

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

IAGO RADAMÉS GARCIA DUARTE

ATRIBUTOS FÍSICOS DO SOLO E A SUA RESPOSTA ESPECTRAL PELA CULTURA DO
MILHO

Monte Carmelo
2022

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

IAGO RADAMÉS GARCIA DUARTE

ATRIBUTOS FÍSICOS DO SOLO E A SUA RESPOSTA ESPECTRAL PELA CULTURA DO
MILHO

Trabalho de Conclusão apresentado ao curso de Agronomia da Universidade Federal de Uberlândia, Campus Monte Carmelo, como requisito necessário para a obtenção do grau de Engenheiro Agrônomo.

Orientadora: Profa. Dra. Cinara Xavier de Almeida
Coorientador: Prof. Dr. George Deroco Martins

Monte Carmelo
2022

IAGO RADAMÉS GARCIA DUARTE

ATRIBUTOS FÍSICOS DO SOLO E A SUA RESPOSTA ESPECTRAL PELA CULTURA
DO MILHO

Trabalho de Conclusão apresentado ao curso de
Agronomia da Universidade Federal de
Uberlândia, Campus Monte Carmelo, como
requisito necessário para a obtenção do grau de
Engenheiro Agrônomo.

Monte Carmelo, 28 de julho de 2022

Banca Examinadora

Profª. Dra. Cinara Xavier de Almeida
Orientadora

Prof. Dr. George Deroco Martins
Coorientador

Prof. Dr. Ricardo Falqueto Jorge
Membro da Banca

Monte Carmelo
2022

AGRADECIMENTOS

Primeiramente agradeço a Deus pelo dom da vida, por me iluminar e proteger meus caminhos e me dar forças em momentos difíceis.

Aos meus pais, Valcir Garcia Duarte e Vânia Teresa Pinto, pelo amor e apoio que sempre me deram em toda minha vida, que sempre fizeram tudo que estava ao seu alcance para me dar saúde, educação e caráter. Agradeço também a todos meus familiares, em especial, minha madrinha Valéria, meu padrinho Valdevino e minha tia Odair, que sempre estiveram presentes, me apoiando e incentivando.

A minha orientadora Prof^a. Dra. Cinara Xavier de Almeida, por todos ensinamentos, por todas as conversas e conselhos, por me confiar responsabilidades durante o desenvolvimento do projeto e pela paciência e compreensão durante esta fase.

Ao meu coorientador Prof. Dr. George Deroco Martins por toda a dedicação e paciência em me explicar e transmitir o conhecimento para o desenvolvimento do trabalho e me instigar para aprofundar sobre o tema Agricultura Digital.

Ao membro da banca Prof. Dr. Ricardo Falqueto Jorge, por todo acompanhamento durante o trabalho, pela ajuda na coleta de dados em campo e por todos os conselhos e ensinamentos.

Agradeço à Universidade Federal de Uberlândia Campus Monte Carmelo por me proporcionar cursar a graduação nesta instituição de excelência. E a todos os técnicos, docentes e demais colaboradores que tornam esta instituição especial, em particular, meus sinceros agradecimentos ao corpo docente do curso de Agronomia, pelo respeito, dedicação e comprometimento em transmitir conhecimento de qualidade a nós discentes, mesmo em situações que a infraestrutura não seja a ideal.

A todos os meus amigos de graduação, pelo companheirismo, pelas trocas de experiências, pela convivência e pelos momentos especiais que tivemos juntos. Em especial, ao Pablo Arthur Silva Gonçalves, que hoje tenho o prazer de chama-lo de irmão.

A minha querida Camila Isabel Pereira Rezende, pela amizade, companheirismo, ensinamentos, pelas broncas e conselhos, pelas experiências que tivemos juntos, por sempre me apoiar e incentivar a evoluir e ser uma pessoa melhor, obrigado por sempre estar ao meu lado e me inspirar!

Agradeço também a empresa MICROGEO Biotecnologia Agrícola pela parceria para a execução do projeto, fornecendo a área, insumos, o auxílio financeiro para o desenvolvimento de todo o projeto e pela disponibilização dos dados para meu trabalho.

Agradeço ao Programa de Educação Tutorial (PET) Agronomia Monte Carmelo pela oportunidade em fazer parte deste projeto durante a minha graduação, por todo conhecimento adquirido e desenvolvido nele e pelas amizades construídas neste tempo. E aos tutores, Prof. Dr. Bruno Nery Fernandes Vasconcelos e ao Prof. Dr. Drausio Honorio Moraes, pela amizade, ensinamentos, apoio e conselhos durante minha permanência no programa.

SUMÁRIO

RESUMO	6
1. INTRODUÇÃO	7
2. OBJETIVO	9
3. REVISÃO DE LITERATURA	9
4. MATERIAL E MÉTODOS	12
4.1. Descrição da área experimental	12
4.2. Delineamento experimental e tratamentos.....	13
4.3. Avaliação dos atributos físicos do solo.....	14
4.3.1. Determinação da densidade e porosidade total do solo.....	14
4.3.2. Determinação da resistência do solo à penetração	15
4.4. Aquisição da imagem multiespectral	17
4.5. Processamento digital de imagens	18
4.6. Extração dos valores de reflectância.....	18
4.7. Geração das bases de dados	18
4.7.1. Base de dados de treino e validação dos modelos de predição	18
4.7.2. Base de dados para a predição dos parâmetros agronômicos.....	19
4.8. Treino e avaliação dos modelos.....	19
4.9. Geração dos mapas de caracterização dos parâmetros	20
5. RESULTADOS E DISCUSSÃO	21
6. CONCLUSÕES	30
REFERÊNCIAS BIBLIOGRÁFICAS	31

RESUMO

A qualidade do solo pode ser estimada a partir de seus atributos químicos, físicos e biológicos, sendo que as propriedades físicas do solo são fundamentais para o desenvolvimento radicular, condutividade hidráulica e trocas gasosas, refletindo diretamente nos demais atributos. No entanto, seu monitoramento em campo se torna muito oneroso devido sua elevada variabilidade espacial, fazendo-se necessário um elevado número de amostras que devem ser coletadas, justificando-se dessa forma, a necessidade de se desenvolver ferramentas e metodologias para o monitoramento remoto das propriedades físicas do solo. Assim, o presente trabalho teve como objetivo avaliar os atributos físicos do solo por meio da resposta espectral da cultura do milho e avaliar o potencial da associação da aprendizagem de máquinas com o sensoriamento remoto como ferramenta para a predição dos atributos físicos do solo, por meio da imagem multiespectral orbital. Para isso, o estudo foi realizado em uma fazenda no município de Ituiutaba – MG, onde foram determinadas a densidade do solo, a porosidade total e a resistência do solo à penetração, nas profundidades de 0,00 – 0,10 m e 0,10 – 0,20 m, em 100 pontos amostrais georreferenciados. A imagem orbital multiespectral foi obtida do satélite Sentinel 2, na mesma data de coleta dos dados em campo. As arquiteturas de predição testadas foram a Linear Regression, Multilayer Perceptron, SMOreg, Random Forest e Random Tree, a fim de verificar a partir do Erro Médio Quadrático (RMSE) e RMSE normalizado (RMSE%) qual arquitetura apresenta melhor desempenho na predição dos atributos agrônômicos. Os resultados confirmaram que a associação da aprendizagem de máquinas com a imagem multiespectral orbital do satélite Sentinel 2 para a predição dos atributos físicos do solo se mostrou promissor. As arquiteturas que obtiveram melhor desempenho na predição dos dados, do presente trabalho, foram a Linear Regression, para a densidade do solo na profundidade de 0,10 – 0,20 m e para as demais propriedades, em ambas profundidades, foi a Random Forest. Na área de estudo os índices de densidade e porosidade do solo, em geral, para ambas as profundidades se apresentaram inferiores aos níveis críticos descritos na literatura, já, para resistência do solo à penetração, os valores de ambas as profundidades se mostraram superiores aos valores críticos, indicando níveis de compactação do solo. Portanto, a associação da aprendizagem de máquinas com o sensoriamento remoto, por meio da imagem multiespectral orbital do satélite Sentinel 2, como ferramenta para a predição dos atributos físicos do solo de densidade, porosidade total e resistência do solo à penetração, se mostrou promissor, podendo ser uma ferramenta para o monitoramento remoto das propriedades físicas do solo, fazendo-se necessário mais estudos, em diferentes tipos de solos e culturas, para maior validação e acurácia desta ferramenta.

Palavras-Chave: machine learning, predição de dados, agricultura de precisão.

1. INTRODUÇÃO

A cultura do milho (*Zea mays* L.) tem grande importância econômica e social, por ser cultivada em praticamente todas as partes do planeta. O milho consiste em um cereal trivial, estando presente na alimentação humana, animal e, não apenas para cunho alimentício, como também está envolvido em abastecimento de energia como um biocombustível (Embrapa, 2019).

Na agricultura, tem-se um conjunto de fatores que influenciam, direta e indiretamente, o desenvolvimento das plantas e, conseqüentemente, a produtividade das culturas. Dentre esses fatores de produtividade, destacam-se os atributos físicos do solo, que são o conjunto de caracteres que delineiam o comportamento da termodinâmica do solo como um todo (MENDES, 2020).

Atributos físicos do solo, tais como, densidade e porosidade, resistência do solo à penetração e textura têm influência direta no potencial de água no solo, na taxa de difusão de oxigênio e crescimento radicular (LETEY, 1958). Portanto, se faz necessário o monitoramento da qualidade física do solo para que haja um bom desenvolvimento radicular e, juntamente com os demais manejos, promover a melhor condição para as plantas expressarem seu máximo potencial produtivo. Assim, como ferramenta para auxiliar no monitoramento dessas propriedades, vem se destacando o uso da agricultura de precisão (AP), junto com suas técnicas e tecnologias que a permeiam.

A AP consiste em um conjunto de técnicas que permitem o gerenciamento localizado das áreas agrícolas, com o objetivo de fornecer informações para uma tomada de decisão mais assertiva (Balastreire, 1998). No entanto, um dos principais entraves da AP é o processo de aquisição de dados em campo, que, por ser volumoso, se torna oneroso ao agricultor (RODRIGUES et al., 2012; SANTI et al., 2012). Assim, em conjunto com a AP, o uso de imagens do sensoriamento remoto vem se tornando uma alternativa para o processo de aquisição de dados, tal como, para a determinação das propriedades do solo das áreas agrícolas.

Associado ao sensoriamento remoto, vem se destacando a utilização do aprendizado de máquinas na agricultura, sob diversas aplicações, tal como no trabalho de Rezende (2022) em que foi avaliado o potencial do aprendizado de máquinas na classificação de áreas com diferentes manejos de adubação por meio de imagem multiespectral. Visto que, a maioria dos trabalhos com sensoriamento remoto resultam em um grande volume de dados, os quais precisam ser processados e analisados, para que se possa obter informações aplicáveis para a

tomada de decisão na agricultura, assim se dá a importância do aprendizado de máquinas como ferramenta para o tratamento desses dados.

Na literatura, há poucos trabalhos utilizando a aprendizagem de máquinas para estimar atributos físicos do solo por meio da reflectância, extraída de sensores multiespectrais orbitais, fazendo-se assim de extrema necessidade a obtenção e utilização de ferramentas que consigam estimar as propriedades físicas do solo, de forma a reduzir os custos com amostragem e tempo de processamento dos dados, otimizando a tomada de decisões no manejo das áreas agrícolas, com vistas à maior produção das culturas.

Segundo Bauer et al. (1980), Curran et al. (1991) e Hoffer (1978), em relação ao espectro de reflectância de uma folha verde normal no intervalo entre 400 nm e 2500 nm, ele pode ser subdividido em três regiões espectrais: visível, infravermelho próximo (NIR) e infravermelho de ondas curtas (SWIR). De forma que, na região do visível, entre 400 nm e 700 nm, está correlacionado a absorção dos pigmentos da folha, os carotenos, xantofilas e, principalmente, a clorofila. Já, na região do infravermelho próximo, entre 700 nm e 1300 nm, há uma elevada reflexão de energia, a qual está correlacionada com as estruturas internas das folhas. E, na região do infravermelho de ondas curtas, a reflectância da vegetação verde é dominada por fortes bandas de absorção pela água, que ocorrem aproximadamente em 1400 nm, 1900 nm e 2700 nm, portanto, as regiões entre essas bandas de absorção são fortemente influenciadas pelo conteúdo de água na folha, de forma que, nesta região espectral, a reflectância foliar é inversamente relacionada com a quantidade total de água presente nas folhas (FORMAGGIO; SANCHES, 2017).

Tendo em vista que os atributos físicos do solo influenciam diretamente na planta, principalmente na capacidade de absorção de água, ocorrendo alterações morfofisiológicas as quais são refletidas na resposta espectral das plantas, obtidas por meio do sensoriamento remoto. Tem-se assim, a hipótese no presente trabalho que há correlação entre os atributos físicos do solo com a resposta espectral da planta, sendo possível assim, realizar a predição dos atributos físicos do solo por meio do aprendizado de máquinas.

2. OBJETIVO

Objetivou-se com este estudo avaliar os atributos físicos do solo por meio da resposta espectral da cultura do milho, e, avaliar o potencial da associação da aprendizagem de máquinas com o sensoriamento remoto como ferramenta para a predição dos atributos físicos do solo, por meio imagem multiespectral orbital.

3. REVISÃO DE LITERATURA

O milho (*Zea mays* L.) é originário da América Central (PATERNIANI; CAMPOS, 2005), pertencente à família Poaceae e representa o cereal com maior produção mundial, devido sua importância na alimentação humana e animal. No Brasil, ele tem elevada representatividade no agronegócio e na economia nacional. No ano agrícola de 2021/2022, estima-se que a cultura ocupou uma área de aproximadamente 21,24 milhões de hectares, com uma produção de 115,6 milhões de toneladas, tendo como produtividade média 5,44 toneladas por hectare (CONAB, 2022).

Dentre os fatores que influenciam a produtividade das culturas, destacam-se os atributos físicos do solo, visto que estão relacionadas ao fornecimento de água, oxigênio e à resistência do solo à penetração das raízes (LETEY, 1958), os quais são fundamentais para o desenvolvimento das culturas.

Entende-se como atributos físicos do solo um conjunto de caracteres que delineiam o comportamento da termodinâmica do solo como um todo, tais como, a densidade e porosidade total do solo e a resistência do solo à penetração (MENDES, 2020). A qualidade física do solo está diretamente ligada ao manejo adotado. Seu uso intensivo juntamente com um manejo inadequado propicia a degradação dos atributos físicos do solo, de forma a intensificar processos que diminuem o tamanho de poros, aumentam a densidade e conseqüentemente impossibilitam o crescimento e o desenvolvimento radicular das plantas, acarretando em uma má qualidade física do solo e redução da produção das culturas.

Materchera et al. (1992) estudando a influência da resistência do solo à penetração no sistema radicular em diferentes culturas, constataram que esse atributo causa aumento no diâmetro das raízes na camada compactada, por provocar modificações morfológicas e

fisiológicas, específicas a cada espécie ou cultivar, a fim de se adaptarem. Rosolem et al. (1994) e Foloni et al. (2003) também verificaram que o diâmetro médio radicular das plantas de milho aumentou na camada de solo compactado com o incremento da resistência do solo à penetração. Corroborando, Freddi et al. (2007) verificaram que valores de resistência do solo à penetração variando entre 1,03 e 5,69 MPa provocaram alterações na morfologia do sistema radicular do milho, reduzindo a produtividade da cultura em 2,581 t ha⁻¹, porém não foram impeditivos ao enraizamento.

Lima (2004) destaca que práticas de manejo do solo e das culturas ocasionam mudanças nos atributos físicos do solo, sendo essas mudanças permanentes ou temporárias. Por isso, o conhecimento da qualidade física de um solo é fundamental para a tomada de decisões quanto às práticas de manejo a serem adotadas.

Com o objetivo de obter maior conhecimento e gestão da área agrícola, para otimizar a tomada de decisões, a AP vem sendo cada vez mais implementada nas práticas agrícolas. Segundo Balastreire (1998), a AP pode ser definida como um conjunto de técnicas que permitem o gerenciamento localizado das culturas, de forma a detectar, monitorar e manejar a variabilidade espacial e temporal dos sistemas de produção agropecuários visando aprimorá-los. A partir desse entendimento, é possível compreender a AP não apenas como uma prática cultural, mas como um modelo de gestão, englobando o uso de tecnologias para o manejo adequado das variações espaciais e fatores que afetam a produção das culturas (MANTOVANI, 2000).

Uma das ferramentas utilizadas na AP é o sensoriamento remoto, o qual se caracteriza pela obtenção de informações de um objeto sem existir um contacto físico com o mesmo. Ele vem sendo amplamente utilizado no monitoramento da agricultura sob diversas abordagens, como, em aplicações específicas (ex.: AP, previsão de produção), por meio de vários sensores (ex.: visível, multiespectral, térmico, microondas, hiperespectral), plataformas para locais específicos (ex.: nível orbital, aéreo ou terrestre) e diferentes contextos climáticos (WEISS; JACOB; DUVEILLERC, 2020).

Entretanto, um dos entraves da AP é o processo de coleta de dados, o qual se torna oneroso ao agricultor, visto que há uma demanda de um grande número de amostras de solo georreferenciadas, por meio de uma malha amostral bem definida, e posterior análise laboratorial, para aquisição das características detalhadas do solo (RODRIGUES et al., 2012; SANTI et al., 2012). Assim, o uso de imagens do sensoriamento remoto vem se tornando uma alternativa para esse processo de determinação das propriedades do solo.

A extração de informações por sensores remotos, revela-se potencialmente útil na agricultura. Com foco na AP, Sishodia, Ray e Singh (2020) relataram estudos na gestão da água de irrigação, estudos de estresse hídrico, evapotranspiração, umidade do solo, gestão de nutrientes, gestão de doenças, manejo de ervas daninhas e no monitoramento de safra e produtividade.

Associado ao sensoriamento remoto, vem se destacando a utilização do aprendizado de máquinas na agricultura, sob diversas aplicações. Visto que, a maioria dos trabalhos com sensoriamento remoto resultam em um grande volume de dados, os quais precisam ser processados e analisados, para que se possa obter informações aplicáveis a tomada de decisão na agricultura, assim se dá a importância do aprendizado de máquinas como ferramenta para o tratamento desses dados.

O aprendizado de máquinas é definido como o campo científico que dá às máquinas a capacidade de aprender sem serem estritamente programadas (SAMUEL, 1967). As tarefas do aprendizado de máquinas são normalmente classificadas em diferentes categorias, conforme o tipo de aprendizagem (supervisionado ou não supervisionado) e a técnica de aprendizagem (ex.: classificação, regressão, agrupamento, redução de dimensionalidade, etc). Para isso, a partir de modelos de aprendizado de máquinas (ex.: redes neurais artificiais, modelos bayesianos, aprendizado profundo, árvores de decisão, máquina de vetores de suporte, etc), seus algoritmos associados (ex.: MLP - MultiLayer Perceptron, NB - Naive Bayes, KNN - k-Nearest Neighbor, RF -Random Forest, etc.) realizam a tarefa (LIAKOS et al., 2018).

O aprendizado de máquinas tem sido uma ferramenta com aplicações diversas na agricultura. Em sua revisão, Liakos et al. (2018) relataram trabalhos com a aplicação do aprendizado de máquinas para a previsão de produtividade, detecção de doenças, detecção de plantas daninhas e manejo do solo. Para o manejo do solo o autor cita trabalhos com objetivos diversos, tais como, o desenvolvimento de um método que avalia a secagem do solo, utilizando dados de evapotranspiração e precipitação; estimativa da evapotranspiração diária; estimativa da temperatura do solo em diferentes camadas, e estimativa da umidade do solo.

Estudos contemporâneos têm buscado utilizar técnicas de aprendizagem de máquinas, com o objetivo de desenvolver modelos preditivos, correlacionando parâmetros agrônômicos e refletância. Prestes (2020) e Gerke (2017), em trabalhos correlatos, objetivaram obter um modelo numérico para a predição de produtividade de trigo baseado em valores digitais de bandas espectrais e valores estimados de alturas de plantas extraídos de imagens coletadas por aeronave remotamente pilotada. Já, Gholizadeh (2016) estudou modelos de predição de textura

de solo, por meio de leituras espectrais do solo utilizando técnicas de espectroscopia de reflectância difusa.

Em suma, há poucos trabalhos na literatura utilizando a aprendizagem de máquinas para estimar atributos físicos do solo por meio da reflectância, extraída de sensores multiespectrais orbitais, tendo-se assim, a necessidade de mais pesquisas para obtenção e utilização de ferramentas que consigam estimar as propriedades físicas do solo, de forma a reduzir os custos com amostragem e tempo de processamento dos dados, otimizando a tomada de decisões no manejo das áreas agrícolas, com vistas ao incremento na produção das culturas.

4. MATERIAL E MÉTODOS

4.1. Descrição da área experimental

O estudo foi realizado em uma propriedade agrícola, no município de Ituiutaba, MG, cujas as coordenadas geográficas são: 18°55'24.2"S de Latitude, 49°19'37.9"W de Longitude e altitude média de 580 m (Figura 1). O clima da região, segundo a classificação de Köppen-Geiger, é classificado como AW, tropical de inverno seco, com estação chuvosa bem definida no período de outubro a abril e um período seco de maio a setembro, com temperatura média de 23,4°C e pluviosidade anual média de 1.305 mm.

O solo da área experimental foi classificado, de acordo com os critérios do Sistema Brasileiro de Classificação de Solos (EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA, 2018), como um LATOSSOLO VERMELHO Distrófico típico, textura argilosa e relevo plano.

A área era cultivada anteriormente com culturas anuais por longo período e no ano agrícola anterior foi cultivada com a cultura da soja.



FIGURA 1. Imagem da propriedade agrícola em Ituiutaba – MG, com a área experimental delineada pela linha vermelha.

4.2. Delineamento experimental e tratamentos

Foram utilizadas duas unidades experimentais para a obtenção dos dados *in situ*, de forma que cada unidade experimental correspondeu a uma área de 1,4 hectares cultivados com milho (*Zea mays*) em segunda safra, onde foi determinada uma grade amostral de 50 pontos, em cada unidade, de 50 m x 50 m entre ponto (Figura 2), os quais foram georreferenciados no ato da coleta em campo, que ocorreu nos dias 27, 28 e 29 de abril de 2019.

Em cada ponto amostral foram coletadas amostras de solo para determinação da densidade do solo, porosidade total e resistência do solo à penetração, em duas profundidades, 0,0-0,10 e 0,10-0,20 m. Totalizando assim, 200 amostras para cada atributo físico, ou seja, 100 amostra para cada profundidade.




FIGURA 2. Distribuição da grade amostral nas duas unidades experimentais.

O milho foi semeado com o auxílio de uma semeadora-adubadora tracionada por um trator. O espaçamento utilizado foi de 0,50 m entrelinhas, com aproximadamente 3 plantas por metro e profundidade de semeadura de 0,05 m.

A adubação da cultura foi realizada em função da análise química do solo e recomendações da Comissão de Fertilidade do Solo para o Estado de Minas Gerais - CFSEMG (1999).

4.3. Avaliação dos atributos físicos do solo

4.3.1. Determinação da densidade e porosidade total do solo

A densidade do solo foi determinada pelo método do anel volumétrico. Foram coletadas 200 amostras indeformadas de solo na ocasião da colheita do milho, nas camadas de 0,0-0,10 e 0,10-0,20 m, as quais foram saturadas por vinte e quatro horas em bandeja com uma lâmina de água a 2/3 de sua altura. Em seguida, as amostras foram pesadas e colocadas em estufa para secagem a 105°C por 24 horas. A altura e o diâmetro dos anéis foram previamente medidos, utilizando um paquímetro digital, para obtenção de seus respectivos volumes. Após a secagem,

foi realizada a pesagem e o seguinte cálculo foi realizado para determinação da densidade do solo (TEIXEIRA, 2017):

$$D_s = \frac{M_s}{V_t} \quad (1)$$

em que, D_s é a densidade do solo em g cm^{-3} , M_s é a massa de solo seco em g e V_t é o volume total do cilindro em cm^3 .

Sabendo que o volume total da amostra é igual ao volume do cilindro, o mesmo foi calculado através da seguinte fórmula:

$$V_t = \pi r^2 h \quad (2)$$

em que, V_t é volume do cilindro em cm^3 , r é raio do cilindro em cm e h é a altura do cilindro, em cm.

A porosidade total do solo foi estimada através do método direto, pelo seguinte cálculo:

$$P_t = \frac{(a-b)-(c-d)}{V_t} \quad (3)$$

em que, P_t é a porosidade total do solo em $\text{m}^3 \text{ m}^{-3}$, a é a massa do conjunto amostra-cilindro-tecido-liga saturado em g, b é a massa do conjunto amostra-cilindro-tecido-liga seco a 105°C em g, c massa do conjunto cilindro-tecido-liga saturado em g, d é a massa do conjunto cilindro-tecido-liga seco a 105°C em g, e V_t é o volume total do anel volumétrico em cm^3 .

4.3.2. Determinação da resistência do solo à penetração

Determinou-se a resistência do solo à penetração nas camadas de 0-0,1 e 0,1-0,2 m, através de um penetrômetro de impacto (STOLF, 1991). O penetrômetro que foi utilizado apresenta as seguintes características: área da base do cone de $1,29 \times 10^{-4} \text{ m}^2$; altura de queda de 0,40 m; massa do êmbolo, ou seja, massa que provoca o impacto igual a 4,00 kg e massa dos

demais componentes do penetrômetro, excluía a de impacto, igual a 3,20 kg, conforme representado na Figura 3. Simultaneamente a essas leituras, determinou-se o conteúdo gravimétrico de água no solo (TEIXEIRA, 2017).




FIGURA 3. Características do penetrômetro de impacto utilizado.

A transformação dos valores da penetração da haste do aparelho no solo (impactos m^{-1}) em resistência do solo à penetração (RP , em MPa) foi realizada conforme a equação 4 (STOLF, 1991):

$$RP = \frac{(Mg + mg) + \frac{M}{M+m} \times Mg \times \frac{h}{x}}{A} \quad (4)$$

em que, M é a massa que provoca o impacto (kg); m corresponde à massa dos demais componentes do penetrômetro excluía a de impacto (kg); $M+m$ é a massa total do aparelho (kg); g equivale a aceleração da gravidade; Mg e mg são os pesos das massas consideradas; h é a altura de queda da massa que provoca o impacto (m); x corresponde à penetração ocasionada por ação do impacto (impactos m^{-1}), e A é área da base do cone (m^2).

4.4. Aquisição da imagem multiespectral

A finalidade do presente trabalho foi estimar os parâmetros agronômicos avaliados *in situ* a partir da resposta espectral da cultura do milho, por meio de uma imagem multiespectral tomada em uma data correlata à data das avaliações em campo.

Neste sentido, foi realizado a aquisição de uma imagem orbital multiespectral obtida pelo sensor Multispectral Instrument (MSI), instalado a bordo do satélite Sentinel-2, referente a data de 28 de abril de 2019, adquirida por meio da instituição United States Geological Survey - USGS, a qual se encontra disponível gratuitamente no link <<https://earthexplorer.usgs.gov/>> em formato JP2. No trabalho foram utilizadas as 13 bandas espectrais, as quais tem suas características discriminadas na Tabela 1.

Tabela 1. Características do sensor SENTINEL-2A

Resolução espacial	Nº da Banda	Nome da Banda	Comprimento de Onda Central (nanômetro)
10 m	B02	Blue (Azul)	490
	B03	Green (Verde)	560
	B04	Red (Vermelho)	665
	B08	NIR (Infravermelho Próximo)	842
20 m	B05	Red Edge 1	705
	B06	Red Edge 2	740
	B07	Red Edge 3	783
	B08A	Red Edge 4	865
	B11	SWIR 1	1610
	B12	SWIR 2	2190
60 m	B01	Aerossol	443
	B09	Water Vapor	940
	B10	Cirrus	1375

Fonte: Engesat, 2015.

4.5. Processamento digital de imagens

Após a obtenção da imagem, deu-se início a fase de processamento. Nesta fase, as imagens foram submetidas à correção atmosférica e, em seguida, à reamostragem das bandas.

A correção atmosférica foi realizada para eliminar a interferência atmosférica, para isso utilizou-se o software SNAP versão 8.0, da empresa ESA - European Space Agency, por meio do plugin Sen2cor. A reamostragem das bandas também foi realizada pelo software SNAP, para compatibilizar todas as bandas em uma mesma resolução de 10 m.

Em seguida, foi realizado o empilhamento das bandas reamostradas, utilizando o software Environment for Visualizing Images - ENVI 5.1, por meio da ferramenta Layer Stracking, de forma a consolidar todas as bandas em um único arquivo.

4.6. Extração dos valores de reflectância

Para a extração dos valores de reflectância, primeiramente foi criado um arquivo no formato *ShapeFile* com as coordenadas dos 100 pontos amostrais, os quais foram adquiridos em campo com o receptor GNSS. Posteriormente, a partir da imagem multiespectral corrigida e o arquivo *ShapeFile*, utilizou-se a ferramenta Region of Interest – ROI Tool do software ENVI 5.1 para realizar a extração dos valores de reflectância de cada banda espectral, para as respectivas coordenadas.

4.7. Geração das bases de dados

4.7.1. Base de dados de treino e validação dos modelos de predição

Após as avaliações, os parâmetros agronômicos foram calculados e tabulados, formando-se as bases de dados no formato de tabela contendo os valores dos parâmetros agronômicos e os valores de reflectância extraídos das bandas espectrais. De forma que foram geradas duas tabelas, uma para cada profundidade analisada, ou seja, uma tabela com os valores

de reflectância e os parâmetros agronômicos da profundidade 0,0 – 0,1 m, e outra, com a reflectância e os parâmetros agronômicos da profundidade 0,1 – 0,2 m.

Este conjunto de dados foi utilizado para o treinamento e validação do modelo de predição. Ao todo foi realizado o treinamento de cinco algoritmos de predição disponíveis no software Waikato Environment for Knowledge Analysis - Weka 3.9.5: Linear Regression, Multilayer Perceptron, SMOreg, Random Forest e Random Tree. Com o objetivo de validar qual arquitetura seria mais eficiente na predição para cada parâmetro.

4.7.2. Base de dados para a predição dos parâmetros agronômicos

Como um dos propósitos do presente trabalho é a predição dos atributos físicos do solo por meio da resposta espectral da cultura, foi gerado uma base de dados com apenas as refletâncias de todos os pixels da área experimental, para que a partir destes dados de reflectância, os atributos agronômicos fossem preditos e, posterior, realizado a construção dos mapas caracterização dos parâmetros.

Nesta etapa, por meio da imagem multiespectral, foi utilizado o software QGIS 3.18 para gerar o polígono vetorizado de toda a área experimental, no formato *ShapeFile*. Em seguida, no software ENVI 5.1, por meio da ferramenta ROI tool, foi extraído os valores de reflectância de todos os pixels presentes dentro do polígono da área em estudo, com suas respectivas coordenadas. Assim, obteve-se uma tabela com os valores de reflectância de cada banda espectral de 1207 pontos.

4.8. Treino e avaliação dos modelos

Para treinamento dos modelos, no software Weka 3.9.5, foram considerados os valores de reflectância de 80 pontos (80% do conjunto amostral) definidos aleatoriamente. Para validar a precisão dos modelos foram calculados os erros médios quadráticos (RMSE) e RMSE normalizado (RMSE%), considerando o resíduo da diferença entre os parâmetros agronômicos estimados e medidos para 20 pontos (20% do conjunto amostral).

O RSME e RMSE% são respectivamente definidos pelas equações 4 e 5:

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(X_o - X_e)^2}{n}} \quad (5)$$

$$RMSE (\%) = \sqrt{\sum_{i=1}^n \frac{(X_o - X_e)^2}{n}} \times \frac{100 \times n}{\sum_{i=1}^n X_e} \quad (6)$$

em que, RMSE é a raiz do erro médio quadrático; RMSE (%) é a raiz do erro médio quadrático em porcentagem; X_o representa os valores dos parâmetros agronômicos observados *in situ*; X_e representa os valores dos parâmetros agronômicos estimados; n é o número de amostras.

Dos modelos treinados, foram selecionadas apenas as arquiteturas que apresentaram o melhor desempenho, em função dos erros médios quadráticos (RMSE) e o RMSE normalizado (RMSE%), para cada parâmetro agronômico avaliado na área experimental, em função de cada profundidade.

4.9. Geração dos mapas de caracterização dos parâmetros

Após definir o melhor modelo em função do RMSE e RMSE%, foi realizado o processo de predição dos dados a partir da base de dados de predição, ou seja, com apenas os valores de reflectância de toda a área experimental.

Para este processo, foi utilizado o software Weka 3.9.5, em que, primeiramente, repetiu-se o processo de treinamento do algoritmo selecionado para a profundidade e o parâmetro agronômico específico e, em seguida, foi adicionado ao software a base de dados com apenas os valores de reflectância, o qual realizou o processamento dos dados, gerando os dados preditos do atributo agronômico, em função da reflectância.

Após a predição dos dados, procedeu a tabulação dos valores estimados com suas respectivas coordenadas, para a posterior confecção dos mapas caracterização dos parâmetros. O método utilizado para gerar as imagens interpoladas, foi o inverso da distância (IDW), utilizando o software QGIS 3.18.

5. RESULTADOS E DISCUSSÃO

As Tabelas 2, 3 e 4 apresentam os resultados das análises de erro médio quadrático (RMSE), RMSE normalizado (RMSE%) e coeficiente de correlação (R^2), respectivamente, para os parâmetros densidade do solo (g cm^{-3}), porosidade total do solo ($\text{m}^3 \text{ m}^{-3}$) e resistência do solo à penetração (MPa), para as profundidades de 0 – 0,1 m e 0,1 – 0,2 m.

De forma que, quanto menor os valores de RMSE e RMSE%, maior a capacidade do algoritmo em estimar os valores médios do atributo na área. Já o coeficiente de correlação, está relacionado a acurácia do algoritmo na predição do atributo em relação a sua distribuição espacial, sendo que, valores negativos denotam que o algoritmo não tem boa acurácia da distribuição espacial da variável, já valores positivos de R^2 denotam maior acurácia para a distribuição espacial.

Para o parâmetro densidade do solo (Tabela 2), na profundidade de 0 – 0,1 m o algoritmo Random Forest apresentou o melhor desempenho, com os menores valores de RMSE (0,200) e RMSE% (14,479) e R^2 positivo (0,301). Já, para a profundidade de 0,1 – 0,2 m, o algoritmo Linear Regression apresentou melhor desempenho, RMSE (0,157) e RMSE% (11,196) e R^2 nulo. No entanto, o algoritmo que apresentou pior desempenho para estimar os valores de densidade do solo, para ambas as profundidades, foi o algoritmo Multilayer Perceptron, com os maiores valores de RMSE (0,482) e RMSE% (34,855) e R^2 positivo (0,102), para a profundidade de 0,0 – 0,1 m, e RMSE (0,346), RMSE% (24,727) e R^2 negativo (-0,326), para 0,1 – 0,2 m.

Tabela 2. Erro Médio Quadrático (RMSE), RMSE normalizado (RMSE%) e coeficiente de correlação (R^2) dos algoritmos na estimativa da densidade do solo para as profundidades de 0 – 0,1 m e 0,1 – 0,2 m

Densidade	Métrica	Profundidade	
		0 – 0,1 m	0,1 – 0,2 m
Linear Regression	RMSE	0,238	0,157
	RMSE%	17,221	11,196
	R^2	0,132	0,000
Multilayer Perceptron	RMSE	0,482	0,346
	RMSE%	34,855	24,727
	R^2	0,102	-0,326

Continua...

Tabela 2. Continuação

Densidade	Métrica	Profundidade	
		0 – 0,1 m	0,1 – 0,2 m
SMOreg	RMSE	0,216	0,161
	RMSE%	15,615	11,474
	R ²	0,272	-0,068
Random Forest	RMSE	0,200	0,177
	RMSE%	14,479	12,631
	R ²	0,301	-0,249
Random Tree	RMSE	0,203	0,223
	RMSE%	14,653	15,916
	R ²	0,485	-0,080

Para o parâmetro porosidade total do solo (Tabela 3), para a profundidade de 0 – 0,1 m o algoritmo Linear Regression apresentou o melhor desempenho, com os menores valores de RMSE (0,050) e RMSE% (9,244) e R² nulo. Já, para a profundidade de 0,1 – 0,2 m, o algoritmo SMOreg apresentou melhor desempenho, RMSE (0,073) e RMSE% (13,022) e R² positivo (0,130).

Tabela 3. Erro Médio Quadrático (RMSE), RMSE normalizado (RMSE%) e coeficiente de correlação (R²) dos algoritmos na estimativa da porosidade total do solo para as profundidades de 0 – 0,1 m e 0,1 – 0,2 m

Porosidade	Métrica	Profundidade	
		0 – 0,1 m	0,1 – 0,2 m
Linear Regression	RMSE	0,050	0,078
	RMSE%	9,244	13,901
	R ²	0,000	-0,326
Multilayer Perceptron	RMSE	0,093	0,115
	RMSE%	17,140	20,700
	R ²	-0,124	-0,015
SMOreg	RMSE	0,059	0,073
	RMSE%	10,941	13,022
	R ²	-0,030	0,130
Random Forest	RMSE	0,051	0,075
	RMSE%	9,336	13,453
	R ²	0,052	-0,019
Random Tree	RMSE	0,071	0,089
	RMSE%	13,081	15,892
	R ²	-0,152	-0,077

No entanto, como o algoritmo Random Forest apresentou um bom desempenho para ambas profundidades, com valores de RMSE, RMSE% e R^2 , respectivamente, de 0,051, 9,336, 0,052, para a profundidade de 0,0 – 0,1 m, e de 0,075, 13,453 e -0,019, para a profundidade de 0,1 – 0,2 m. Assim, para a sequência deste trabalho, optou-se utilizar o algoritmo Random Forest para estimar os dados de porosidade total do solo, por este ser um algoritmo mais robusto.

Já, o algoritmo que apresentou pior desempenho para estimar os valores de porosidade total do solo, para ambas as profundidades, foi o algoritmo Multilayer Perceptron, com os maiores valores de RMSE (0,093) e RMSE% (17,140) e R^2 negativo (-0,124), para a profundidade de 0,0 – 0,1 m e RMSE (0,115), RMSE% (20,700) e R^2 negativo (-0,015), para 0,1 – 0,2 m.

Para o parâmetro resistência do solo à penetração (Tabela 4), para ambas as profundidades o algoritmo Random Forest apresentou o melhor desempenho para estimar os valores médios do atributo na área. Para a profundidade de 0,0 – 0,1 m, obteve os valores de RMSE (1,086), RMSE% (24,102) e R^2 positivo (0,186), já, para a profundidade de 0,1 – 0,2 m, RMSE (2,091), RMSE% (27,410), porém o R^2 negativo (-0,235), significando que o mesmo não tem boa acurácia na estimativa dos atributos em relação a sua distribuição espacial, no entanto, para estimar a média ele apresenta bom desempenho.

Tabela 4. Erro Médio Quadrático (RMSE), RMSE normalizado (RMSE%) e coeficiente de correlação (R^2) dos algoritmos na estimativa da resistência do solo à penetração para as profundidades de 0 – 0,1 m e 0,1 – 0,2 m

Resistência do solo à penetração	Métrica	Profundidade	
		0 – 0,1 m	0,1 – 0,2 m
Linear Regression	RMSE	1,835	3,136
	RMSE%	40,737	41,109
	R^2	-0,091	-0,191
Multilayer Perceptron	RMSE	3,294	4,479
	RMSE%	73,108	58,722
	R^2	0,021	-0,211
SMOreg	RMSE	1,514	2,276
	RMSE%	33,616	29,841
	R^2	-0,100	-0,078
Random Forest	RMSE	1,086	2,091
	RMSE%	24,102	27,410
	R^2	0,186	-0,235
Random Tree	RMSE	1,205	3,928
	RMSE%	26,741	51,498
	R^2	0,303	-0,365

No entanto, o algoritmo que apresentou pior desempenho para estimar os valores de resistência do solo à penetração, para ambas as profundidades, foi o algoritmo Multilayer Perceptron, com os maiores valores de RMSE (3,294) e RMSE% (73,108) e R^2 positivo (0,021), para a profundidade de 0,0 – 0,1 m e RMSE (4,479) e RMSE% (58,722) e R^2 negativo (-0,211), para 0,1 – 0,2 m.

As Figuras 4, 5, 6, 7, 8 e 9 apresentam os mapas de caracterização dos valores preditos pelos algoritmos determinados acima, respectivamente para os seguintes parâmetros: densidade do solo (g cm^{-3}) na profundidade 0 – 0,1 m, densidade do solo (g cm^{-3}) na profundidade 0,1 – 0,2 m, porosidade total do solo ($\text{m}^3 \text{ m}^{-3}$) na profundidade 0 – 0,1 m, porosidade total do solo ($\text{m}^3 \text{ m}^{-3}$) na profundidade 0,1 – 0,2 m, resistência do solo à penetração (MPa) na profundidade 0 – 0,1 m e resistência do solo à penetração (MPa) na profundidade 0,1 – 0,2 m.

Podemos observar na Figura 4 que mais de 50% da área em estudo apresentou uma densidade de solo entre 1,317 e 1,441 g cm^{-3} , de forma que a densidade média da área, para a profundidade de 0,0 – 0,10 m foi de 1,365 g cm^{-3} . Também são observadas manchas com densidade superior a 1,441 g cm^{-3} , as quais se apresentam no perímetro da área, o que pode ser explicado por ao lado dos carregadores da área.

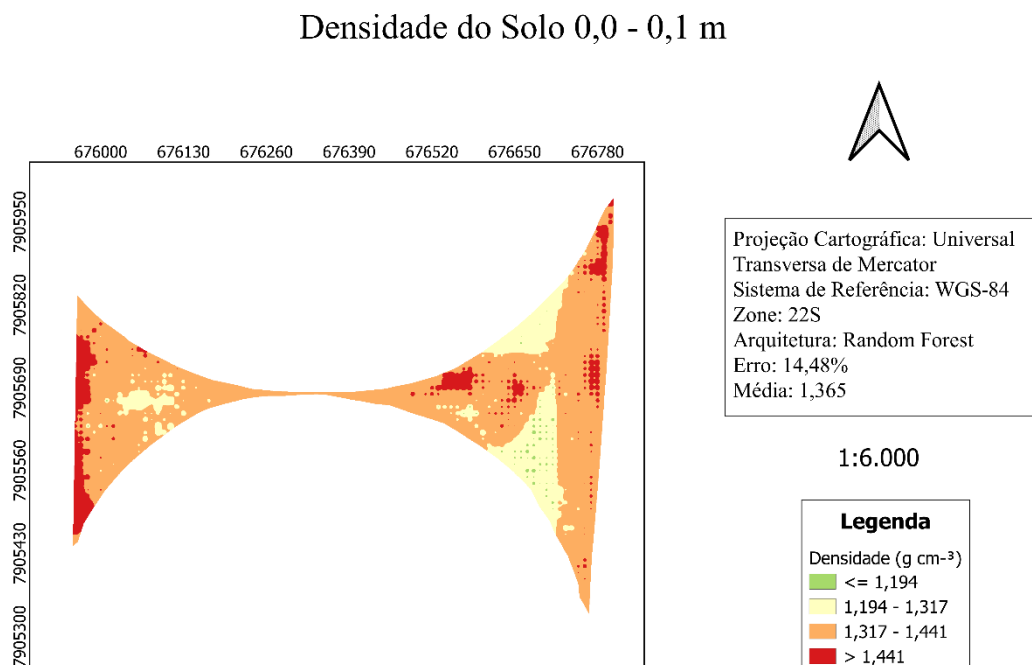


FIGURA 4. Mapa de caracterização para o parâmetro densidade do solo (g cm^{-3}) na profundidade de 0,00 – 0,10 m.

Já, na Figura 5, podemos observar que a densidade média da área, para a profundidade de 0,1 – 0,20 m foi de 1,494 g cm⁻³, sendo superior à camada de 0,0 -0,1 m, corroborando com Genro Junior et al. (2004), em que também constatou menor densidade na camada superficial em um Latossolo Vermelho distroférico típico muito argiloso. Podendo ser explicado pelo fato de que, no sistema de plantio direto, há um revolvimento mínimo da camada superficial do solo na operação de semeadura.

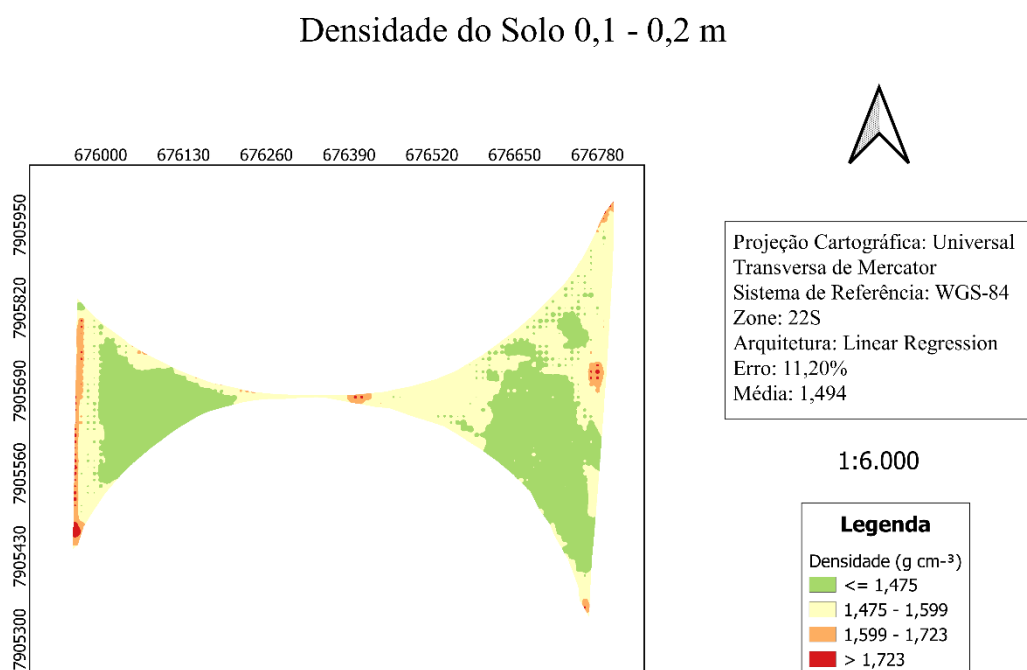


FIGURA 5. Mapa de caracterização para o parâmetro densidade do solo (g cm⁻³) na profundidade de 0,10 – 0,20 m.

Siqueira (2009) afirma que não há um consenso entre pesquisadores sobre um valor crítico de densidade do solo. Já, Reichert (2003) relata em sua revisão que os valores críticos de densidade do solo propostos são de 1,45 g cm⁻³ para solos com textura argilosa, 1,55 g cm⁻³ para textura média e 1,65 g cm⁻³ para textura arenosa.

Reinert (2008) verificou em seu estudo, em um Argissolo Vermelho distrófico típico, que o crescimento normal das plantas de cobertura utilizadas em sua pesquisa ocorreu até o limite de densidade média da camada de 0,0 - 0,5 m de 1,75 g cm⁻³. Entre a faixa de 1,75 e 1,85 g cm⁻³, ocorreu restrição com deformações na morfologia das raízes em grau médio e, acima de 1,85 g cm⁻³, essas deformações foram significativas, com grande engrossamento, desvios no crescimento vertical e concentração na camada mais superficial.

Arshad et al. (1997), com pesquisa realizada em um solo argiloso, descrevem que valores de densidade superiores a $1,35 \text{ g cm}^{-3}$ restringem o desenvolvimento radicular. Já, Queiroz Voltan et al. (2000) descrevem que valores de até $1,50 \text{ g cm}^{-3}$ não afetam o desenvolvimento das plantas, em seu estudo com o desenvolvimento radicular de plântulas de soja em Latossolo Roxo. Camargo e Alleoni (1997) consideram o valor crítico de $1,55 \text{ g cm}^{-3}$ em solos franco-argilosos a argilosos para o desenvolvimento das culturas, quando então é considerado como compactado.

Podemos concluir assim, que os valores de densidade do solo da área em estudo, na profundidade de $0,0 - 0,10 \text{ m}$ se enquadram abaixo dos valores críticos. No entanto, para a profundidade de $0,10 - 0,20 \text{ m}$, algumas zonas do mapa superam os valores críticos, sendo um indício de compactação desta camada e, conseqüentemente, impedimento do desenvolvimento radicular.

Na Figura 6, podemos observar que a porosidade média da camada de $0,0 - 0,1 \text{ m}$ foi de $0,539 \text{ m}^3 \text{ m}^{-3}$, de forma que no mapa mais de 50 % da área se encontra na faixa de $0,537 - 0,570 \text{ m}^3 \text{ m}^{-3}$, com poucas manchas de porosidade superiores a $0,570 \text{ m}^3 \text{ m}^{-3}$. Já, para a camada de $0,10 - 0,20 \text{ m}$ (Figura 7), nota-se que a maior parte da área ficou entre a faixa de $0,517 - 0,546 \text{ m}^3 \text{ m}^{-3}$, com uma média de porosidade de $0,542 \text{ m}^3 \text{ m}^{-3}$.

Porosidade Total do Solo 0,0 - 0,1 m

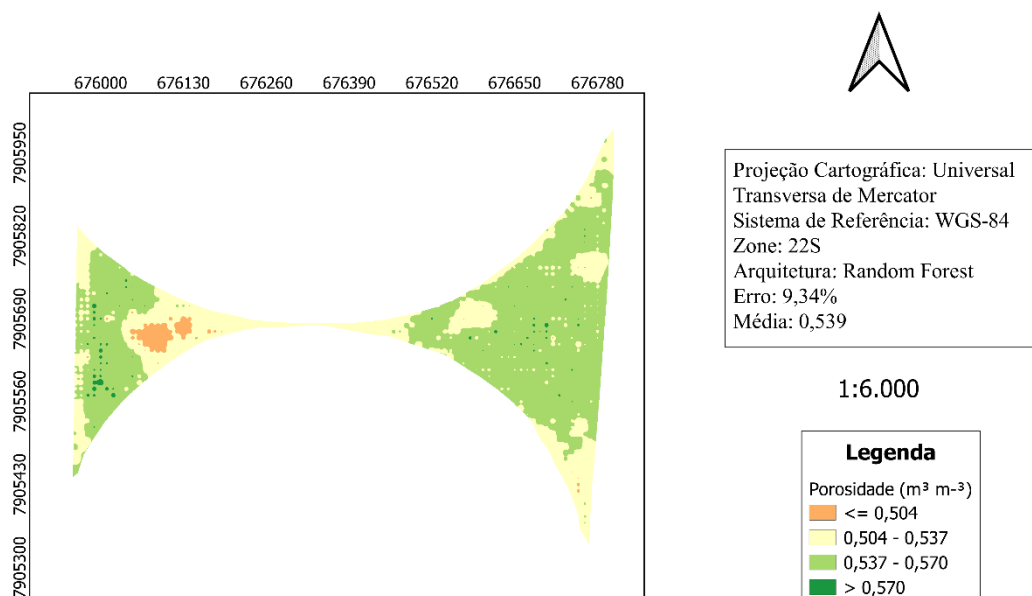


FIGURA 6. Mapa de caracterização para o parâmetro porosidade do solo ($\text{m}^3 \text{ m}^{-3}$) na profundidade de $0,00 - 0,10 \text{ m}$.

Porosidade Total do Solo 0,1 - 0,2 m

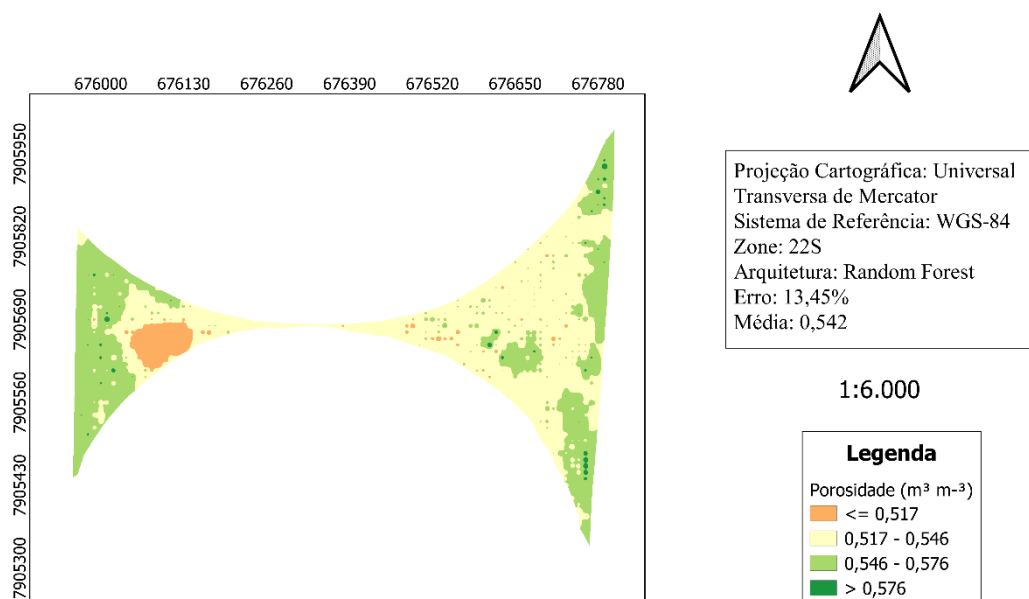


FIGURA 7. Mapa de caracterização para o parâmetro porosidade do solo ($\text{m}^3 \text{m}^{-3}$) na profundidade de 0,10 – 0,20 m.

Reichardt e Timm (2004) afirmam que, de modo geral, os solos arenosos possuem porosidade total na faixa de $0,32$ a $0,47 \text{ m}^3 \text{m}^{-3}$, enquanto os solos argilosos variam de $0,52$ a $0,61 \text{ m}^3 \text{m}^{-3}$ e os solos francos um valor intermediário. Andrade e Stone (2009) constataram que valores de $0,50 \text{ m}^3 \text{m}^{-3}$ de porosidade total nos solos são ideais para a produção agrícola. Portanto, considera-se assim, um solo ideal aquele que apresenta 50% do seu volume total como sendo espaço poroso.

Reichert (2003) discorrendo sobre os efeitos da compactação do solo, sob as propriedades físicas do solo, afirma que a redução da porosidade afeta a condutividade hidráulica, permeabilidade, infiltração de água, fluxo e concentração dos gases, nutrientes e da temperatura, limitando assim o crescimento e desenvolvimento das plantas.

Portanto, podemos concluir que a área em estudo, em ambas as profundidades apresentam índices superiores ao citado pelos autores, indicando assim, que o solo não afetou o desenvolvimento das culturas nessa camada, havendo aeração e trocas gasosas no solo necessária para o adequado crescimento e desenvolvimento radicular.

Em relação à resistência do solo à penetração, uma propriedade físico-mecânica também relacionada à compactação do solo, visto que integra os efeitos da densidade e da umidade nas condições físicas do solo necessárias para o crescimento das raízes (TORMENA, 2002). Pode-

se observar, na Figura 8, que na camada 0,0 – 0,10 m a RP média na área foi de 4,375 MPa, com a maior área do mapa se enquadrando na faixa de 4,036 – 4,814 MPa. Já, na camada de 0,10 – 0,20 m (Figura 9), valores substancialmente superiores foram encontrados, tendo uma RP média de 7,675 MPa, com a maior parte do mapa representado pela faixa de 7,262 – 8,446 MPa.

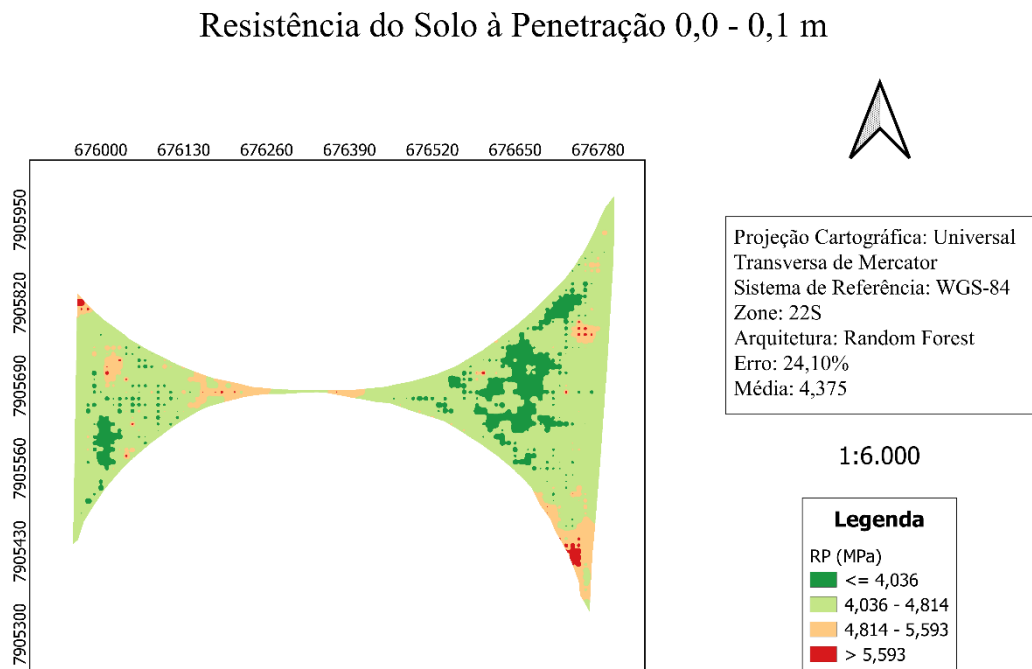


FIGURA 8. Mapa de caracterização para o parâmetro resistência do solo à penetração (MPa) na profundidade de 0,00 – 0,10 m.




FIGURA 9. Mapa de caracterização para o parâmetro resistência do solo à penetração (MPa) na profundidade de 0,10 – 0,20 m.

Genro Junior (2004) em sua revisão descreve alguns valores críticos de RP descritos na literatura, indicando valores de 1, 2, 3,5 e 5 MPa. Contudo, pesquisadores têm utilizado o valor de 2 MPa como limite crítico, conforme Taylor et al. (1966) e Reichert (2003). Portanto, os valores de RP de ambas as camadas da área de estudo foram superiores ao valor crítico determinado na literatura, sendo um forte indício de compactação do solo, ocasionando restrições no desenvolvimento radicular.

Uma possível explicação para os valores elevados de RP da área é que no dia da avaliação em campo, o solo estava com a umidade abaixo da capacidade de campo, com uma umidade gravimétrica média de $0,21 \text{ kg kg}^{-1}$, podendo ter influenciado negativamente os valores de RP.

6. CONCLUSÕES

A associação da aprendizagem de máquinas com o sensoriamento remoto, por meio da imagem multiespectral orbital do satélite Sentinel 2, como ferramenta para a predição dos atributos físicos do solo de densidade, porosidade total e resistência do solo à penetração, se mostrou promissor, podendo ser uma ferramenta para o monitoramento remoto das propriedades físicas do solo, fazendo-se necessário mais estudos, em diferentes tipos de solos e culturas, para maior validação e acurácia desta ferramenta.

As arquiteturas que obtiveram melhor desempenho na predição dos dados, do presente trabalho foram a Linear Regression, para a densidade do solo na profundidade de 0,10 – 0,20 m e para as demais propriedades, em ambas profundidades, foi a Random Forest.

Na área de estudo os índices de densidade e porosidade do solo, em geral, para ambas as profundidades se apresentaram inferiores aos níveis críticos descritos na literatura, já, para resistência do solo à penetração, os valores de ambas as profundidades se mostraram superiores aos valores críticos, indicando níveis de compactação do solo.

REFERÊNCIAS BIBLIOGRÁFICAS

- ANDRADE, R. S.; STONE, L. F. Culturas de cobertura e qualidade física de um Latossolo em plantio direto. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 13, n. 4, p. 411- 418, 2009.
- ARSHAD, M. A.; LOWERY, Birl; GROSSMAN, Bob. Physical tests for monitoring soil quality. **Methods for assessing soil quality**, v. 49, p. 123-141, 1997.
- ATZBERGER, C. Advances in remote sensing of agriculture: context description, existing operational monitoring systems and major information needs. **Remote Sensing**, v. 5, n. 2, p. 949-981, 2013. <http://dx.doi.org/10.3390/rs5020949>
- BALASTREIRE, L. A. **A experiência com pesquisas em Agricultura de Precisão na ESALQ-USP**. In: Congresso e feira para usuários de geoprocessamento da América Latina, 4., 1998, Curitiba. Anais... Curitiba: Microservice, 1998.
- BAUER, M.E, et al. Spectral properties of agricultural crops and soils measured from space, aerial, field, and laboratory sensors. In: **THE XIV CONGRESS OF INT. SOC. PHOTOGRAMMETRY**, Proceedings... Hamburg, West Germany, p. 56-73, 1980.
- CAMARGO, O. A.; ALLEONI, L. R. F. **Compactação do solo e o desenvolvimento das plantas**. Piracicaba: ESALQ, 1997. 132p.
- COMISSÃO DE FERTILIDADE DO SOLO DE MINAS GERAIS. **Recomendações para o uso de corretivos e fertilizantes para o uso de corretivos e fertilizantes em Minas Gerais: 5ª aproximação**. Viçosa, 1999. 359 p.
- CONAB - Companhia Nacional de Abastecimento. **Acompanhamento da safra brasileira de grãos**. V. 9. Safra 2021/2022, n. 10, julho 2022. Brasília, p.1-93, 2022. Disponível em: <https://www.conab.gov.br/info-agro/safra/graos/boletim-da-safra-de-graos>. Acesso em: 10 de julho de 2022.
- CURRAN, P. J. et al. The effect of a red leaf pigment on the relationship between red edge and chlorophyll concentration. **Remote Sensing of Environment**, v. 35, n. 1, p. 69-76, 1991.
- EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. Centro Nacional de Pesquisa de Solos. **Sistema brasileiro de classificação de solos**. 5.ed. Brasília, Embrapa Solos, 2018.
- ENGESAT. **Sentinel-2**. Curitiba-PR, 2015. Disponível em: <http://www.engesat.com.br/sentinel-2/>. Acesso em: 22 set. de 2021.
- FOLONI, J. S. S.; CALONEGO, J. C.; LIMA, S. L. de. Efeito da compactação do solo no desenvolvimento aéreo e radicular de cultivares de milho. **Pesquisa Agropecuária Brasileira**, v. 38, p. 947-953, 2003.
- FORMAGGIO, A.R.; SANCHES, I.D. **Sensoriamento remoto em agricultura**. São Paulo: Oficina de Textos, 2017.

FREDDI, O. S. et al. Compactação do solo no crescimento radicular e produtividade da cultura do milho. **Revista Brasileira de Ciência do Solo**, v. 31, p. 627-636, 2007.

GENRO JUNIOR, S. A.; REINERT, D. J.; REICHERT, J. M. Variabilidade temporal da resistência à penetração de um Latossolo argiloso sob semeadura direta com rotação de culturas. **Revista Brasileira de Ciência do Solo**, v. 28, n. 3, p. 477-484, 2004.

GERKE, Tiago. **Mineração de dados de imagens obtidas com aeronave remotamente pilotada para estimativa de produtividade do trigo**. 2017. 84 f. Dissertação (Mestrado em Computação para Tecnologias em Agricultura) - UNIVERSIDADE ESTADUAL DE PONTA GROSSA, Ponta Grossa, 2017.

GHOLIZADEH, Asa et al. A memory-based learning approach as compared to other data mining algorithms for the prediction of soil texture using diffuse reflectance spectra. **Remote Sensing**, v. 8, n. 4, p. 341, 2016.

HOFFER, R.M. Biological and physical considerations in applying computer-aided analysis techniques to remote sensor data. In: SWAIN, P.H; DAVIS, S.M. (Org) **Remote sensing: The quantitative approach**. McGraw-Hill, New York, p. 227-289, 1978.

LETEY, J. O. H. N. Relationship between soil physical properties and crop production. In: **Advances in soil science**. Springer, New York, NY, 1958. p. 277-294.

LIAKOS, K. et al. Machine learning in agriculture: A Review. **Sensors**, v. 18, n. 8, p. 2674. 2018. DOI: <https://doi.org/10.3390/s18082674>

LIMA, C. L. R. **Compressibilidade de solos versus intensidade de tráfego em um pomar de laranja e pisoteio animal em pastagem irrigada**. 2004. 70 f. Tese (Doutorado em Agronomia) – Escola Superior de Agricultura de “Luiz de Queiroz”, Piracicaba, 2004.

MANTOVANI, E.C.; QUEIROZ, D.M.; DIAS, G.P. Máquinas e operações utilizadas na agricultura de precisão. In: SILVA, F. M. da. (Coord.). **Mecanização e agricultura de precisão**. Poços de Caldas: UFLA/SBEA, 2000. p. 109-157.

MATERECHERA, S. A. et al. Influence of root diameter on the penetration of seminal roots into a compacted subsoil. **Plant and soil**, v. 144, n. 2, p. 297-303, 1992.

MENDES, Danilo Ferreira. **Variabilidade espacial e resposta espectral de atributos físicos e substâncias húmicas de um latossolo sob cafeicultura no Cerrado mineiro**. 2020. 56 f. Dissertação (Mestrado em Agronomia) – Universidade Federal de Uberlândia, Uberlândia, 2020. Disponível em: <http://doi.org/10.14393/ufu.di.2020.3309>

PATERNIANI, E.; CAMPOS, M.S. Melhoramento do Milho. In: BOREM, A. **Melhoramento de espécies cultivadas**. Viçosa: UFV, 2005. p. 491 – 552.

PRESTES, Christopher Djonny Pereira. **Predição de produtividade de trigo por meio de dados espectrais e altura estimada da planta obtidos por meio de aeronave remotamente pilotada**. 2020. Dissertação (Mestrado em Computação Aplicada) - Universidade Estadual de Ponta Grossa, Ponta Grossa, 2020.

QUEIROZ-VOLTAN, R. B.; NOGUEIRA, S. S. S.; MIRANDA, M.A.C. Aspectos da estrutura da raiz e do desenvolvimento de plantas de soja em solos compactados. **Pesquisa Agropecuária Brasileira**. v.35, n.5, p.929-938, 2000.

REICHARDT, K.; TIMM, L. C. **Solo, Planta e Atmosfera: Conceitos Processos e Aplicações**. São Paulo: Manole, 2004. 478 p.

REICHERT, J. M.; REINERT, D. J.; BRAIDA, J. A. Qualidade dos solos e sustentabilidade de sistemas agrícolas. **Ciência e Ambiente**, v. 27, p. 29-48, 2003.

REINERT, D. J. et al. Limites críticos de densidade do solo para o crescimento de raízes de plantas de cobertura em Argissolo Vermelho. **Revista Brasileira de Ciência do Solo**, v. 32, n. 5, p. 1805-1816, 2008.

REZENDE, C. I. P. **Imagens multiespectrais para discriminar fontes de adubo no cafeeiro**. 2022. 32 f. Dissertação (Mestrado em Agricultura e Informações Geoespaciais) - Universidade Federal de Uberlândia, Monte Carmelo, 2022. Disponível em: <http://doi.org/10.14393/ufu.di.2022.140>

ROSOLEM, C. A. et al. Sistema radicular e nutrição do milho em função da calagem e da compactação do solo. **Revista Brasileira de Ciência do Solo**, v. 18, n. 3, p. 491-497, 1994.

SAMUEL, A. L. Some studies in machine learning using the game of checkers. II—Recent progress. **IBM Journal of research and development**, v. 11, n. 6, p. 601-617, 1967.

SIQUEIRA, G. M.; VIEIRA, S. R.; DECEN, S. C. F. Variabilidade espacial da densidade e da porosidade de um Latossolo Vermelho Eutroférico sob semeadura direta por vinte anos. **Bragantia**, v. 68, p. 751-759, 2009. DOI: <https://doi.org/10.1590/S0006-87052009000300023>.

STOLF, R. Teoria e teste experimental de fórmulas de transformação dos dados de penetrômetro de impacto em resistência do solo. **Revista Brasileira de Ciência do Solo**, Campinas, v.15, p.229-235, 1991.

TEIXEIRA, P. C. et al. **Manual de Métodos de Análise de Solo**. 3. ed. rev. e ampl. Brasília: Embrapa Solos, 2017. 573 p.

TORMENA, C. A. et al. Densidade, porosidade e resistência à penetração em Latossolo cultivado sob diferentes sistemas de preparo do solo. **Scientia Agricola**, v. 59, p. 795-801, 2002.

WEISS, M.; JACOB, F.; DUVEILLERC, G. Remote sensing for agricultural applications: A meta-review. **Remote Sensing of Environment**, v. 236, p.111402. 2020. DOI: <https://doi.org/10.1016/j.rse.2019.111402>