



MAPEAMENTO DA PRODUTIVIDADE DE CULTURAS A PARTIR DE REDES NEURAIIS ARTIFICIAIS E IMAGENS MULTIESPECTRAIS

Laura Cristina Moura Xavier¹, George Deroco Martins¹

¹Universidade Federal de Uberlândia, Monte Carmelo, Monte Carmelo (xavier.laura moura@gmail.com)

RESUMO: A estimativa da produtividade de culturas é desafiadora devido à sua relação com as condições ambientais, estrutura física das espécies vegetais, composição química do solo e práticas de manejo de campo. Por este motivo, algoritmos de aprendizado de máquina em conjunto com dados de sensoriamento remoto vêm sendo estudados para aplicações na estimativa da produtividade. Sendo assim, o objetivo deste trabalho foi disponibilizar uma solução gratuita em ambiente de Sistema de Informação Geográfica – SIG para a estimativa e mapeamento de produtividade das culturas de trigo e girassol integrando aprendizado de máquina, especificamente a modelagem a partir do algoritmo de Redes Neurais Artificiais – RNA, e imagens multiespectrais. Informações de produtividade geolocalizadas, imagens multiespectrais do satélite Sentinel 2 e os índices de vegetação foram combinados como dados de entrada para o treinamento, validação e teste dos modelos de RNA. Os modelos que apresentaram menor erro (*Root Mean Squared Error* - RMSE em %) foram implementados na ferramenta em ambiente SIG. Para as culturas em estudo foram obtidos modelos com RMSEs satisfatórios, menores que 40% na validação interna e 30% na validação externa, constatando que os modelos de predição utilizando algoritmos de RNA são capazes de realizar estimativas de produtividade com acurácia.

Palavras-chave: estimativa de produtividade, sensoriamento remoto, Sistema de Informação Geográfica.

INTRODUÇÃO

Uma parte considerável dos incentivos à pesquisa na agricultura são destinadas para identificação de estratégias para o aumento de produtividade, o que contribui para o fornecimento de alimentos no intuito de atender a demanda mundial. A produtividade de uma cultura é a relação entre a produção atingida e a unidade de área. Dessa forma, os mapas de produtividade apresentam, especialmente, as áreas de maior e menor intensidade ou quantidade de produtividade, além de serem úteis para prever lucros e realizar investigações relacionadas ao manejo preciso da área (NTALIANI *et al.*, 2010).

Os trabalhos ligados a produção de culturas têm proposto o subsídio do sensoriamento remoto com o uso de imagens multiespectrais de alta e média resolução espacial para geração de modelos de estimativa e mapeamento da produtividade (HE *et al.*, 2018; LEDA *et al.*, 2019). Além das bandas das imagens multiespectrais de sensoriamento remoto, algoritmos de



aprendizado de máquina têm usado como dado de entrada para construção dos modelos de estimativa da produtividade agrícola índices de vegetação derivados de imagens de satélite (GASO *et al.*, 2019; SKAKUN *et al.*, 2019,).

A estimativa da produtividade de culturas agrícolas de forma acurada é uma tarefa complexa, pois esta variável está diretamente relacionada a vários fatores como as condições ambientais, estrutura física da cultura, composição química do solo e práticas de manejo utilizadas em campo (GUIMARÃES, 2019). Dessa forma, justifica-se a exploração de técnicas de pré-processamento de dados, modelagem e avaliação destas previsões a fim de garantir acurácia na estimativa da produtividade.

Assim, este trabalho teve como objetivo disponibilizar uma solução gratuita em ambiente SIG para a estimativa e mapeamento de produtividade das culturas de trigo e girassol integrando aprendizado de máquina, especificamente a modelagem a partir do algoritmo de Redes Neurais Artificiais – RNA, e imagens multiespectrais.

MATERIAL E MÉTODOS

O método utilizado foi dividido em aquisição e processamento de dados e construção da ferramenta. As áreas de estudo dos quais os dados foram obtidos estão localizadas na França. As informações georreferenciadas de produtividade foram fornecidas pela empresa *Lallemand Plant Care* em forma de um banco de dados composto por arquivos vetoriais no formato *shapefile* contendo os valores de produtividade mensurada por máquina do tipo colhedora agrícola. Em conjunto, foram obtidas imagens multiespectrais gratuitas do satélite Sentinel 2 devido às suas características de resolução espacial de 10, 20 e 60 metros, resolução temporal de 5 dias e sensor multiespectral de 13 bandas.

O processamento dos dados foi realizado utilizando o *software* QGIS versão 3.X e consistiu na extração dos valores de reflectância das imagens para associação com os valores de produtividade, e também no cálculo dos índices de vegetação. Para compor os dados de entrada dos modelos de estimativa foram calculados três índices de vegetação, (i) índice de vegetação da diferença normalizada – NDVI, (ii) índice de vegetação da diferença normalizada utilizando a banda do comprimento de onda verde – GNDVI, e (iii) índice de vegetação resistente a atmosfera na região do visível – VARI.

Para a construção da ferramenta primeiramente foi realizado desenvolvimento de modelos de RNA para predição, para isso foi realizada a codificação do algoritmo específico para problemas de regressão em linguagem de programação *Python* utilizando a IDE *online*



GoogleColaboratory. Depois da implementação, foi realizado o treinamento, validação interna e validação externa dos algoritmos de predição para ambas as culturas em estudo (trigo e girassol). Depois disso, foi realizada a extração dos parâmetros dos modelos que apresentaram melhor ajuste para o problema, ou seja, menores valores de *Root MeanSsquaredError* - RMSE. Por fim, foi realizada a implementação da ferramenta em ambiente SIG no software QGIS utilizando a ferramenta de modelador gráfico.

RESULTADOS E DISCUSSÃO

As arquiteturas de RNA foram obtidas por meio do monitoramento do RMSE com a variação de hiperparâmetros. A Tabela 1 apresenta os valores dos hiperparâmetros e o erro de validação dos modelos de RNA selecionados para as culturas.

Tabela 1. Valores dos hiperparâmetros e erro de treinamento dos modelos de RNA selecionados para cada cultura

Hiperparâmetro	Cultura	
	Trigo	Girassol
Taxa de aprendizagem	0,10	0,10
Coeficiente de momento	0,90	0,99
Número de camadas ocultas	1	1
Quantidade de neurônios na camada oculta	16	16
Número de épocas	100	100
RMSE (%) da validação interna	34,23	20,19
Desvio padrão do RMSE (%)	70,15	26,11

A interface da ferramenta seguiu o padrão das ferramentas tradicionais do software QGIS. No canto direito encontram-se todas as informações para a utilização da ferramenta, como a descrição do algoritmo, culturas aptas para predição, parâmetros de entrada, arquivos de saída, características dos modelos, bem como as informações sobre os desenvolvedores.

As entradas consistem na seleção da cultura a ser mapeada, campos para seleção das bandas das imagens Sentinel 2, campo para selecionar o contorno da área de interesse, e também opção para seleção de pontos para validação dos dados gerados. Os últimos campos se referem a seleção de caminhos para salvar os arquivos de saída, que são a superfície com os valores de produtividade estimada e estatística descritiva, e também a camada de pontos de validação contendo a produtividade estimada e o erro.

A interface de execução da ferramenta para estimativa da produtividade de culturas está apresentada na Figura 1.

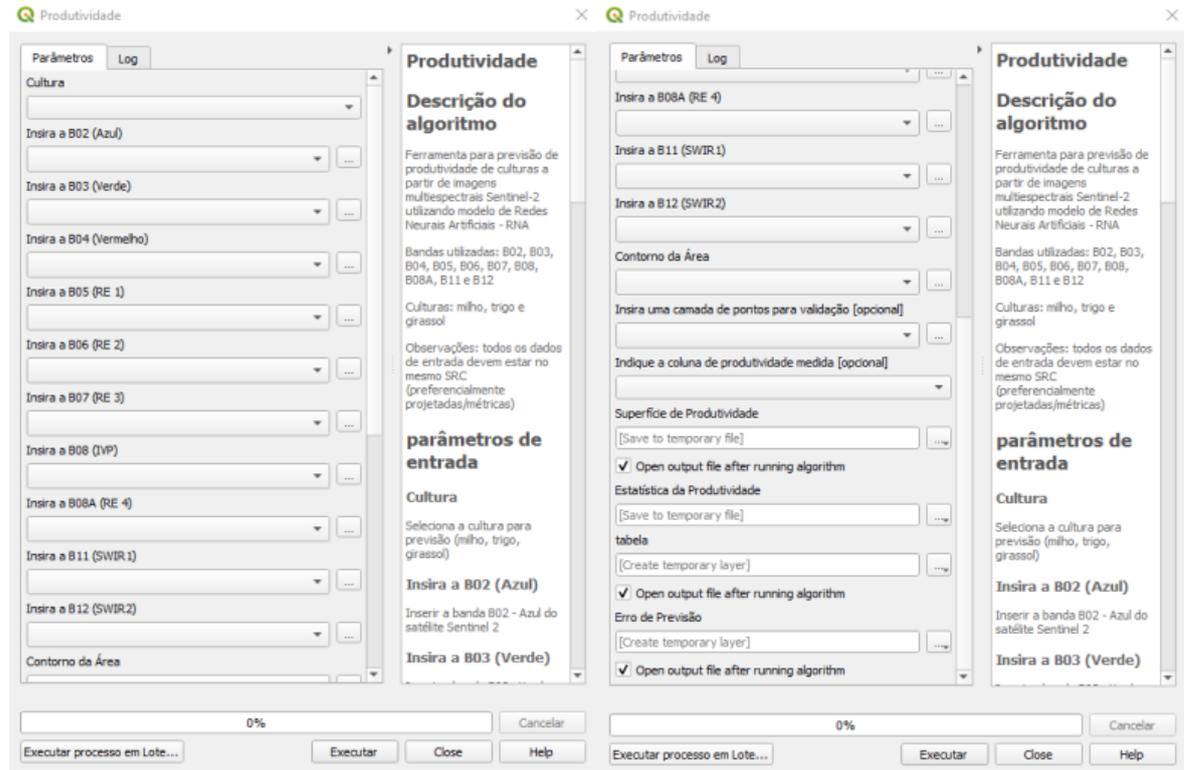


Figura 1 – Interface da ferramenta desenvolvida

O código fonte completo da ferramenta desenvolvida pode ser acessado pelo link <https://github.com/LauraMouraXavier/Ferramenta---Trabalho-deConclus-o-de-Curso>. A Figura 2 apresenta um exemplo dos resultados gerados após a execução da ferramenta em ambiente QGIS.

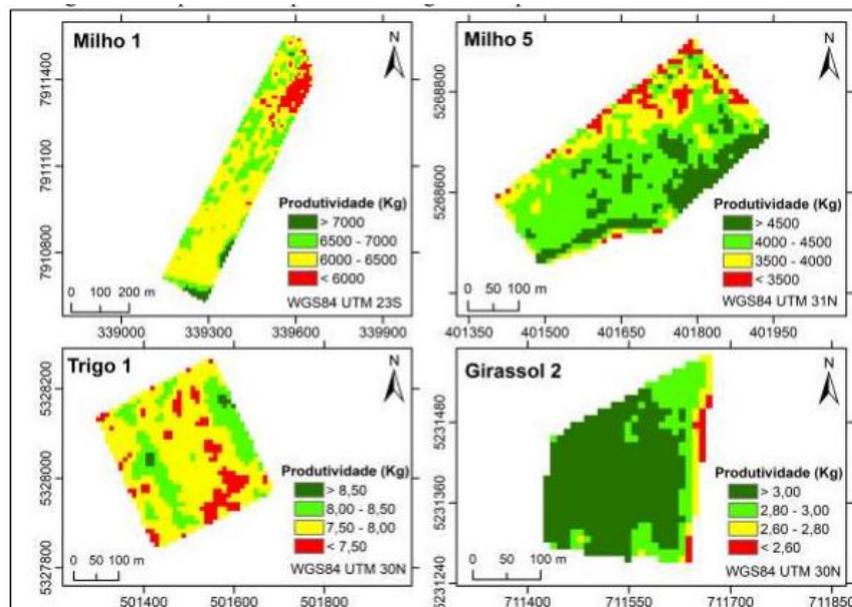


Figura 2 - Exemplo dos resultados gerados após a execução da ferramenta em ambiente QGIS



A partir da análise dos resultados gerados pela ferramenta foi possível gerar as superfícies estimadas de produtividade de cada cultura, bem como obter suas estatísticas e erros, estes dados podem ser exportados e importados para qualquer outro software para as diversas finalidades, como por exemplo a geração de mapas temáticos.

CONCLUSÕES

O objetivo deste estudo foi atingido através do desenvolvimento de uma ferramenta destinada ao mapeamento da produtividade das culturas de trigo e girassol. Para as culturas em estudo foram obtidos modelos com RMSEs satisfatórios, menores que 40% na validação interna e 30% na validação externa, constatando que os modelos de predição utilizando algoritmos de RNA são capazes de realizar estimativas de produtividade com acurácia.

REFERÊNCIAS

GASO, D. V.; BERGER, A. G.; CIGANDA, V. S. Predicting wheat grain yield and spatial variability at field scale using a simple regression or a crop model in conjunction with Landsat images. **Computers and Electronics in Agriculture**, v. 159, p. 75-83, 2019.

GUIMARÃES, E. S. Aprendizado de Máquina aplicado à predição da produtividade da cultura da soja utilizando dados de clima e solo. 2019. 78 f. Dissertação (Mestrado) – Curso de Matemática, Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - Usp, São Carlos, 2019.

HE, M. et al. Regional crop gross primary productivity and yield estimation using fused landsat-MODIS data. **Remote Sensing**, v. 10, n. 3, p. 372, 2018.

LEDA, V. C. et al. Sensoriamento remoto aplicado a modelagem de produtividade da cultura da cana-de-açúcar. **Energia na Agricultura**, v. 34, n. 2, p. 263-270, 2019.

NTALIANI, M. et al. Agricultural e-government services: An implementation framework and case study. **Computers and Electronics in Agriculture**, v. 70, n. 2, p. 337-347, 2010.

SKAKUN, S. et al. Winter wheat yield assessment from Landsat 8 and Sentinel-2 data: Incorporating surface reflectance, through phenological fitting, into regression yield models. **Remote Sensing**, v. 11, n. 15, p. 1768, 2019.