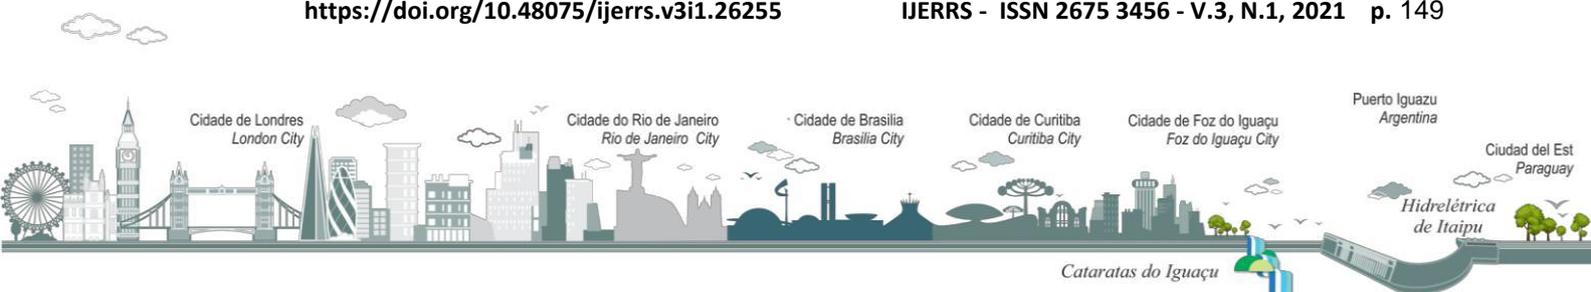
DOORENBOS, J.; KASSAM, A. H. **Yield response to water**. [s.l.: s.n.].

DUARTE, Y. C. N.; SENTELHAS, P. C. NASA/POWER and DailyGridded weather datasets—how good they are for estimating maize yields in Brazil? **International Journal of Biometeorology**, v. 64, n. 3, p. 319–329, mar. 2020.

HAJJAR, R. et al. Scaling up sustainability in commodity agriculture: Transferability of governance mechanisms across the coffee and cattle sectors in Brazil. **Journal of Cleaner Production**, v. 206, p.

<https://doi.org/10.48075/ijerr.v3i1.26255>

IJERRS - ISSN 2675 3456 - V.3, N.1, 2021 p. 149





124–132, jan. 2019.

HAMEED, A.; HUSSAIN, S. A.; SULERIA, H. A. R. “Coffee Bean-Related” Agroecological Factors Affecting the Coffee. In: MÉRILLON, J.-M.; RAMAWAT, K. G. (Eds.). . **Co-Evolution of Secondary Metabolites**. Reference Series in Phytochemistry. Cham: Springer International Publishing, 2020. p. 641–705.

HERNANDEZ-ESPINOZA, L. H.; BARRIOS-MASIAS, F. H. Physiological and anatomical changes in tomato roots in response to low water stress. **Scientia Horticulturae**, v. 265, p. 109208, abr. 2020.

BRAZILIAN GEOGRAPHY AND STATISTICS INSTITUTE. BGSÍ **Automatic Recovery System - SIDRA: Municipal Agricultural Production**. BGSÍ, 2018 Available at: <<https://sidra.ibge.gov.br/home/pnadcm>>. Access in: 28 maio. 2020.

IIZUMI, T. et al. Global crop yield forecasting using seasonal climate information from a multi-model ensemble. **Climate Services**, v. 11, p. 13–23, aug. 2018.

INTERNATIONAL COFFEE ORGANIZATION. Historical Data on the Global Coffee Trade. Available at: <[http://www.ico.org/new\\_historical.asp](http://www.ico.org/new_historical.asp)>. Access in: 02 abr. 2020.

JAYAKUMAR, M.; RAJAVEL, M.; SURENDRAN, U. Climate-based statistical regression models for crop yield forecasting of coffee in humid tropical Kerala, India. **International Journal of Biometeorology**, v. 60, n. 12, p. 1943–1952, dez. 2016.

JERSZURKI, D.; SOUZA, J. L. M. DE. Parameterization of Hargreaves & Samani and Angström-PreScott equations for solar radiation estimation in the region of Telêmaco Borba, state of Paraná. **Rural Science**, v. 43, n. 3, p. 383–389, mar. 2013.

KOGAN, F. et al. Winter wheat yield forecasting in Ukraine based on Earth observation, meteorological data and biophysical models. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, p. 192–203, aug. 2013.

KRIGE, D. G. A statistical approach to some basic mine valuation problems on the Witwatersrand. **Journal of the Southern African Institute of Mining and Metallurgy**, v. 52, n. 6, p. 119–139, 1 dez. 1951.

LÄDERACH, P. et al. Climate change adaptation of coffee production in space and time. **Climatic Change**, v. 141, n. 1, p. 47–62, mar. 2017.

LEE, J. H.; SHIN, J.; REALFF, M. J. Machine learning: Overview of the recent progresses and implications for the process systems engineering field. **Computers & Chemical Engineering**, v. 114, p. 111–121, jun. 2018.

LIAKOS, K. et al. Machine Learning in Agriculture: A Review. **Sensors**, v. 18, n. 8, p. 2674, 14 ago. 2018.

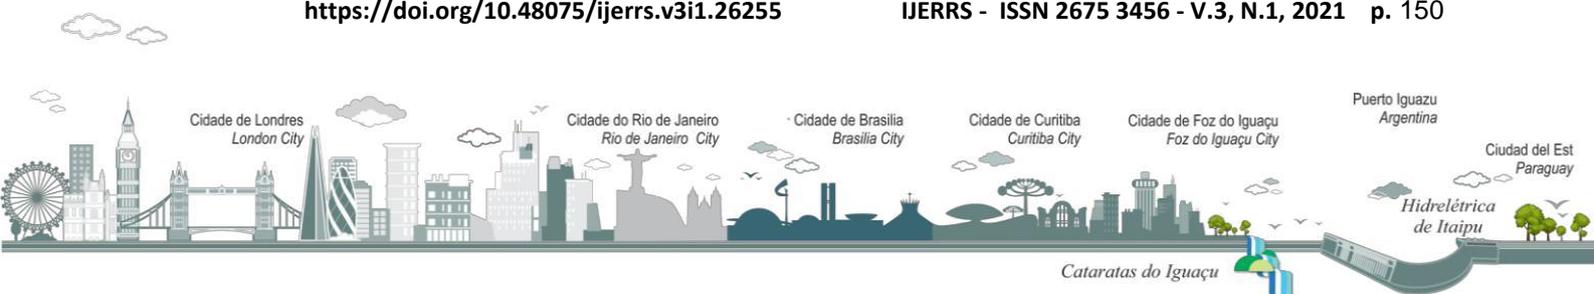
MARTINS, M. A. et al. Improving drought management in the Brazilian semiarid through crop forecasting. **Agricultural Systems**, v. 160, p. 21–30, fev. 2018.

MERLE, I. et al. Forecast models of coffee leaf rust symptoms and signs based on identified microclimatic combinations in coffee-based agroforestry systems in Costa Rica. **Crop Protection**, v. 130, p. 105046, abr. 2020.

MESQUITA, Carlos Magno de et al. **Coffee manual: Coffea arabica L. coffee plantations**. Belo

<https://doi.org/10.48075/ijerr.v3i1.26255>

IJERRS - ISSN 2675 3456 - V.3, N.1, 2021 p. 150





Horizonte: EMATER-MG, 2016. 50 p. il.

MINUZZI, R. B.; CARAMORI, P. H.; BORROZINO, E. Trends in annual and seasonal climate variability of the minimum and maximum air temperatures in the State of Paraná, Brazil. **Bragantia**, v. 70, n. 2, p. 471–479, 2011.

MONTEIRO, J. E. B. DE A. et al. Modeling of corn yield in Brazil as a function of meteorological conditions and technological level. **Brazilian Agricultural Research**, v. 52, n. 3, p. 137–148, mar. 2017.

MORETO, V. B.; ROLIM, G. D. S. Agrometeorological models for groundnut crop yield forecasting in the Jaboticabal, São Paulo State region, Brazil. **Acta Scientiarum. Agronomy**, v. 37, n. 4, p. 403, 1 out. 2015.

MUHARAM, F. M. et al. Remote Sensing Derivation of Land Surface Temperature for Insect Pest Monitoring. **Asian Journal of Plant Sciences**, v. 16, n. 4, p. 160–171, 15 set. 2017.

NERY, J. T.; ROSEGHINI, W. F. F.; MARTINS, M. D. L. O. F. Characterization of Rainfall in the Northwestern Region of the State of Paraná. **Geography Bulletin**, v. 19, n. 1, p. 99–114, 2001.

PAGANI, V. et al. Forecasting sugarcane yields using agro-climatic indicators and Canegro model: A case study in the main production region in Brazil. **Agricultural Systems**, v. 154, p. 45–52, jun. 2017.

PORTUGAL, I.; ALENCAR, P.; COWAN, D. The use of machine learning algorithms in recommender systems: A systematic review. **Expert Systems with Applications**, v. 97, p. 205–227, maio 2018.

RAPOPORT, H. F. et al. Influence of water deficits at different times during olive tree inflorescence and flower development. **Environmental and Experimental Botany**, v. 77, p. 227–233, 1 abr. 2012.

RENA, A. B.; BARROS, R. S. Critical aspects in the study of coffee flowering. In: ZAMBOLIM, L. (Ed.). Effects of irrigation on coffee quality and yield. Viçosa, MG: UFV, 2004. p. 149-172

RIBEIRO, W. et al. Limitation of Relative Transpiration and Growth of Arabic Coffee in Response to Water Deficit. **Journal of Experimental Agriculture International**, v. 24, n. 1, p. 1–12, 21 jun. 2018.

RODRIGUES, W. P. et al. Stomatal and photochemical limitations of photosynthesis in coffee (*Coffea spp.*) plants subjected to elevated temperatures. **Crop and Pasture Science**, v. 69, n. 3, p. 317, 2018.

ROSA, V. G. C. DA et al. Estimation of coffee productivity based on an agrometeorological-spectral model. **Brazilian Agricultural Research**, v. 45, n. 12, p. 1478–1488, dez. 2010.

SAMPAIO, S. C. et al. Estimation and Distribution of Decay Precipitation for the State of Parana. **IRRIGA**, v. 12, n. 1, p. 38–53, 27 mar. 2007.

SANCHES, R. F. E. et al. Changes in carbohydrates accumulation in *Viguiera discolor* Baker in response to water deficit. **Hoehnea**, v. 46, n. 4, 2019.

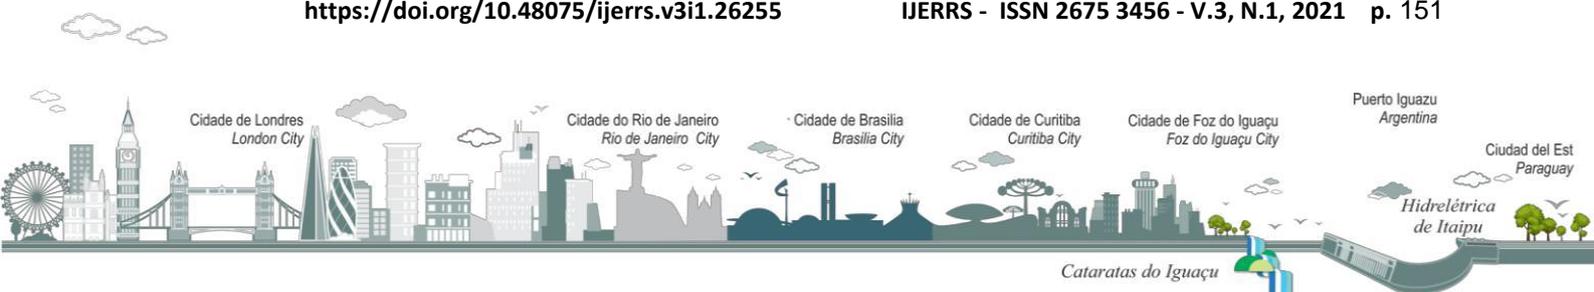
SERRA, E. Coffee cooperatives of Northern Paraná: trajectory and evolution. **Campo-Território Journal**, v. 13, n. 29, p. 89–111, 30 abr. 2018.

SESSA FIALHO, G. et al. Behaviour of arabica coffee plants subjected to water deficit during initial development. **Idesia (Arica)**, v. 28, n. 3, p. 35–39, dec. 2010.

SILVA, W. L. et al. Observed trends in climate extreme indicators of temperature and precipitation in

<https://doi.org/10.48075/ijerr.v3i1.26255>

IJERRS - ISSN 2675 3456 - V.3, N.1, 2021 p. 151





the state of Paraná. **Brazilian Journal of Meteorology**, v. 30, n. 2, p. 181–194, jun. 2015.

SOUSA, P. DE; NERY, J. T. Analysis of annual and inter-annual rainfall variability in the region of Manuel Ribas, Paraná State. **Acta Scientiarum. Technology**, v. 24, p. 1707–1713, 2002.

STACKHOUSE, P. W. et al. Prediction of Worldwide Energy Resource (POWER)-Agroclimatology methodology-(1.0 latitude by 1.0 longitude spatial resolution). **Prediction of Worldwide Energy Resource (POWER)-Agroclimatology methodology-(1.0 latitude by 1.0 longitude spatial resolution)**, 2015.

TAIZ, L et al. **Physiology and plant development**. [s.l.] Artmed, 2017. v. 858

TAVARES, P. DA S. et al. Climate change impact on the potential yield of Arabica coffee in southeast Brazil. **Regional Environmental Change**, v. 18, n. 3, p. 873–883, mar. 2018.

VOLSI, B. et al. The dynamics of coffee production in Brazil. **PLOS ONE**, v. 14, n. 7, p. e0219742, 23 jul. 2019.

WANG, X. et al. Impact of climate change on regional irrigation water demand in Baojixia irrigation district of China. **Mitigation and Adaptation Strategies for Global Change**, v. 21, n. 2, p. 233–247, fev. 2016.

WARD, J. H. Hierarchical Grouping to Optimize an Objective Function. **Journal of the American Statistical Association**, v. 58, n. 301, p. 236–244, 1 mar. 1963.

WTO, W. T. O. **Statistics on merchandise trade**. Disponível em: <timeseries.wto.org/>. Acesso em: 28 maio. 2020.

