

RESSALVA

Atendendo solicitação do(a)
autor(a), o texto completo desta tese
será disponibilizado somente a partir
de 12/11/2022.

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP
CÂMPUS DE JABOTICABAL**

**RUMO À AGRICULTURA INTELIGENTE: PREVISÃO DE
PRODUTIVIDADE AGRÍCOLA COM DADOS
AGROMETEOROLÓGICOS USANDO MACHINE
LEARNING**

Kamila Cunha de Meneses
Engenheira Agrônoma

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP
CÂMPUS DE JABOTICABAL**

**RUMO À AGRICULTURA INTELIGENTE: PREVISÃO DE
PRODUTIVIDADE AGRÍCOLA COM DADOS
AGROMETEOROLÓGICOS USANDO MACHINE
LEARNING**

Kamila Cunha de Meneses

Orientador: Prof. Dr. Glauco de Souza Rolim

Coorientador: Prof. Dr. Newton La Scala Júnior

Tese apresentada à Faculdade de Ciências Agrárias e Veterinárias – Unesp, Câmpus de Jaboticabal, como parte das exigências para a obtenção do título de Doutora em Agronomia (Ciência do Solo).

2021

M543r Meneses, Kamila Cunha de
Rumo à agricultura inteligente: previsão de produtividade agrícola com dados agrometeorológicos usando Machine Learning / Kamila Cunha de Meneses. -- Jaboticabal, 2021
97 p.

Tese (doutorado) - Universidade Estadual Paulista (Unesp),
Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal
Orientador: Glauco de Souza Rolim
Coorientador: Newton La Scala Junior

1. Análise de riscos. 2. Agrometeorologia. 3. Inteligência artificial.
I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal. Dados fornecidos pelo autor(a).

CERTIFICADO DE APROVAÇÃO


TÍTULO DA TESE: RUMO À AGRICULTURA INTELIGENTE: PREVISÃO DE PRODUTIVIDADE AGRÍCOLA COM DADOS AGROMETEOROLÓGICOS USANDO MACHINE LEARNING

AUTORA: KAMILA CUNHA DE MENESES

ORIENTADOR: GLAUCO DE SOUZA ROLIM

COORIENTADOR: NEWTON LA SCALA JUNIOR

Aprovada como parte das exigências para obtenção do Título de Doutora em AGRONOMIA (CIÊNCIA DO SOLO), pela Comissão Examinadora:


Assinado de forma digital por Glauco de Souza Rolim
Dados: 2021.11.21 09:21:13 -03'00'

Prof. Dr. GLAUCO DE SOUZA ROLIM (Participação Virtual)
Departamento de Engenharia e Ciências Exatas (DECEX) / FCAV / UNESP - Jaboticabal

Prof. Dr. GENER TADEU PEREIRA (Participação Virtual)
Departamento de Engenharia e Ciências Exatas (DECEX) / FCAV / UNESP - Jaboticabal

Prof. Dr. LUCAS EDUARDO DE OLIVEIRA APARECIDO (Participação Virtual)
Instituto Federal de Educação, Ciência e Tecnologia do Sul de Minas Gerais - Campus Muzambinho / Muzambinho/MG

Profa. Dra. AMANDA LIZ PACÍFICO MANFRIM PERTICARRARI (Participação Virtual)
Departamento de Engenharia e Ciências Exatas (DECEX) / FCAV / UNESP - Jaboticabal

Prof.ª Dr.ª MARYZÉLIA FURTADO DE FARIAS (Participação Virtual)
Universidade Federal do Maranhão-UFMA / São Luís/MA

Jaboticabal, 12 de novembro de 2021

DADOS CURRICULARES DA AUTORA

Kamila Cunha de Meneses – Filha de Francisco Feitosa de Meneses e Maria dos Milagres dos Santos Cunha, nasceu em Alcântara, Maranhão, no dia 06 de novembro de 1991. cursou Agronomia pela Universidade Federal do Maranhão – Câmpus IV, de Chapadinha – MA, de 2009 a 2013. Durante a graduação, foi bolsista de extensão da PROEX-UFMA, no período de 2011 a 2013. Foi voluntária de projetos de iniciação científica e monitora das disciplinas Hidráulica Agrícola e Irrigação e Drenagem. Em fevereiro de 2018, obteve o título de Mestre em Agronomia pelo Programa de Pós-graduação em Agronomia (Ciência do Solo), na Universidade Estadual Paulista “Júlio de Mesquita Filho” – Unesp, Câmpus de Jaboticabal, sob orientação do Prof. Dr. Glauco de Souza Rolim. Em março de 2018, iniciou o curso de Doutorado pelo mesmo programa de Pós-graduação na Unesp/FCAV, desenvolvendo pesquisas sobre modelagem agrícola, sensoriamento remoto e agrometeorologia. Durante o doutorado também atuou como docente da disciplina de Processamento de Dados no curso de graduação de Engenharia Agrônômica da Unesp/FCAV pelo Programa Institucional de Aperfeiçoamento e Apoio à Docência no Ensino Superior – PAADES, coorientou alunos da Universidade Federal do Maranhão - UFMA, participou de diversas bancas de defesa de trabalho de conclusão de curso e publicou artigos em periódicos de alto impacto. É Integrante dos grupos de pesquisa: i) “Group of Agrometeorological Studies” (GAS); ii) Emissão de CO₂ do Solo e balanço de gases de efeito estufa em sistemas agrícolas, iii) Caracterização do Solo para Fins de Manejo Específico (CSME) da Unesp – Câmpus de Jaboticabal e iv) Manejo Sustentável de Sistemas Agropecuários da UFMA – Câmpus IV. Atualmente, é professora substituta das disciplinas de solos, economia rural e administração rural da Universidade Federal do Maranhão e cofundadora da empresa AGRODIMENSÃO. Em 12 de novembro de 2021, submeteu-se à banca para a defesa de Tese, sendo aprovada como Doutora em Agronomia.

"Se fiz descobertas valiosas, foi mais por ter paciência do que qualquer outro talento."

Isaac Newton

"Ciência não conhece os países, porque o conhecimento pertence à humanidade e é a tocha que ilumina o mundo. Ciência é a alma da prosperidade das nações e a fonte de todo progresso"

Louis Pasteur

Dedico ao meu colega e amigo Washigton Bruno Silva Pereira (*in memoriam*)
que planejava defender sua dissertação no mesmo dia da minha defesa, mas
teve sua vida ceifada pela COVID-19.

AGRADECIMENTOS

A maior parte do meu doutorado foi no período da pandemia COVID-19, na qual passamos por vários sentimentos e incertezas, mas a ciência acendeu uma esperança de dias melhores com o surgimento da vacina. Viva a ciência e o SUS!

Agradeço a Deus por ter mostrado em todos os momentos que a fé e sua presença foram essenciais para contemplar essa fase tão importante na minha vida. Toda honra e glória a ti!

A minha família que estive ao meu lado durante todo este tempo e mesmo de longe sempre conseguiu me dar amor e apoio. Tudo por vocês!

Aos meus amigos que deixaram esse momento mais alegre e divertido.

Ao Departamento de Ciências Exatas e Engenharia pela oportunidade de conviver com pessoas que muito me ensinaram e contribuíram para realização deste trabalho. Conviver com estas pessoas todos os dias é uma alegria muito grande.

Ao meu orientador Glauco de Souza Rolim e coorientador Newton La Scala Junior pelos ensinamentos, paciência, oportunidades e exemplo de profissionalismo. Gratidão por tudo!

Professores da banca de qualificação: professora Dra. Teresa Cristina Tarle Pissarra e professor Dr. Lucas Eduardo de Oliveira Aparecido, pelas sugestões e atenção.

Aos membros da banca de defesa: professor Dr. Gener Tadeu Pereira, professor Dr. Lucas Eduardo de Oliveira Aparecido, professora Dra. Maryzélia Furtado de Farias e professora Dra. Amanda Liz Pacífico Manfrim Peticarrari pelas sugestões que contribuíram na conclusão deste estudo.

À Universidade Estadual Paulista “Júlio de Mesquita Filho”, campus Jaboticabal, especialmente a Pós-Graduação em Agronomia (Ciência do Solo), pela oportunidade oferecida.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

A todos que contribuíram diretamente e indiretamente na realização deste trabalho.

Muito obrigada!

SUMÁRIO

RESUMO	xi
ABSTRACT.....	xii
CAPÍTULO 1 – CONSIDERAÇÕES GERAIS	13
1 INTRODUÇÃO E JUSTIFICATIVA	13
<i>1.1 Agricultura inteligente para o clima.....</i>	<i>13</i>
<i>1.2 Machine learning no sistema agrícola.....</i>	<i>14</i>
<i>1.3 Fatores meteorológicos importantes nos modelos.....</i>	<i>17</i>
1.3 OBJETIVO GERAL	19
REFERÊNCIAS	19
CAPÍTULO 2 – PREVISÃO DA PRODUTIVIDADE DE CANA-DE-AÇÚCAR NO BRASIL A PARTIR DE MODELOS DE MACHINE LEARNING	22
RESUMO	22
ABSTRACT.....	23
2.1 INTRODUÇÃO.....	24
2.2 MATERIAL E MÉTODOS	26
<i>2.2.1 Área de estudo e dados.....</i>	<i>26</i>
<i>2.2.2 Cálculo da evapotranspiração potencial.....</i>	<i>28</i>
<i>2.2.3 Balanço Hídrico.....</i>	<i>29</i>
<i>2.2.4 Época de colheita.....</i>	<i>30</i>
<i>2.2.5 Modelos de previsão.....</i>	<i>31</i>
<i>2.2.5.1 Multiple linear regression (MLR).....</i>	<i>32</i>
<i>2.2.5.2 Support Vector Machine (SVM).....</i>	<i>33</i>
<i>2.2.5.3 Random Forest (RF).....</i>	<i>34</i>
<i>2.2.5.4 Multi-layer perceptron artificial neural network (ANN).....</i>	<i>35</i>
<i>2.2.5.5 Least Absolute Shrinkage and Selection Operator (LASSO).....</i>	<i>35</i>
<i>2.2.5.6 RIDGE.....</i>	<i>36</i>
<i>2.2.5.7 XGBOOST</i>	<i>36</i>
<i>2.2.6 Avaliação dos modelos</i>	<i>37</i>
2.3 RESULTADOS E DISCUSSÃO	38
2.4 CONCLUSÕES.....	54
REFERÊNCIAS	55
CAPÍTULO 3 – Algoritmos para previsão da produtividade do algodão utilizando parâmetros climáticos no Brasil.....	66
RESUMO	66
ABSTRACT	67
3.1 Introdução	68
3.2 Material e Métodos	70
<i>3.2.1 Região estudada</i>	<i>70</i>
<i>3.2.2 Banco de dados</i>	<i>71</i>
<i>3.2.3 Evapotranspiração potencial</i>	<i>72</i>
<i>3.2.4 Balanço hídrico climatológico</i>	<i>72</i>
<i>3.2.5 Produtividade de algodão x Modelos não lineares.....</i>	<i>73</i>
<i>3.2.6 Algoritmos de Machine learning</i>	<i>74</i>
<i>3.2.7 Avaliação dos algoritmos.....</i>	<i>76</i>
3.3 Resultados e Discussão	77
<i>3.3.1 Produtividade do algodão</i>	<i>79</i>
<i>3.3.2 Produtividade x Correlação de Pearson.....</i>	<i>84</i>
<i>3.3.3 Algoritmos x clima x previsão.....</i>	<i>86</i>

3.3.4 Mapas de produtividade x Algoritmo TREE	90
3.4 Conclusões.....	92
Referências.....	93

RUMO À AGRICULTURA INTELIGENTE: PREVISÃO DE PRODUTIVIDADE AGRÍCOLA COM DADOS AGROMETEOROLÓGICOS USANDO MACHINE LEARNING

RESUMO – Sistemas agrícolas baseados em tecnologias digitais podem contribuir para um aumento da segurança alimentar global como parte dos esforços de mitigação e adaptação às mudanças climáticas. Um modelo acurado para previsão da produtividade beneficia muitos aspectos do gerenciamento de áreas produtivas. Portanto, nossa hipótese é a possibilidade do uso de algoritmos de machine learning para a previsão da produtividade em regiões do Brasil. Neste contexto, foram utilizadas séries históricas de produtividade de dois principais cultivos do Brasil. No primeiro trabalho, o objetivo foi prever a produtividade da cana-de-açúcar com seis meses de antecedência da colheita com acurácia em várias regiões produtoras do Brasil, utilizando modelos de machine learning. No segundo trabalho, o objetivo foi prever a produtividade do algodão usando algoritmos de machine learning baseado em elementos climáticos. Para cana-de-açúcar, nós utilizamos dados de produtividade da cana-de-açúcar de 62 localidades do Brasil. Foram utilizados também dados meteorológicos diários de temperatura média do ar, temperatura mínima, temperatura máxima, precipitação, velocidade do vento a 2 metros de altura, umidade relativa, irradiância solar no topo da atmosfera, irradiância solar global coletados na plataforma NASA/POWER. Foi utilizado um método de modelagem tradicional de regressão linear múltipla (RLM) e seis métodos de aprendizado de máquina (ML): support vector machine (SVM), random forest approach (RF), Artificial neural network (ANN), Least Absolute Shrinkage and Selection Operator (LASSO) regression, RIDGE regression e eXtreme Gradient Boosting (XGBoost) para prever a produtividade da cana-de-açúcar com seis meses de antecedência. Para o algodão, foi realizada a previsão da produtividade do algodão em função dos elementos climáticos por meio de algoritmos de aprendizado de máquina com quatro parâmetros ajustados por mínimos quadrados ordinários. Para cana-de-açúcar foram separados 4 grupos de localidades conforme a produtividade a partir de análise de cluster. Nos grupos 1 e 2 ocorrem os maiores valores de deficiência hídrica nas localidades produtoras de cana-de-açúcar. No teste dos modelos de ML, os valores de MAPE foram acima de 20%. No teste dos modelos pelo XGBOOST apresentou MAPEs de 29.71%, 26.79%, 43.5% e 33.36% para os grupos 1, 2, 3 e 4, respectivamente. Os modelos XBOOST e MLP apresentam os melhores desempenhos para a previsão de produtividade da cana-de-açúcar. Os modelos mostram que a produtividade do algodão apresenta tendência sigmóide devido ao acúmulo de precipitação, evapotranspiração potencial, armazenamento de água no solo e excedente hídrico durante o ciclo. É possível prever a produtividade do algodão para as principais regiões produtoras do Brasil usando algoritmos de aprendizado de máquina. Modelos de regressores Extra-trees tiveram melhor desempenho na previsão da produtividade do algodão usando dados climáticos do plantio à floração.

Palavras-chaves: análise de riscos, agrometeorologia, inteligência artificial

TOWARDS SMART AGRICULTURE: FORECASTING AGRICULTURAL PRODUCTIVITY WITH AGROMETEOROLOGICAL DATA USING MACHINE LEARNING

ABSTRACT – Agricultural systems based on digital technologies can contribute to an increase in global food security as part of climate change mitigation and adaptation efforts. An accurate model for forecasting productivity benefits many aspects of productive area management. Therefore, our hypothesis is the possibility of using machine learning algorithms to predict productivity in regions of Brazil. In this context, historical series of productivity of two main crops in Brazil were used. In the first work, the objective was to accurately predict the productivity of sugarcane six months before harvesting in several producing regions in Brazil, using machine learning models. In the second work, the objective was to predict cotton productivity using machine learning algorithms based on climatic elements. For sugarcane, we used sugarcane productivity data from 62 locations in Brazil. Daily meteorological data of mean air temperature, minimum temperature, maximum temperature, precipitation, wind speed at 2 meters high, relative humidity, solar irradiance at the top of the atmosphere, global solar irradiance collected on the NASA/POWER platform were also used. A traditional multiple linear regression (RLM) modeling method and six machine learning (ML) methods were used: support vector machine (SVM), random forest approach (RF), Artificial neural network (ANN), Least Absolute Shrinkage and Selection Operator (LASSO) regression, RIDGE regression and eXtreme Gradient Boosting (XGBoost) to predict sugarcane productivity six months in advance. For cotton, cotton yield prediction was performed as a function of climatic elements through machine learning algorithms with four parameters adjusted by ordinary least squares. For sugarcane, 4 groups of locations were separated according to productivity from cluster analysis. In groups 1 and 2, the highest values of water deficit occur in sugarcane-producing localities. In the test of the ML models, the MAPE values were above 20%. In the test of the models by XGBOOST they presented MAPEs of 29.71%, 26.79%, 43.5% and 33.36% for groups 1, 2, 3 and 4, respectively. The XBOOST and MLP models present the best performances for predicting sugarcane productivity. The models show that cotton yield has a sigmoid trend due to the accumulation of P, PET, STO and EXC throughout the cycle. It is possible to predict cotton productivity for the main producing regions in Brazil using machine learning algorithms. Extra-trees regressor models performed better in predicting cotton yield using climatic data from planting to flowering. With this, it is possible to have an average anticipation of around 80 days, allowing the producer time to plan their activities such as harvesting and sales strategies.

Keywords: risk analysis, agrometeorology, artificial intelligence

CAPÍTULO 1 – CONSIDERAÇÕES GERAIS

1 INTRODUÇÃO E JUSTIFICATIVA

1.1 Agricultura inteligente para o clima

A expansão de área e a intensificação rápida do uso do solo a partir de 1961 contribuíram para o aumento da produção total de alimentos em 240%, devido ao aumento da produtividade e da área de uso do solo. No entanto, a produção de alimentos deve dobrar até 2050 para alimentar a população mundial que deverá chegar a 9,7 bilhões, gerando um aumento de até 70% na demanda por alimentos, sem considerar a complexidade da mitigação das mudanças climáticas (FAO, 2013).

A temperatura média do ar na superfície terrestre aumentou 1,53 °C e a temperatura média da superfície 0,87 °C no período de 1850 a 2015. Em 2080, a produtividade agrícola global diminuirá de 3 a 16% (FAO, 2011), pois os sistemas agrícolas são altamente sensíveis às condições climáticas voláteis. Para que ocorra a manutenção e o fortalecimento da segurança alimentar, os sistemas de produção precisam se tornar mais robustos, para serem capazes de ter um bom desempenho em face de condições vitais de estresses e acidentes agrícolas. Além disso, a mudança nesses sistemas também pode levar ao aumento dos sumidouros de carbono, a benefícios significativos de mitigação e redução nas emissões por unidade de produto agrícola (Azadi et al., 2011).

A agricultura inteligente para o clima (Climate-smart Agriculture, em inglês) foi desenvolvida pela Organização para Agricultura e Alimentação (FAO) como uma abordagem unificada para enfrentar os desafios das mudanças climáticas. O conceito de Climate-smart Agriculture (CSA) foi lançado pela FAO em 2010 em um documento de referência preparado para a Conferência de Haia sobre Agricultura, Segurança Alimentar e Mudança Climática (FAO, 2019). A CSA é definida como uma abordagem que visa transformar, reorientar e desenvolver sistemas agrícolas baseados em tecnologias digitais, com o objetivo de contribuir para um aumento na segurança alimentar global como parte dos esforços de mitigação e adaptação às mudanças climáticas (Zecca, 2019).

Um pré-requisito essencial da agricultura inteligente é, definitivamente, a adoção da Tecnologia da Informação e Comunicação (TIC), que é promovida por formuladores de políticas em todo o mundo (Sørensen et al., 2019). A TIC pode incluir, de forma indicativa, sistemas de informação de gestão agrícola, sensores de umidade e solo, acelerômetros, redes de sensores sem fio, câmeras, drones, satélites de baixo custo, serviços online e veículos guiados automatizados (Benos et al., 2021).

Os produtores inovadores se esforçam para reduzir a quebra da produtividade entre a potencial e real usando tecnologias avançadas, uma vez que, a produção agrícola é dependente dos fatores ambientais como radiação solar, água, temperatura, manejo cultural e tipo de solo. Assim, compreender o impacto desses fatores é essencial para quantificar a causa e a magnitude da variação, principalmente em sistemas de cultivos de sequeiro (Al-Shammari et al., 2021).

3.4 Conclusões

Os elementos climáticos que mais influenciam a produtividade do algodão nas principais regiões produtoras do Brasil são ETP e o ARM. Essas duas variáveis demonstraram correlações positivas e alta significância no período de plantio ao florescimento. A ocorrência de elevadas P e EXC no período do florescimento promove redução da produtividade do algodão.

Os modelos não lineares evidenciam que a produtividade do algodão tem tendência sigmoide em função do acúmulo de P, ETP, ARM e EXC durante o ciclo da cultura. Com acúmulo de 30 mm de DEF e T médias acima de 26.4° C ocorre redução drástica da produtividade do algodão.

É possível prever antecipadamente a produtividade do algodão com acurácia para as principais regiões produtoras do Brasil usando algorithms of Machine learning. O melhor algoritmo foi o TREE que evidenciou índices de $r=0.99$, $R^2=0.98$, $MSE=20294.51$, $RMSE=142.46$ e $MAPE=2.13$. O algoritmo com menor desempenho foi o RLM.

O algoritmo TREE teve bastante sucesso na previsão da produção de algodão com dados climáticos do plantio até o florescimento. Com isso é possível prever ter uma antecipação em torno de ± 80 dias, o que possibilita o produtor um tempo hábil para planejar sua colheita.

Referências

Ahamed ATMS, Mahmood NT, Hossain N, Kabir MT, Das K, Rahman F, Rahman RM. 2015. Applying data mining techniques to predict annual yield of major crops and recommend planting different crops in different districts in Bangladesh. In: 2015 IEEE/ACIS 16th Int Conf Softw Eng Artif Intell Netw Parallel/Distributed Comput. [place unknown]; p. 1–6.

Akbar A, Kuanar A, Patnaik J, Mishra A, Nayak S. 2018. Application of Artificial Neural Network modeling for optimization and prediction of essential oil yield in turmeric (*Curcuma longa* L.). *Comput Electron Agric* [Internet]. 148:160–178. <http://www.sciencedirect.com/science/article/pii/S0168169916311371>

Allen RG, S PL, Raes D, Martin S. 1998. Crop evapotranspiration : Guidelines for computing crop water requirements / by Richard G. Allen ... [et al.]. *FAO Irrig Drain Pap* 56.:1–15.

Alvares CA, Stape JL, Sentelhas PC, de Moraes G, Leonardo J, Sparovek G. 2013. Köppen's climate classification map for Brazil. *Meteorol Zeitschrift*. 22(6):711–728.

Andrade Junior AS de, Silva FAM, de Lima MG, Amaral AB. 2009. Climatic aptitude zoning for cotton in Piauí State, Brazil. *Rev Ciência Agronômica*. 40(2):175.

Aparecido LE de O, Rolim G de S, de Moraes JR da SC, Rocha HG, Lense GHE, Souza PS. 2018. Agroclimatic zoning for urucum crops in the state of Minas Gerais, Brazil. *Bragantia*. 77(1):193–200.

Aparecido LE de O, de Souza Rolim G, De JR da SC, Costa CTS, de Souza PS, others. 2020. Machine learning algorithms for forecasting the incidence of *Coffea arabica* pests and diseases. *Int J Biometeorol*.:1–18.

Aparecido LE de O, Torsoni GB, Mesquita DZ, Meneses KC de, Moraes JR da SC de. 2020. Modeling safrinha corn productivity according to climatic conditions in Mato Grosso do Sul. *Rev Bras Climatol*. 26.

Assad ED, Martins SC, Beltrão NE de M, Pinto HS. 2013. Impacts of climate change on the agricultural zoning of climate risk for cotton cultivation in Brazil. *Pesqui Agropecuária Bras*. 48(1):1–8.

Barros MAL, Silva CRC Da, Lima LM De, Farias FJC, Ramos GA, Santos RC Dos. 2020. A Review on Evolution of Cotton in Brazil: GM, White, and Colored Cultivars. *J Nat Fibers*.:1–13.

Batista CH, de Aquino LA, Silva TR, Silva HRF. 2010. Growth and productivity of cotton culture in response to phosphorus application and irrigation methods. *Rev Bras Agric Irrig*. 4(4).

Bezerra, J. R. C.; Silva E Luz, M. J.; Pereira, J. R.; Santana, J. C. F.; Dias, J. M.; Santos, J. W.; Santos, T. Silva. 2003. Effect of soil water deficit on yield and fiber of herbaceous cotton, cultivar BRS 201. *Revista Brasileira de Oleaginosas e Fibras*, Campina Grande, v. 7, n. 2/3, p.727-734.

Bhojani SH, Bhatt N. 2020. Wheat crop yield prediction using new activation functions in neural network. *Neural Comput Appl.*:1–11.

Biswas R, Bhattacharyya B. 2019. Rice yield prediction in lower Gangetic Plain of India through multivariate approach and multiple regression analysis. *J Agrometeorol.* 21(1):101–103.

Brasil.1981. Ministry of Mines and Energy. General secretary. RADAMBRASIL Project. Rio de Janeiro: Survey of Natural Resources, 25, 29, 31.

CONAB (Companhia Nacional Do Abastecimento). 2019. www.conab.gov.br

Chen X, Qi Z, Gui D, Sima MW, Zeng F, Li L, Li X, Gu Z. 2020. Evaluation of a new irrigation decision support system in improving cotton yield and water productivity in an arid climate. *Agric Water Manag.* 234:106139.

Chou J, Xu Y, Dong W, Xian T, Wang Z. 2019. Research on the variation characteristics of climatic elements from April to September in China's main grain-producing areas. *Theor Appl Climatol.* 137(3–4):3197–3207.

Doorenbos J, Kassam AH. 1979. Yield response to water. *Irrig Drain Pap.*(33):257.

Draper NR, Smith H. 1980. *Applied Regression Analysis*, 2nd Edn. Chap. 1.
Elavarasan D, Vincent DR, Sharma V, Zomaya AY, Srinivasan K. 2018. Forecasting yield by integrating agrarian factors and machine learning models: A survey. *Comput Electron Agric* [Internet]. 155(October):257–282. <https://doi.org/10.1016/j.compag.2018.10.024>

Everingham Y, Sexton J, Skocaj D, Inman-Bamber G. 2016. Accurate prediction of sugarcane yield using a random forest algorithm. *Agron Sustain Dev.* 36(2):27.
Feng A, Zhou J, Vories ED, Sudduth KA, Zhang M. 2020. Yield estimation in cotton using UAV-based multi-sensor imagery. *Biosyst Eng* [Internet]. 193:101–114. <http://www.sciencedirect.com/science/article/pii/S1537511020300544>

Gonzalez-Sanchez A, Frausto-Solis J, Ojeda-Bustamante W. 2014. Attribute selection impact on linear and nonlinear regression models for crop yield prediction. *Sci World J.* 2014.

Goyal MK. 2014. Modeling of sediment yield prediction using M5 model tree algorithm and wavelet regression. *Water Resour Manag.* 28(7):1991–2003.
Griddi-Papp, I.L. 1965, Botany and Genetics. In - Cotton Culture and Fertilization, ed. Brazilian Institute of Potash, São Paulo, pp.117-157.

Gyamerah SA, Ngare P, Ikpe D. 2020. Probabilistic forecasting of crop yields via

quantile random forest and Epanechnikov Kernel function. *Agric For Meteorol.* 280:107808.

Hansen JW, Indeje M. 2004. Linking dynamic seasonal climate forecasts with crop simulation for maize yield prediction in semi-arid Kenya. *Agric For Meteorol.* 125(1–2):143–157.

Hussain M, Tariq AF, Nawaz A, Nawaz M, Sattar A, Ul-Allah S, Wakeel A. 2020. Efficacy of fertilizing method for different potash sources in cotton (*Gossypium hirsutum* L.) nutrition under arid climatic conditions. *PLoS One.* 15(1):1–9.

IBGE, G. Sistema IBGE de recuperação automática: SIDRA. 2020. Banco de dados agregados. <http://www.sidra.ibge.gov.br/bda/tabela/protabl.asp>.

Iqbal M, Ul-Allah S, Naeem M, Ijaz M, Sattar A, Sher A. 2017. Response of cotton genotypes to water and heat stress: from field to genes. *Euphytica.* 213(6):1–11.

Kaul M, Hill RL, Walthall C. 2005. Artificial neural networks for corn and soybean yield prediction. *Agric Syst.* 85(1):1–18.

Krige DG. 1951. A statistical approach to some basic mine valuation problems on the Witwatersrand. *J South African Inst Min Metall.* 52(6):119–139.

Lasdon LS, Waren AD. 1982. General reduced gradient software for linearly and non-linearly contained problems. *GRG2 users Guid Univ Texas, Austin.*

Li L, Baker TE, White SR, Burke K, others. 2016. Pure density functional for strong correlation and the thermodynamic limit from machine learning. *Phys Rev B.* 94(24):245129.

Li N, Lin H, Wang T, Li Y, Liu Y, Chen X, Hu X. 2020. Impact of climate change on cotton growth and yields in Xinjiang, China. *F Crop Res.* 247:107590.

Li P. 2012. Robust logitboost and adaptive base class (abc) logitboost. *arXiv Prepr arXiv12033491.*

Marcari MA, Rolim G de S, Aparecido LE de O. 2015. Agrometeorological models for forecasting yield and quality of sugarcane. *Aust J Crop Sci.* 9(11):1049–1056.

Marengo JA, Tomasella J, Nobre CA. 2017. Climate change and water resources. In: *Waters of Brazil.* [place unknown]: Springer; p. 171–186.

Martins E, de Oliveira Aparecido LE, Santos LPS, de Mendonça JMA, de Souza PS. 2015. Weather influence in yield and quality coffee produced in South Minas Gerais region. *Coffee Sci.* 10(4):499–506.

Marur, C.J. 1991. Comparison of rates of liquid photosynthesis, stomatal resistance and yield of two cotton cultivars submitted to water stress. *Pesquisa Agropecuaria Brasileira,* 26, 153- 161.

Mercante E, de Lima LEP, Justina DDD, Uribe-Opazo MA, Lamparelli RAC. 2012. Detection of soybean planted areas through orbital images based on culture spectral dynamics. *Eng Agrícola.* 32(5):920–931.

Moreto VB, de Souza Rolim G. 2015. Estimation of annual yield and quality of Valncia orange related to monthly water deficiencies. *African J Agric Res.* 10(6):543–553.

Moreto VB, de Souza Rolim G, Zacarin BG, Vanin AP, de Souza LM, Latado RR. 2017. Agrometeorological models for forecasting the qualitative attributes of “Valência” oranges. *Theor Appl Climatol.* 130(3–4):847–864.

Nayakekorala, H. Taylor, H. M. 1990. Phosphorus uptake rates of cotton roots at different growth stages from different soil layers. *Pant and soil.* Dordrecht, 122:105-110.

Opelt A, Fussenegger M, Pinz A, Auer P. 2004. Weak hypotheses and boosting for generic object detection and recognition. In: *Eur Conf Comput Vis.* [place unknown]; p. 71–84.

Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, Blondel M, Prettenhofer P, Weiss R, Dubourg V, others. 2011. Scikit-learn: Machine learning in Python. *J Mach Learn Res.* 12:2825–2830.

Quinlan JR. 1983. Learning Efficient Classification Procedures and Their Application to Chess End Games. In: Michalski RS, Carbonell JG, Mitchell TM, editors. *Mach Learn An Artif Intell Approach* [Internet]. Berlin, Heidelberg: Springer Berlin Heidelberg; p. 463–482. https://doi.org/10.1007/978-3-662-12405-5_15

Rahimi J, Khalili A, Butterbach-Bahl K. 2019. Projected changes in modified Thornthwaite climate zones over Southwest Asia using a CMIP5 multi-model ensemble. *Int J Climatol.* 39(12):4575–4594.

Rehman TU, Mahmud MS, Chang YK, Jin J, Shin J. 2019. Current and future applications of statistical machine learning algorithms for agricultural machine vision systems. *Comput Electron Agric.* 156:585–605.

Rosolem, C A. 2007. Maximum soybean productivity. Rondonópolis: Foundation MT. p.237-244.

Sahoo S, Russo TA, Elliott J, Foster I. 2017. Machine learning algorithms for modeling groundwater level changes in agricultural regions of the US. *Water Resour Res.* 53(5):3878–3895.

Schwalbert RA, Amado T, Corassa G, Pott LP, Prasad PVV, Ciampitti IA. 2020. Satellite-based soybean yield forecast: Integrating machine learning and weather data for improving crop yield prediction in southern Brazil. *Agric For Meteorol.* 284:107886.

Shekoofa A, Emam Y, Shekoufa N, Ebrahimi M, Ebrahimie E. 2014. Determining the most important physiological and agronomic traits contributing to maize grain yield through machine learning algorithms: a new avenue in intelligent agriculture.

PLoS One. 9(5):e97288.

Silva KA, de Souza Rolim G, Valeriano TTB, others. 2020. Influence of El Niño and La Niña on coffee yield in the main coffee-producing regions of Brazil. *Theor Appl Climatol.* 139(3):1019–1029.

Silva MP da, Marujo LG. 2012. Analysis of an intermodal model for the outlet of the soy production at the Brazilian midwest. *J Transp Lit.* 6(3):90–106.

Singh RK. 2008. Artificial neural network methodology for modelling and forecasting maize crop yield. *Agric Econ Res Rev.* 21(347-2016–16813):5–10.

Stackhouse PW, Westberg D, Hoell JM, Chandler WS, Zhang T. 2017. Prediction Of Worldwide Energy Resource (POWER)---Sustainable Buildings Methodology--(1.0 o Latitude by 1.0 o Longitude Spatial Resolution).

Thomas J, Mayr A, Bischl B, Schmid M, Smith A, Hofner B. 2018. Gradient boosting for distributional regression: faster tuning and improved variable selection via noncyclical updates. *Stat Comput.* 28(3):673–687.

Thornthwaite CW. 1948. An approach toward a rational classification of climate. [place unknown]: LWW.

Thornthwaite CW, Mather JR. 1955. Publications in climatology. *water Balanc.* 8:1–104.

Torkashvand AM, Ahmadi A, Nikravesht NL. 2017. Prediction of kiwifruit firmness using fruit mineral nutrient concentration by artificial neural network (ANN) and multiple linear regressions (MLR). *J Integr Agric.* 16(7):1634–1644.

Veenadhari S, Mishra B, Singh CD. 2011. Soybean productivity modelling using decision tree algorithms. *Int J Comput Appl.* 27(7):11–15.

Veenadhari S, Misra B, Singh CD. 2014. Machine learning approach for forecasting crop yield based on climatic parameters. In: 2014 Int Conf Comput Commun Informatics. [place unknown]; p. 1–5.

Wrege MS, Caramori PH, Gonçalves SL, Almeida WP de, Marur CJ, Pires JR, Yamaoka RS. 2000. Cotton zoning based on sowing periods of lower risk in Paraná State, Brazil. *Brazilian Arch Biol Technol.* 43(1):0.