



**UNIVERSIDADE DE BRASÍLIA – UnB
FACULDADE DE AGRONOMIA E MEDICINA VETERINÁRIA
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA**

**MODELAGEM DE DADOS DE SENSORIAMENTO REMOTO PARA O
MAPEAMENTO DIGITAL DE SOLOS E ÍNDICE RELATIVO DE
UMIDADE DOS SOLOS DO DISTRITO FEDERAL**

**REMOTE SENSING DATA MODELING FOR DIGITAL SOIL MAPPING
AND RELATIVE SOIL MOISTURE INDEX OF FEDERAL DISTRICT**

JEAN DE JESUS NOVAIS

TESE DE DOUTORADO EM AGRONOMIA

**BRASÍLIA – DF
AGOSTO/2021**



UNIVERSIDADE DE BRASÍLIA – UnB
FACULDADE DE AGRONOMIA E MEDICINA VETERINÁRIA
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

**MODELAGEM DE DADOS DE SENSORIAMENTO REMOTO PARA O
MAPEAMENTO DIGITAL DE SOLOS E ÍNDICE RELATIVO DE
UMIDADE DOS SOLOS DO DISTRITO FEDERAL**

**REMOTE SENSING DATA MODELING FOR DIGITAL SOIL MAPPING
AND RELATIVE SOIL MOISTURE INDEX OF FEDERAL DISTRICT**

JEAN DE JESUS NOVAIS

ORIENTADORA: MARILUSA PINTO COELHO LACERDA
COORIENTADOR: EDSON EYJI SANO

TESE DE DOUTORADO EM AGRONOMIA

BRASÍLIA – DF
AGOSTO/2021



**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE AGRONOMIA E MEDICINA VETERINÁRIA
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA**

**MODELAGEM DE DADOS DE SENSORIAMENTO REMOTO PARA O
MAPEAMENTO DIGITAL DE SOLOS E ÍNDICE RELATIVO DE
UMIDADE DOS SOLOS DO DISTRITO FEDERAL**

JEAN DE JESUS NOVAIS

**TESE DE DOUTORADO SUBMETIDA AO PROGRAMA DE PÓS-GRADUAÇÃO
EM AGRONOMIA, COMO PARTE DOS REQUISITOS NECESSÁRIOS À
OBTENÇÃO DO GRAU DE DOUTOR EM AGRONOMIA**

APROVADA POR:

MARILUSA PINTO COELHO LACERDA, (ORIENTADORA), Profa. Dra. Faculdade de Agronomia e Medicina Veterinária – FAV/UnB. E-mail: marilusa@unb.br

EDSON EYJI SANO, (COORDENADOR), Prof. Dr. Empresa Brasileira de Pesquisa Agropecuária – Embrapa Cerrados, E-mail: edson.sano@embrapa.br

TATI DE ALMEIDA, Profa. Dra. (EXAMINADOR INTERNO), Instituto de Geociências – IG/ UnB, E-mail: tati_almeida@unb.br

JOSÉ ALEXANDRE DE MELO DEMATTÊ, (EXAMINADOR EXTERNO 1), Prof. Dr. Escola Superior de Agricultura Luiz de Queiróz – Universidade de São Paulo – USP, E-mail: jamdemat@usp.br

PAULO ROBERTO MENESES, (EXAMINADOR EXTERNO 2), Prof. Dr. Instituto de Geociências – IG/ UnB E-mail: pmeneses@unb.br

BRASÍLIA/DF, 26 de AGOSTO de 2021

FOLHA CATALOGRÁFICA

FICHA CATALOGRÁFICA

Novais, Jean de Jesus.

Modelagem de Dados de Sensoriamento Remoto para o Mapeamento Digital de Solos e Índice Relativo de Umidade dos Solos do Distrito Federal. / Jean de Jesus Novais; orientação de Marilusa Pinto Coelho Lacerda; coorientação de Edson Eyji Sano. – Brasília, 2021.

250 p.: il.

Tese de Doutorado (D) – Universidade de Brasília / Faculdade de Agronomia e Medicina Veterinária, 2021.

1. Espectroscopia de Reflectância. 2. Radar de Abertura Sintética. 3. Aprendizado de máquina. 4. Série temporal. 5. Pedomorfogeologia. I. Novais, J.J. II. Título. III. Doutor. Lacerda, Marilusa Pinto Coelho. IV. Sano, Edson Eyji.

REFERÊNCIA

NOVAIS, J. J. Modelagem de dados de sensoriamento remoto para o mapeamento digital de solos e índice relativo de umidade dos solos do Distrito Federal. Brasília: Faculdade de Agronomia e Medicina Veterinária, Universidade de Brasília, 2021, 250 p. Tese de Doutorado.

CESSÃO DE DIREITOS

NOME DO AUTOR: Jean de Jesus Novais

TÍTULO DA TESE DE DOUTORADO: Modelagem de Dados de Sensoriamento Remoto para o Mapeamento Digital de Solos e Índice Relativo de Umidade dos Solos do Distrito Federal.

GRAU: DOUTOR.

ANO: 2021

É concedida à Universidade de Brasília permissão para reproduzir cópias desta tese de doutorado para única e exclusivamente propósitos acadêmicos e científicos. O autor reserva para si os outros direitos autorais, de publicação. Nenhuma parte desta tese de doutorado pode ser reproduzida sem a autorização por escrito do autor. Citações são estimuladas, desde que citada à fonte.

Nome: Jean de Jesus Novais

E-mail: jjnagron@gmail.com

À Neyara, minha amada.

In memoriam, à minha mãe, Edite, e ao meu pai, Dudu.

A tudo que realmente importa:

a vida, a felicidade, a família.

Dedico

AGRADECIMENTOS

À Professora Dra. Marilusa Pinto Coelho Lacerda e ao Professor Dr. Edson Eyji Sano, pelas orientações.

À Dra. Neyara M. C. Barbosa, minha amada, pela ajuda nos trabalhos de campo, redação e revisão do texto, pelo amor, carinho, cumplicidade e compreensão, por acreditar no meu potencial e sempre me incentivar a ir além.

Ao grupo de pesquisa em Pedomorfogeologia do Laboratório de Geoprocessamento, Sensoriamento Remoto e Pedomorfogeologia – Geoped da FAV e ao grupo de pesquisa Geotecnologias em Ciências do Solo – GeoCIS da Esalq/ USP, pelo suporte técnico teórico.

Àqueles que, de alguma forma, contribuíram para o desenvolvimento da pesquisa, nas atividades de campo e laboratório.

Ao Programa de Pós-Graduação em Agronomia, à Faculdade de Agronomia e Medicina Veterinária, e à Universidade de Brasília, pelo suporte técnico e administrativo ao projeto de pesquisa.

À Embrapa Cerrados, por conceder acesso e coleta de amostras de solos nas dependências da unidade experimental.

Por último, e não menos importante, aos órgãos governamentais de fomento à pesquisa: Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq; Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, Fundação de Apoio à Pesquisa do Distrito Federal – FAPDF, Decanato de Pós-graduação – DPG-UnB, pelo suporte financeiro, o qual foi imprescindível à realização deste trabalho.

*Está instaurada a dúvida.
A metódica dúvida epistemológica.
Neste mundo a terra não está no centro
nenhum saber é saber completo.
Seja bem-vinda era da razão.
Não há que se temer a revisão.
Nada que se diga ou que foi dito
merece estatuto de dogma irrestrito.
Cuidado com a verdade
que se pretende
maior que a realidade,
pois, os fatos são os fatos
e fluem diante de nós
que estupefatos
assistimos ao espetáculo.*

Galileo Galilei

RESUMO

Estudiosos ao redor do mundo reconhecem que as ações antrópicas têm intensificado as variações nos fenômenos naturais na Terra. Os efeitos do chamado aquecimento global são cada vez mais perceptíveis em nível regional. O uso e ocupação indiscriminada das terras, a alta demanda por alimentos e água podem levar a diversos problemas socioeconômicos e ambientais como degradação do solo, assoreamento de corpos hídricos, aumento na ocorrência de queimadas e a crises de abastecimento de água, como a ocorrida no Distrito Federal (DF), Brasil, entre 2015 e 2017. Portanto, estudos com foco em solo e água podem subsidiar ações de gestão racional desses recursos. Nesse contexto, esta pesquisa teve como objetivo desenvolver uma metodologia que inter-relacione classes pedológicas com a dinâmica da água na superfície dos solos por meio de geotecnologias. Os procedimentos envolveram três etapas, as quais: a) mapeamento digital de solos (MDS), b) compilação de um índice relativo de umidade do solo (IRUS) e c) o cruzamento dessas informações cartográficas. Para a primeira etapa, foram estabelecidas as relações pedomorfogeológicas em campo para individualização de área e amostragem de solo, em que 173 perfis de solo foram designados para modelagem multiespectral de solo ao longo de três superfícies geomorfológicas em uma série temporal Landsat (1984 a 2020) construída por computação em nuvem. O segundo passo foi dedicado às estimativas de umidade do solo, realizadas mediante a modelagem por aprendizado de máquina com o algoritmo *Random Forest* aplicado aos dados dos satélites Sentinel-1 (radar) e Sentinel-2 (óptico), além de atributos dos solos e do terreno. Os modelos dessa etapa foram calibrados por dados de umidade gravimétrica medidos em 40 pontos, distribuídos em quatro setores do DF e extraídos sincronicamente com a passagem do Sentinel-1 sobre a região. Esta etapa foi repetida dez vezes ao longo de um ciclo pluviométrico (2019 a 2020) para o cálculo da variabilidade da umidade do solo na série temporal. Posteriormente, a última fase dedicou-se à avaliação das classes de solo quanto aos índices de umidade para discutir a influência das características diferenciais na variação da umidade ao longo do ano. O MDS gerado atingiu 69% no índice Kappa, que é considerado uma precisão muito boa. As estimativas de umidade do solo tiveram algumas limitações atribuídas à complexidade dos dados de radar, que são afetados por vários fatores biogeofísicos, como vegetação densa e rugosidade do terreno. No entanto, a sobreposição dos mapas possibilitou a compilação do IRUS, que apresentou correspondência com o MDS durante a avaliação qualitativa e quantitativa. As diferentes capacidades de manutenção da água nos perfis dos solos foram observadas de acordo com as propriedades e atributos inerentes a cada classe. Essas informações são úteis na tomada de decisões quanto à conservação ou manejo do solo sob a perspectiva da sustentabilidade.

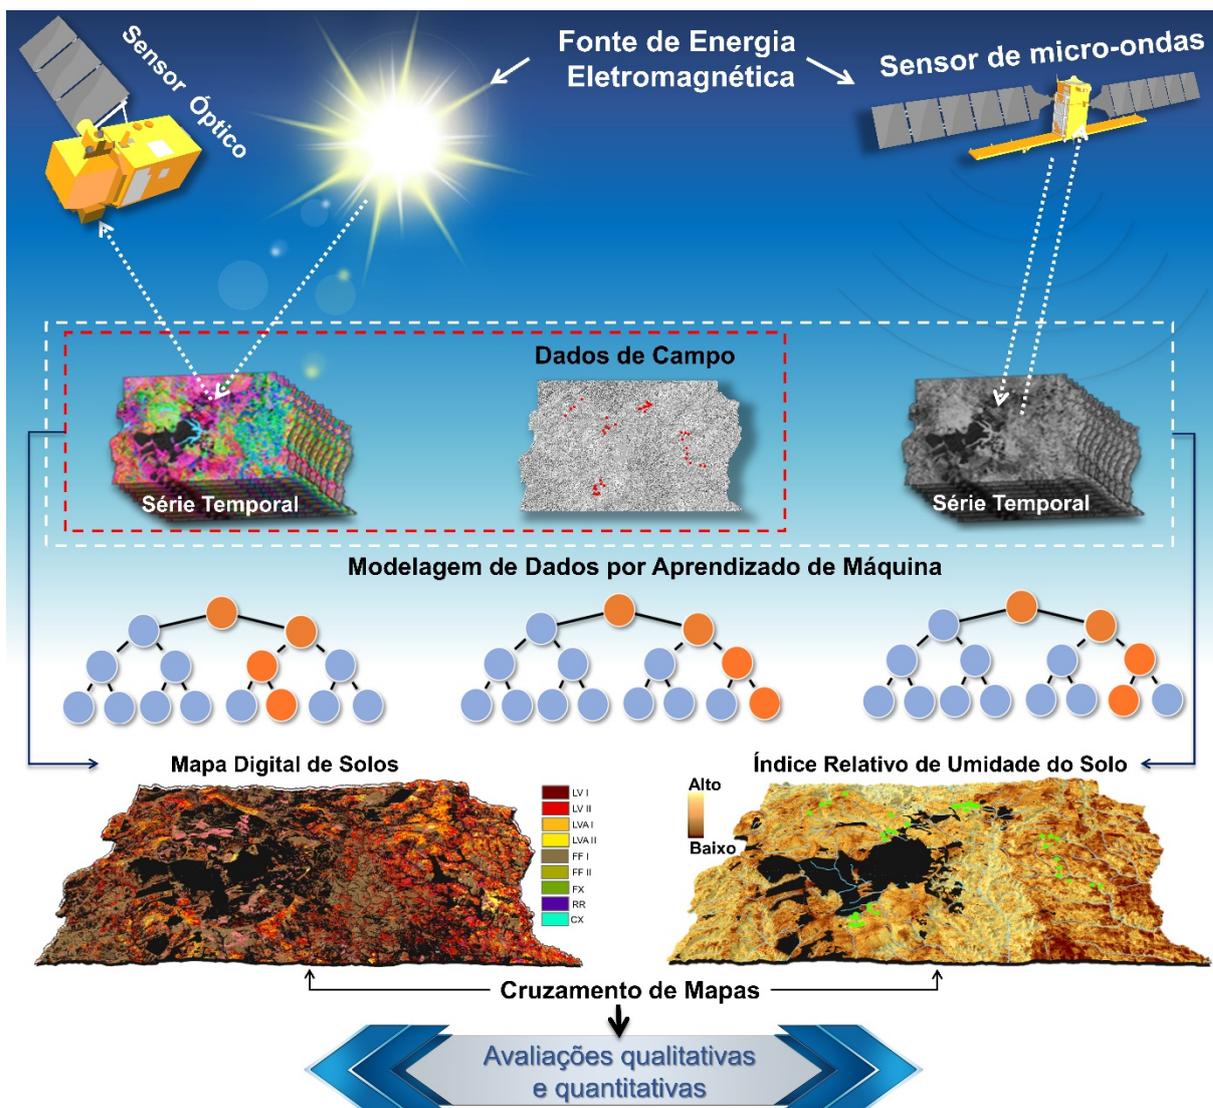
Palavras-chave: Espectroscopia de reflectância, Radar de Abertura Sintética, Aprendizado de máquina, Série temporal, Pedomorfogeologia.

ABSTRACT

Scholars around the world recognize that anthropic actions have intensified variations in natural phenomena on Earth. The effects of the so-called global warming are progressively perceptible at the regional level. Indiscriminate land-use and occupation and high demand for food and water can lead to several socio-economic and environmental problems, such as soil degradation, silting up of water bodies, increase in burning occurrences and water supplying crises, such as the one that occurred in the Federal District (DF), Brazil, between 2015 and 2017. Therefore, studies focusing on soil and water can support actions for the rational management of these resources. In this context, this research aimed to develop a methodology that interrelates pedological classes with water dynamics on the soil surface using geotechnologies. The procedures involved three steps, which: a) digital soil mapping (MDS), b) relative soil moisture index (IRUS) compilation and c) the crossing of these cartographic information. For the first stage, field pedomorphogeological relationships were established for area individualization and soil sampling, in which 173 soil profiles were designated for multispectral soil modeling along three geomorphological surfaces in a Landsat time series (from 1984 to 2020) built by cloud computing. The second step was dedicated to soil moisture estimates, using machine learning modeling with the Random Forest algorithm applied to data from the Sentinel-1 (radar), Sentinel-2 (optical) satellites, as well as soil and terrain attributes. The models utilized this step were calibrated by gravimetric moisture data measured at 40 points, distributed in four sectors of the DF and extracted synchronously with the Sentinel-1 passage over the region. This procedure was repeated ten times over a rainfall cycle (from 2019 to 2020) to calculate soil moisture variability in the time series. Subsequently, the last phase was dedicated to soil classes assessment regarding moisture indices to discuss the influence of differential characteristics on moisture variation throughout the year. The generated MDS reached 69% in the Kappa index, which is considered a very good accuracy. Soil moisture estimates presented some limitations attributed to the complexity of the radar data, which are affected by several biogeophysical factors, such as dense vegetation and terrain roughness. However, the overlapping of maps enabled the compilation of the IRUS, which demonstrated some correspondence with the MDS during the qualitative and quantitative assessment. The different capacities of water maintenance in the soil profiles were observed according to the properties and attributes inherent to each class. This information is useful in making decisions regarding soil conservation or management from a sustainability perspective.

Keywords: Reflectance Spectroscopy, Synthetic Aperture Radar, Machine Learning, Time Series, Pedomorphogeology.

RESUMO GRÁFICO



APRESENTAÇÃO DOS CAPÍTULOS

Capítulo 1 – Considerações iniciais

A seção inicial dedica-se a uma introdução geral deste trabalho de forma a traçar um breve panorama dos estudos sobre a modelagem de solos e atributos com auxílio de dados de sensoriamento remoto e sistemas de informações geográficas. Em seguida, é exposto o embasamento hipotético da ideia central por meio da caracterização dos problemas de pesquisa que orientaram o presente trabalho. Nesse sentido, o objetivo geral delimitou o escopo do estudo, no qual os objetivos específicos detalham os processos necessários para a realização do trabalho. As motivações que justificaram a relevância da pesquisa, no que se refere aos estudos da umidade dos solos tropicais, encerram este tópico.

Capítulo 2 – Fundamentação teórica: Geotecnologias aplicadas ao mapeamento de classes e umidade do solo

Neste item, expõe-se a base teórica na qual se discute tópicos acerca do objeto de estudo, o solo, e o estado da arte acerca das geotecnologias aplicadas ao mapeamento de classes e umidade do solo. O capítulo apresenta uma abordagem conceitual desse recurso natural desde os primórdios das pesquisas em solos com Dokuchaev no século XIX, até os dias atuais, que incluem as observações fora do planeta Terra. Dessa forma, são explorados temas relacionados à pedogênese e sua interação com o ambiente na Terra. Em seguida, são abordados tópicos em mapeamento pedológico com ênfase ao mapeamento digital de solos (MDS). Os modelos que correlacionam os fatores de formação dos solos de Hans Jenny (1941) e de McBratney (2003) também são discutidos. Nesta linha, foram apresentadas as iniciativas de MDS e banco de dados de solos no Brasil e no Distrito Federal (DF). Este capítulo direciona-se à importância da umidade do solo na regulação climática, no qual se apresentam as diferentes técnicas de aferição ou estimativa da umidade do solo. Dedicou-se, ainda, uma seção sobre as geotecnologias aplicadas aos estudos pedológicos, como: sistema de informações geográficas (SIG), processamento de dados geoespaciais e sensoriamento remoto óptico e na faixa das micro-ondas. Por fim, são descritas as principais características dos sistemas sensores orbitais Landsat, Sentinel-1 e Sentinel-2 utilizados.

Capítulo 3 – Caracterização do meio físico do Distrito Federal

A terceira parte deste trabalho é dedicada a uma breve apresentação e discussão acerca das características do meio físico e socioeconômico do DF. Foram abordados os aspectos quanto: à classificação climática nos ambientes tropicais, os quais o bioma Cerrado é representado por várias fitofisionomias; à dinâmica do uso e ocupação das terras, marcada por grandes áreas de preservação ambiental e pela intensa exploração das atividades

antrópicas, sobretudo na porção leste do DF; ao material parental, composto, na maior parte, por rochas metassedimentares pelíticas dos Grupos Araxá, Bambuí, Canastra e Paranoá; à classificação da paisagem do DF, em que são apresentadas as principais propostas de compartimentação geomorfológica para a individualização da área de estudo em três superfícies geomorfológicas principais: SG-I (chapadas elevadas); SG-II (região de dissecação intermediária); e SG-III (região dissecada de vales). Ao fim dessa seção, é exposta a pedodiversidade local, que é formada predominantemente por solos altamente intemperizados, que são caracterizados pela fertilidade natural baixa, altos teores de acidez, alumínio trocável e óxidos de ferro herdados da matriz rochosa. Os Latossolos em áreas planas cobrem mais de 80% da superfície do DF. Os Plintossolos Pétricos e Neossolos Regolíticos também têm destaque em áreas de relevo movimentado, que influenciam as relações pedomorfogeológicas da paisagem do DF.

Capítulo 4 – Mapeamento digital de solo por meio de modelagem multiespectral com série temporal Landsat baseada em computação em nuvem

A quarta parte deste trabalho é voltada ao MDS por meio de modelagem multiespectral de série temporal Landsat baseada em computação em nuvem no DF. Nesta seção, consta uma revisão de relevantes estudos sobre a aplicação de geotecnologias para o MDS. Em seguida, são apresentados os procedimentos metodológicos necessários para alcançar os objetivos deste trabalho. Para tanto, foi realizada uma descrição da área de interesse quanto aos aspectos fisiográficos e ambientais para a divisão em três superfícies geomorfológicas. A metodologia aplicada envolveu: a) análises pedomorfogeológicas, físico-químicas e morfológicas de 173 pontos; b) compilação de uma biblioteca espectral de solos representativa da área (por meio de espectroscopia de reflectância do visível ao infravermelho de ondas curtas em laboratório); c) análises de correlação de Pearson, de principais componentes, hierárquica de *clusters* e dos espectros de reflectância dos solos para o agrupamento e interpretação das curvas espectrais; d) elaboração, na plataforma Google Earth Engine, de uma imagem sintética de solos ou rochas expostas (SySI) da série temporal Landsat (1984-2020). Como resultados, a análise de mistura espectral de múltiplos membros referência (MESMA) modelou a SySI com os *endmembers* reamostrados nas três superfícies geomorfológicas. O MDS gerado apresentou 13 classes de solos, o qual foi avaliado pelo índice Kappa, que alcançou 69% de acurácia. A raiz do erro quadrático médio (RMSE) variou de 0% a 1,3%, o que demonstrou a eficácia da metodologia para diferenciar os solos estudados. Parte deste capítulo encontra-se publicado no periódico Remote Sensing, edição de março de 2021, vol. 13, número 6, artigo no. 1181 (<https://doi.org/10.3390/rs13061181>).

Capítulo 5 – Estimativa de umidade de solos por meio de aprendizado de máquina auxiliado por dados SAR (Sentinel-1), ópticos (Sentinel-2) e atributos pedomorfológicos

Esta seção referiu-se à geração de índices de umidade dos solos do DF por meio de modelagem pelo método de regressão linear múltipla e *Random Forest* sobre dados de radar do Sentinel-1, associados ao índice de vegetação derivados de imagens do Sentinel-2, adquiridos da plataforma Google Earth Engine (GEE), bem como atributos do terreno e dos solos. Como introdução, foram consultadas pesquisas semelhantes voltadas às estimativas da umidade do solo. A metodologia utilizada compreendeu o estabelecimento das relações pedomorfogeológicas para o direcionamento de 40 pontos de amostragem. Esses foram analisados para caracterização físico-química e classificação dos solos. Paralelamente, foram realizadas 10 amostragens indeformadas de solos para determinação da umidade gravimétrica ao longo um ciclo pluviométrico (outubro de 2019 a setembro de 2020), sincronizadas com a passagem do Sentinel-1 em quatro setores do DF. Dessa forma, considerou-se dados de retroespalhamento nas polarizações VH e VV, além do ângulo de incidência local do Sentinel-1 e NDVI do Sentinel-2 referentes a cada data de amostragem, além dos atributos do solo e do terreno. De posse das covariáveis estatisticamente significativas, procedeu-se à modelagem sobre cada conjunto de dados. Os modelos empíricos foram avaliados pelo RMSE e erro-padrão. Como resultados, avaliou-se a mudança de uso do solo mediante a polarização VH durante a série temporal para verificação das características do uso, atributos dos solos e variação da umidade do solo. A correlação de Pearson demonstrou uma maior relevância das covariáveis para estimativas da umidade do solo. Os modelos geraram índices de umidade do solo e mapas com a distribuição espacial da umidade do solo por meio do algoritmo *Random Forest* (RF).

Capítulo 6 – Relação entre classes pedológicas e índice relativo de umidade do solo

Este item contém a integração dos dados matriciais gerados nos Capítulos 4 e 5, por meio da análise da relação entre índice de umidade do solo em séries temporais e classes pedológicas. Como nota introdutória, também foi realizado um levantamento de pesquisas relacionadas para validar a pesquisa. A seção de métodos traz uma breve caracterização da área de estudo e o fluxo de trabalho. Os 10 arquivos *raster* com a variação espacial da umidade do solo foram submetidos a álgebra de bandas para compilação do índice relativo de umidade do solo (IRUS) para a série temporal, o qual foi correlacionado com o coeficiente de variação da umidade do solo. Posteriormente, o mapa de IRUS foi cruzado com o MDS para avaliação quantitativa e qualitativa das classes de solos. Os resultados demonstraram limitação técnica em recuperar a umidade do solo, sobretudo, em áreas densamente vegetadas. As classes com maior capacidade de retenção umidade como os Plintossolos Háplicos e aquelas com menor taxa de manutenção da água no perfil, como os Neossolos

Quartzarênicos, apresentaram percentuais mais baixos de IRUS, o que evidencia uma menor variabilidade durante a série temporal. Por outro lado, solos com manutenção de umidade intermediária como os Latossolos Vermelhos exibiram IRUS mais altos. Os resultados demonstraram a relação direta entre as características diferenciais de cada classe e a umidade superficial dos solos que apoiam a validade da metodologia utilizada. A inserção de outras variáveis e a aplicação de outros algoritmos podem minimizar os erros e melhorar o desempenho dos modelos para as estimativas da umidade do solo de forma a representar melhor as variações. Os resultados das análises realizadas neste Capítulo foram submetidos ao periódico *Soil Security* (<https://www.sciencedirect.com/journal/Soil-Security>).

Capítulo 7 – Considerações finais

A seção que encerra esta pesquisa traz a compilação dos resultados alcançados com as potencialidades da metodologia aplicada, bem como as dificuldades enfrentadas para alcançar os objetivos propostos. Em seguida, são apresentadas perspectivas de trabalhos futuros sobre a temática para estudos pedológicos e hidrológicos.

Referências

As referências utilizadas ao longo do texto compõem a última parte desta tese. Nesta parte, são listados, em ordem alfabética, artigos científicos, livros, capítulos de livros, sites eletrônicos e programas de computador utilizados como suporte teórico e prático para a execução e discussão.

Apêndices

Os materiais complementares estão incluídos ao final deste trabalho. Esta seção justifica-se por motivos de diagramação para auxiliar na leitura, bem como facilitar a visualização dos dados cartográficos produzidos. Segue, nesta seção, o mapa da imagem sintética de solos e o mapa digital de solos do DF, gerados no Capítulo 4. Para o Capítulo 5, constam as tabelas com os resultados das análises físicas e químicas utilizados para a caracterização dos solos e classificação pedológica; por fim, o mapa com o índice relativo de umidade dos solos produzido no Capítulo 6 e o relatório fotográfico com imagens panorâmicas dos pontos de amostragem dos Capítulos 5 e 6.

LISTA DE ILUSTRAÇÕES

| | | |
|---------------------|---|-----|
| Figura 2.1. | Interações entre a umidade do solo, evapotranspiração e temperatura. Fonte: Seneviratne et al. (2010) | 44 |
| Figura 2.2. | Esquema do balanço hídrico no solo. Fonte: Elaborado pelo autor com base em Hillel (1982) | 45 |
| Figura 2.3. | Esquema básico de um sistema de informação geográfica. Fonte: Adaptado de Reddy (2018) | 50 |
| Figura 2.4. | Esquema básico de um sistema de informação geográfica on-line. Fonte: Adaptado de Law (2014) | 51 |
| Figura 2.5. | Gráfico de dispersão entre o índice de vegetação e média mensal de precipitação pluviométrica no Distrito Federal. Fonte: Elaborado pelo autor | 56 |
| Figura 2.6. | Esquema funcional do algoritmo <i>Random Forest</i> . Fonte: Elaborado pelo autor com base em Breiman (2001) | 57 |
| Figura 2.7. | Componentes da radiação eletromagnética medida por um sensor imageador. Fonte: Adaptado de Jensen (2009) | 61 |
| Figura 2.8. | Reflectância espectral de um Luvissole com diferentes níveis de umidade. Fonte: Adaptado de Lobell e Asner (2002) | 65 |
| Figura 2.9. | Linha do tempo da série de satélites Landsat. Fonte: USGS (2020) | 74 |
| Figura 2.10. | Padrão de nomenclatura dos dados Sentinel-1. Fonte: ESA (2021) | 79 |
| Figura 2.11. | Posição das bandas espectrais de alguns dos sistemas sensores multiespectrais espaciais. MSI: <i>Multispectral Imager</i> ; OLI: <i>Operational Land Imager</i> ; TIRS: <i>Thermal Infrared Sensor</i> ; ETM+: <i>Enhanced Thematic Mapper Plus</i> . ESA (2021) .. | 80 |
| Figura 2.12. | Índice de vegetação do Distrito Federal de setembro de 2020. Fonte: Elaborado pelo autor em ambiente Google Earth Engine com dados ESA (2021) | 83 |
| Figura 3.1. | Mapa de localização do Distrito Federal. Elaborado pelo autor com dados de IBGE (2017) e CODEPLAN (2020a) | 84 |
| Figura 3.2. | Média mensal de precipitação pluviométrica (mm) do Distrito Federal no período de 1974 a 2013. Fonte: Adaptado de Silva et al. (2017) | 86 |
| Figura 3.3. | Mapa da cobertura vegetal e uso do solo do Distrito Federal. Fonte: Adaptado de SEMA (2021) | 87 |
| Figura 3.4. | Pluviosidade média mensal e o correspondente índice de vegetação por diferença normalizada do Distrito Federal. Fonte: INMET (2020); ESA (2021) | 89 |
| Figura 3.5. | Mapa de unidades hidrográficas do Distrito Federal. Fonte: Adaptado de CODEPLAN (2020a) | 90 |
| Figura 3.6. | Mapas de disponibilidade hídrica (a) e Capacidade de retenção de água dos solos (b) do Distrito Federal. Fonte: Adaptado de Campos (2007) | 92 |
| Figura 3.7. | Mapa geológico do Distrito Federal. Fonte: Adaptado de Freitas-Silva e Campos (1998) | 93 |
| Figura 3.8. | Mapa hipsométrico do Distrito Federal. Fonte: Elaborado pelo autor com dados de CODEPLAN (1991) | 95 |
| Figura 3.9. | Classes de declividade do Distrito Federal. Fonte: Elaborado pelo autor com dados de CODEPLAN (1991) e classificado segundo Santos et al. (2018) | 96 |
| Figura 3.10. | Mapa de superfícies geomorfológicas do Distrito Federal. SG-I = Região de chapadas elevadas; SG-II = Região de dissecação intermediária e SG-III = Região dissecada de vales. Fonte: Adaptado de Novaes Pinto (1987) | 98 |
| Figura 3.11. | Mapa de compartimentação geomorfológica do Distrito Federal. Fonte: Adaptado de Campos (2011) | 99 |
| Figura 3.12. | Mapa pedológico do Distrito Federal. Fonte: Adaptado de Reatto et al. (2004), classificado de acordo com Santos et al. (2018) | 100 |

| | | |
|---------------------|--|-----|
| Figura 4.1. | Fluxograma da metodologia de produção do mapa digital de solos da área de estudo. MIRS: interpretação morfológica de espectros de refletância; TM: sensor <i>Tematic Mapper</i> ; MDS: mapa digital do solo; RMSE: raiz quadrada média do erro | 105 |
| Figura 4.2. | Distribuição dos pontos de amostragem de solos sobre as superfícies geomorfológicas. MDS = mapeamento digital de solos; US = Umidade superficial do solo. Fonte: Elaborado pelo autor com base em Novaes Pinto (1987) | 106 |
| Figura 4.3. | Gráfico de caixa com a distribuição empírica dos dados de textura dos solos nas três superfícies geomorfológicas. | 117 |
| Figura 4.4. | Gráfico de caixa com a distribuição empírica dos dados dos atributos químicos dos solos nas três superfícies | 118 |
| Figura 4.5. | Correlação de Pearson, análise de componentes principais e gráfico de autovalores dos atributos dos solos nas SG-I (a), SG-II (b) e SG-III (c) | 120 |
| Figura 4.6. | Comportamento espectral (a) Latossolos Vermelhos (LV-I e LV-II), (b) Latossolos Vermelhos-Amarelos (LVA-I e LVA-II), (c) Plintossolos Pétricos (FF-I e FF-II) e (d) Neossolo Regolítico (RR) e Neossolo Quartzarênico. Ht: Hematita, Gt: Goethita; Ct: Caulinita; Gb: Gibbsita; MO: Matéria orgânica | 122 |
| Figura 4.7. | Comportamento espectral do (a) Argissolo Vermelho (PV) e Argissolo Vermelho-Amarelo (PVA), (b) Nitossolo Vermelho (PV) e Cambissolo Háplico (CX) e (c) Gleissolo Háplico (GX) e Organossolo Háplico (OX). Ht: Hematita, Gt: Goethita; Ct: Caulinita; Gb: Gibbsita; MO: Matéria orgânica | 124 |
| Figura 4.8. | Gráfico integrado com a porcentagem de área útil e suprimida e o número de amostragem por superfície estudada | 127 |
| Figura 4.9. | Imagem sintética de solos e rochas expostas nas superfícies geomorfológicas SG-I (a), SG-II (b) e SG-III (c) | 129 |
| Figura 4.10. | Imagem da raiz quadrada média do erro da modelagem (a) e Imagem-fração dos espectros de referência modelados (b). As regiões em cores branca e cinza claro representam os locais suprimidos | 131 |
| Figura 4.11. | Distribuição dos modelos espectrais da SG-III. Distribuição dos modelos espectrais da SG-II. Não computado, LV-I = Latossolo Vermelho argiloso; LV-II = Latossolo Vermelho muito argiloso; LVA-I = Latossolo Vermelho-Amarelo argiloso; LVA-II = Latossolo Vermelho-Amarelo muito argiloso; FF-I = Plintossolo Pétrico argiloso; FF-II = Plintossolo Pétrico muito argiloso; FX = Plintossolo Háplico muito argiloso; RR = Neossolo Regolítico argiloso; RQ = Neossolo Quartzarênico Órtico; CX = Cambissolo Háplico argiloso; PV = Argissolo Vermelho muito argiloso; PVA = Argissolo Vermelho-Amarelo muito argiloso; NV = Nitossolo Vermelho muito argiloso | 134 |
| Figura 4.12. | Percentuais de contribuição das classes no MDS do Distrito Federal. LV-I = LATOSSOLO VERMELHO Distrófico típico argiloso; LV-II = LATOSSOLO VERMELHO Distrófico típico muito argiloso; LVA-I = LATOSSOLO VERMELHO-AMARELO Distrófico típico argiloso; LVA-II = LATOSSOLO VERMELHO-AMARELO Distrófico típico muito argiloso; FF-I = PLINTOSSOLO PÉTRICO Concrecionário típico argiloso; FF-II = PLINTOSSOLO PÉTRICO Concrecionário típico muito argiloso; FX = PLINTOSSOLO HÁPLICO Distrófico típico muito argiloso; CX = CAMBISSOLO HÁPLICO tb Distrófico típico argiloso; RR = NEOSSOLO REGULÍTICO Distrófico típico argiloso; RQ = NEOSSOLO QUARTZARÊNICO Órtico típico; PV = ARGISSOLO VERMELHO Eutroférico típico muito argiloso; PVA = ARGISSOLO VERMELHO-AMARELO Eutroférico típico muito argiloso; NV = NITOSSOLO VERMELHO Eutroférico chernossólico muito argiloso | 137 |
| Figura 4.13. | Mapa digital de solos expostos do Distrito Federal. LV-I = LATOSSOLO VERMELHO Distrófico típico argiloso; LV-II = LATOSSOLO VERMELHO Distrófico típico muito argiloso; LVA-I = LATOSSOLO VERMELHO-AMARELO Distrófico típico argiloso; LVA-II = LATOSSOLO VERMELHO-AMARELO Distrófico típico muito argiloso; FF-I = PLINTOSSOLO PÉTRICO Concrecionário típico argiloso; FF-II = PLINTOSSOLO PÉTRICO Concrecionário típico muito argiloso; FX = PLINTOSSOLO HÁPLICO Distrófico típico muito argiloso; CX = | 138 |

| | | |
|---------------------|--|-----|
| | CAMBISSOLO HÁPLICO tb Distrófico típico argiloso; RR = NEOSSOLO REGOLÍTICO Distrófico típico argiloso | |
| Figura 5.1. | Fluxograma da metodologia de trabalho. MDT: Modelo Digital do Terreno; RMSE: Raiz quadrada do erro médio; EP: Erro-padrão; IUS: Índice de Umidade do Solo. | 146 |
| Figura 5.2. | Distribuição da normal pluviométrica nos setores A, B, C e D no período 2019-2020. Fonte: Elaborado pelo autor com dados de INMET (2020) | 148 |
| Figura 5.3. | Material utilizado para amostragem indeformada de solos: a) kit de amostragem; b) anel volumétrico e c) espaçamento de amostragem | 149 |
| Figura 5.4. | Amostras indeformadas de solo para estimativa de umidade: (a) solo úmido; (b) amostras secas na estufa e (c) anéis limpos prontos para reutilização | 151 |
| Figura 5.5. | Composição colorida RGB das imagens Sentinel-1 do DF obtidas em outubro de 2019, fevereiro de 2020 e junho de 2020 na polarização VH | 163 |
| Figura 5.6. | Triângulo textural dos horizontes superficiais (a) e subsuperficiais (b) dos 40 pontos amostrados para as estimativas de umidade dos solos | 165 |
| Figura 5.7. | Gráfico de caixa dos valores dos atributos dos solos: (a) argila, (b) silte, (c) areia, (d) pH em H ₂ O, (e) Fósforo assimilável, (f) Hidrogênio + Alumínio, (g) Alumínio trocável, (h) soma das bases trocáveis, (i) Capacidade de Troca de Cátions potencial, (j) saturação de alumínio, (k) saturação por bases e (l) matéria orgânica | 167 |
| Figura 5.8. | Correlograma (a), importância de Gini (b), análise de componentes principais (a) dispersão dos pontos e (d) importância dos autovalores | 172 |
| Figura 5.9. | Gráfico de dispersão com as médias de umidade de solos coletadas em campo: (a) retroespalhamento das polarizações VH e VV; e (b) ângulo de incidência local do S1 ao longo da série temporal analisada | 173 |
| Figura 5.10. | Histogramas dos valores de NDVI (a) e resumo dos dados de NDVI (b) | 174 |
| Figura 5.11. | Plotagem correlativa do SNAP sobre dados médios de umidade do solo medida em campo e (a) retroespalhamento e (b) NDVI da primeira série de dados | 175 |
| Figura 5.12. | Covariáveis morfométricas: a) Índice de Posição Topográfica; b) Índice de Rugosidade do Terreno; c) Índice Topográfico de Umidade e d) Correlação | 176 |
| Figura 5.13. | Variação da umidade dos solos predita pelos modelos de regressão linear múltipla (RLM) (em vermelho) e Random Forest (RF) (em verde); acumulados de precipitação diária e média de umidade do solo medida (linha pontilhada) | 180 |
| Figura 5.14. | Histogramas da série temporal de umidade do solo modelada por <i>Random Forest</i> . | 181 |
| Figura 5.15. | Validação da modelagem da umidade do solo: (a) referência em campo; (b) método de regressão linear múltipla e (c) método <i>Random Forest</i> | 184 |
| Figura 5.16. | Mapas de umidade do solo da série temporal estudada. I – outubro (a), II – outubro (b), III – novembro (c), IV – dezembro (d), V – janeiro (e), VI – fevereiro (f), VII – março (g), VIII – abril (h), IX – junho (i) e X – setembro (j) | 189 |
| Figura 5.17. | Imagem de raiz quadrada do erro médio da umidade da série temporal analisada.. | 192 |
| Figura 6.1. | Fluxograma de trabalho para avaliação da umidade do solo em diferentes classes pedológicas. IRUS = Índice de umidade do solo, MDS = Mapa digital de solos | 196 |
| Figura 6.2. | Umidade do solo predita e precipitação pluviométrica ao longo da série temporal. DP- e DP+ correspondem a desvio-padrão inferior e superior, respectivamente | 203 |
| Figura 6.3. | Mapa de coeficiente de variação da umidade do solo com destaque para áreas de baixa (a) e alta variabilidade (b) | 204 |
| Figura 6.4. | Mapa de índice relativo de umidade do solo com destaque para áreas de baixa (a) e alta variabilidade (b) | 206 |
| Figura 6.5. | Gráficos de distribuição do coeficiente de variação de Pearson (CV) e do índice relativo de umidade de solos (IRUS). Variação conjunta (a) e histogramas (b) | 207 |
| Figura 6.6. | Gráficos de dispersão entre o índice relativo de umidade de solos (IRUS) e coeficiente de variação (a) medidos em campo e (b) das imagens preditas | 208 |

LISTA DE TABELAS

| | | |
|--------------------|--|-----|
| Tabela 2.1. | Caracterização de levantamentos de solos: tipos, objetivos, área examinada, número de perfis por hectare e escala do mapa-base | 34 |
| Tabela 2.2. | Comprimentos de onda e frequências do espectro eletromagnético..... | 59 |
| Tabela 2.3. | Informações gerais sobre a série de satélites Landsat..... | 75 |
| Tabela 2.4. | Características da constelação de satélites da missão Sentinel..... | 77 |
| Tabela 2.5. | Especificações dos produtos obtidos pelo satélite Sentinel-1..... | 78 |
| Tabela 2.6. | Características das bandas do sensor Sentinel-2 Multispectral Imager | 81 |
| Tabela 3.1. | Áreas referentes à cobertura vegetal e uso do solo do Distrito Federal..... | 88 |
| Tabela 3.2. | Áreas das unidades hidrográficas do Distrito Federal..... | 91 |
| Tabela 3.3. | Contabilização das áreas das classes hipsométricas do Distrito Federal | 94 |
| Tabela 3.4. | Contabilização das áreas das classes de declividade do Distrito Federal | 96 |
| Tabela 4.1. | Classificação de solos, distribuição dos perfis por superfície geomorfológica e relação de endmembers de cada classe..... | 115 |
| Tabela 4.2. | Estatística descritiva dos atributos dos solos por superfície geomorfológica..... | 116 |
| Tabela 4.3. | Contabilização das áreas de solos expostos por superfície geomorfológica e total. | 125 |
| Tabela 4.4. | Estudos que utilizaram imagem sintética de solos expostos..... | 126 |
| Tabela 4.5. | Contabilização das áreas mapeadas e não mapeadas por superfície geomorfológica e total..... | 135 |
| Tabela 4.6. | Matriz do mapeamento digital de solos expostos do DF..... | 141 |
| Tabela 5.1. | Resultados dos modelos de Regressão Linear Múltipla e <i>Random Forest</i> | 178 |
| Tabela 5.2. | Coefficientes da Regressão Linear Múltipla..... | 179 |
| Tabela 5.3. | Índices de umidade do solo da série temporal analisada pelos modelos Regressão Linear Múltipla e <i>Random Forest</i> | 186 |
| Tabela 5.4. | Distribuição dos RMSE médios de umidade do solo predita ao longo da série temporal..... | 191 |
| Tabela 6.1. | Descrição da série temporal de umidade do solo medida em campo..... | 199 |
| Tabela 6.2. | Contabilização das classes de índice relativo de umidade do solo da série temporal..... | 205 |
| Tabela 6.3. | Testes de normalidade dos dados de índice relativo de umidade de solos (IRUS) e coeficiente de variação de Pearson (CV)..... | 207 |
| Tabela 6.4. | Percentuais de sobreposição entre as classes solos e as classes de variação da umidade do solo ao longo da série temporal analisada..... | 210 |

LISTA DE APÊNDICES

| | | |
|---------------------|--|-----|
| Apêndice A. | Imagem Sintética de Solo (SySI) do Distrito Federal. Fonte: Elaborado pelo autor com base em Demattê et al. (2018) | 230 |
| Apêndice B. | Mapa digital de solos expostos do Distrito Federal. LATOSSOLO VERMELHO Distrófico típico (LV-I = argiloso e LV-II = muito argiloso), LATOSSOLO VERMELHO-AMARELO Distrófico típico (LVA-I = argiloso e LVA-II = muito argiloso), PLINTOSSOLO PÉTRICO Concrecionário típico (FF = argiloso a muito argiloso), PLINTOSSOLO HÁPLICO Distrófico típico argiloso (FX), CAMBISSOLO HÁPLICO tb Distrófico típico (CX) NEOSSOLO REGOLÍTICO Distrófico típico (RR) | 231 |
| Apêndice C1. | Algoritmo para pré-processamento de imagens Sentinel-1 | 232 |
| Apêndice C2. | Código para obtenção das imagens NDVI do Sentinel-2 | 232 |
| Apêndice C3. | Tabela de atributos dos solos do setor A | 233 |
| Apêndice C4. | Tabela de atributos dos solos do setor B | 234 |
| Apêndice C5. | Tabela de atributos dos solos do setor C | 235 |
| Apêndice C6. | Tabela de atributos dos solos do setor D | 236 |
| Apêndice C7. | Quadro resumo das características dos pontos e setores | 237 |
| Apêndice C8. | Classes e textura dos solos estudados | 238 |
| Apêndice C9. | Gráfico bidirecional dos valores de umidade do solo medida e predita pelos métodos de regressão linear múltipla (RLM) (a) e <i>Random Forest</i> (RF) (b) | 239 |
| Apêndice D1. | Relatório fotográfico dos pontos de amostragem do setor A | 240 |
| Apêndice D2. | Relatório fotográfico dos pontos de amostragem do setor B | 242 |
| Apêndice D3. | Relatório fotográfico dos pontos de amostragem do setor C | 244 |
| Apêndice D4. | Relatório fotográfico dos pontos de amostragem do setor D | 246 |
| Apêndice E1. | Coefficiente de variação da umidade do solo do Distrito Federal | 248 |
| Apêndice E2. | Índice relativo de umidade do solo do Distrito Federal | 249 |

LISTA DE SIGLAS E ACRÔNIMOS

| | |
|--|---|
| AI – Ângulo de Incidência Local | NIR – <i>Near Infra-Red</i> |
| APP – Áreas de Preservação Permanentes | NV – NITOSSOLO VERMELHO |
| ASF – <i>Alaska Satellite Facility</i> | o – Caráter órtico |
| BD – Banco de Dados | OLI – <i>Operationa Land Imager</i> |
| c – Caráter concrecionário | OX – ORGANOSSOLO HÁPLICO |
| Ct – Caulinita | PAD-DF – Programa de Assentamento Dirigido do Distrito Federal |
| CX – CAMBISSOLO HÁPLICO | PCA – <i>Principal Components Analysis</i> |
| CV – Coeficiente de Variação de Pearson | PV – ARGISSOLO VERMELHO |
| d – Caráter distrófico | PVA – ARGISSOLO VERMELHO-AMARELO |
| DF – Distrito Federal | RA – Região Administrativa |
| e – Caráter eutrófico | RADAR – <i>Radio Detection And Ranging</i> |
| Embrapa – Empresa Brasileira de Pesquisa Agropecuária | REM – Radiação Eletromagnética |
| ENVI – <i>Environment for Visualizing Images</i> | RF – <i>Random Forest</i> |
| EP – Erro Padrão | RGB – <i>Red Green and Blue aditive color model</i> |
| ESA – <i>European Spatial Agency</i> | RLM – Regressão Linear Múltipla |
| Esalq-USP – Escola Superior de Agricultura Luiz de Queiróz da Universidade de São Paulo | RMSE – <i>Root Mean Square Error</i> |
| ETM – <i>Enhanced Thematic Mapper</i> | RQ – NEOSSOLO QUARTZARÊNICO |
| FAL – Fazenda Água Limpa (FAV-UnB) | RR – NESSOLO REGOLÍTICO |
| FAO – <i>Food and Agriculture Organization</i> | SAR – <i>Synthetic Aperture Radar</i> |
| FF – PLINTOSSOLO PÉTRICO | SB – Soma das bases trocáveis |
| FX – PLINTOSSOLO HÁPLICO | SG – Superfície Geomorfológica |
| Gb – Gibbsita | SG-I – Região de Chapadas Elevadas |
| Geoped – Laboratório de Geoprocessamento, Sensoriamento Remoto e Pedomorfogeologia | SG-II – Região de Dissecção Intermediária |
| GEE – <i>Google Earth Engine</i> | SG-III – Região Dissecada de Vales |
| GRD – <i>Ground Range Detected</i> | SiBCS – Sistema Brasileiro de Classificação de Solos |
| Gt – Goethita | SIG – Sistema de Informação Geográfica |
| GX – GLEISSOLO HÁPLICO | SNAP – <i>Sentinel Application Platform</i> |
| IG – Instituto de Geociências | SPD – Sistema de Plantio Direto |
| Ht – Hematita | SR – Sensoriamento Remoto |
| IRUS – Índice Relativo de Umidade do Solo | SWIR – <i>Short Wave Infra-Red</i> |
| IUS – Índice de Umidade do Solo | SySI – <i>Synthetic Soil Image</i> |
| IW – <i>Interferometric Wide Swath</i> | T – Capacidade de Troca de Cátions |
| LandSat – <i>Land Remote Sensing Satellite</i> | TM – <i>Thematic Mapper</i> |
| LV – LATOSSOLO VERMELHO | TPI – <i>Topographic Position Index</i> |
| LVA – LATOSSOLO VERMELHO-AMARELO | TRI – <i>Terrain Roughness Index</i> |
| m – Saturação por Alumínio | TWI – <i>Topographic Wetness Index</i> |
| MDE – Modelo Digital de Elevação | US – Umidade do Solo |
| MDS – Mapeamento Digital de Solos | USGS – <i>United States Geological Service</i> |
| MDT – Modelo Digital do Terreno | V – Saturação por Bases Trocáveis |
| MESMA – <i>Multiple Endmember Spectral Mixture Analysis</i> | VH – Polarização Emissão Vertical e Recepção Horizontal |
| MO – Matéria Orgânica | VV – Polarização Emissão Vertical e Recepção Vertical |
| MSS – <i>Multispectral Scanner</i> | WRB – <i>World Reference Base for Soil Resource</i> |
| NDVI – <i>Normalized Difference Vegetation Index</i> | |

SUMÁRIO

| | |
|--|----|
| CAPÍTULO 1 – CONSIDERAÇÕES INICIAIS | 22 |
| 1.1. INTRODUÇÃO GERAL | 22 |
| 1.2. HIPÓTESES | 25 |
| 1.3. OBJETIVOS | 27 |
| 1.3.1. Objetivo geral | 27 |
| 1.3.2. Objetivos específicos..... | 27 |
| 1.4. JUSTIFICATIVA | 28 |
| CAPÍTULO 2 – FUNDAMENTAÇÃO TEÓRICA: GEOTECNOLOGIAS APLICADAS AO MAPEAMENTO DE CLASSES E ATRIBUTOS DOS SOLOS | 30 |
| 2.1. EVOLUÇÃO CONCEITUAL DO SOLO | 30 |
| 2.2. A PEDOGÊNESE E AS RELAÇÕES SOLO-PAISAGEM | 33 |
| 2.3. LEVANTAMENTO E MAPEAMENTO PEDOLÓGICO | 33 |
| 2.3.1. Mapeamento digital de solos | 37 |
| 2.3.2. Iniciativas de MDS e banco de dados no Brasil | 39 |
| 2.4. ASPECTOS PEDOLÓGICOS NA REGULAÇÃO DO CLIMA | 41 |
| 2.4.1. Balanço hídrico no solo | 43 |
| 2.5. IMPORTÂNCIA DA UMIDADE DO SOLO PARA A AGRICULTURA | 45 |
| 2.5.1. Principais técnicas de aferição da umidade do solo..... | 46 |
| 2.6. GEOTECNOLOGIAS APLICADAS AOS ESTUDOS PEDOLÓGICOS | 48 |
| 2.6.1. Sistemas de informação geográfica..... | 49 |
| 2.6.2. Processamento de dados geoespaciais | 50 |
| 2.6.3. Modelagem de dados de sensoriamento remoto | 52 |
| 2.6.3.1. Modelagem por aprendizado de máquina | 53 |
| 2.6.3.2. Análise de regressão..... | 54 |
| 2.6.3.3. Modelagem por <i>Random Forest</i> | 56 |
| 2.6.4. Sensoriamento remoto aplicado aos solos | 58 |
| 2.6.4.1. Espectroscopia de reflectância dos solos..... | 60 |
| 2.6.4.2. Comportamento da reflectância espectral dos solos | 61 |
| 2.6.4.3. Umidade do solo via dados de sensoriamento remoto | 65 |
| 2.6.4.3.1. Umidade do solo na faixa óptica | 66 |
| 2.6.4.3.2. Umidade do solo na região de micro-ondas | 67 |
| 2.6.4.3.3. Atributos do terreno em estimativas de umidade do solo | 70 |
| 2.6.4.3.4. Principais missões SAR e estudos sobre a umidade do solo | 72 |
| 2.6.5. O sistema Landsat..... | 74 |
| 2.6.6. Missões Sentinel | 76 |
| 2.6.6.1. Sentinel-1..... | 78 |
| 2.6.6.2. Sentinel-2..... | 80 |
| 2.6.2.2.1. Sentinel-2 para estudos da vegetação | 81 |
| CAPÍTULO 3 – CARACTERIZAÇÃO DO MEIO FÍSICO DO DISTRITO FEDERAL | 84 |
| 3.1. ÁREA DE ESTUDO | 84 |
| 3.2. CLIMA | 85 |
| 3.3. VEGETAÇÃO, USO E OCUPAÇÃO DAS TERRAS | 86 |
| 3.4. RECURSOS HÍDRICOS | 89 |
| 3.4.1. Situação dos recursos hídricos no Distrito Federal | 91 |
| 3.5. GEOLOGIA | 93 |
| 3.6. CARACTERIZAÇÃO DA PAISAGEM | 94 |

| | |
|---|------------|
| 3.6.1. Hipsometria | 94 |
| 3.6.2. Declividade..... | 95 |
| 3.6.3. Compartimentação geomorfológica | 97 |
| 3.7. SOLOS | 100 |
| CAPÍTULO 4 – MAPEAMENTO DIGITAL DE SOLOS POR MEIO DE MODELAGEM MULTIESPECTRAL SOBRE SÉRIE TEMPORAL LANDSAT E PROCESSAMENTO EM NUVEM | 102 |
| 4.1. INTRODUÇÃO..... | 102 |
| 4.2. MATERIAL E MÉTODOS..... | 104 |
| 4.2.1. Pesquisa bibliográfica e levantamento de dados secundários | 104 |
| 4.2.2. Fluxo de trabalho..... | 105 |
| 4.2.3. Descrição da área de estudo..... | 105 |
| 4.2.4. Individualização da área de estudo | 106 |
| 4.2.5. Amostragem e caracterização dos solos | 107 |
| 4.2.6. Análises estatísticas dos dados pedológicos..... | 108 |
| 4.2.7. Espectroscopia e compilação da biblioteca espectral de solos..... | 109 |
| 4.2.8. Imagem multitemporal de solos expostos..... | 111 |
| 4.2.9. Modelagem espectral dos solos | 111 |
| 4.2.10. Validação do mapa digital de solos | 113 |
| 4.3. RESULTADOS E DISCUSSÃO | 113 |
| 4.3.1. Caracterização e classificação dos perfis de solos | 113 |
| 4.3.2. Classificação dos solos estudados | 114 |
| 4.3.3. Análise de dados pedológicos | 115 |
| 4.3.3.1. Estatística descritiva..... | 115 |
| 4.3.3.2. Correlação e análise de principais componentes | 119 |
| 4.3.3.3. Comportamento espectral dos <i>endmembers</i> | 120 |
| 4.3.4. Análise da imagem sintética de solos e rochas expostas | 124 |
| 4.3.5. Desempenho da modelagem espectral | 130 |
| 4.3.5.1. Avaliação dos erros de predição | 130 |
| 4.3.6. Espacialização dos modelos de mistura espectral..... | 132 |
| 4.3.6.1. Modelagem de solo por superfície geomorfológica | 132 |
| 4.3.6.2. Contabilização das áreas mapeadas e não mapeadas | 134 |
| 4.3.6.3. Avaliação do mapa digital de solos expostos do DF..... | 136 |
| 4.3.6.4. Validação dos modelos de mistura espectral | 140 |
| 4.4. CONCLUSÕES..... | 141 |
| CAPÍTULO 5 – ESTIMATIVA DE UMIDADE DE SOLOS POR MEIO DE APRENDIZADO DE MÁQUINA AUXILIADO POR DADOS SAR (SENTINEL-1), ÓPTICOS (SENTINEL-2) E ATRIBUTOS PEDOMORFOLÓGICOS | 143 |
| 5.1. INTRODUÇÃO..... | 143 |
| 5.2. MATERIAL E MÉTODOS..... | 145 |
| 5.2.1. Fluxo de trabalho..... | 145 |
| 5.2.2. Individualização da área | 147 |
| 5.2.3. Amostragem e análise dos solos | 148 |
| 5.2.3.1. Localização e amostragem período de amostragem de solos | 148 |
| 5.2.3.2. Análises de campo e laboratório | 150 |
| 5.2.4. Aquisição, processamento e seleção das covariáveis | 151 |
| 5.2.4.1. Dados SAR | 152 |
| 5.2.4.2. Pré-processamento e aquisição dos dados SAR..... | 152 |
| 5.2.4.3. Índice de vegetação por diferença normalizada (NDVI)..... | 155 |

| | |
|--|------------|
| 5.2.4.4. Atributos do terreno..... | 156 |
| 5.2.4.5. Extração dos dados para implementação dos modelos..... | 158 |
| 5.2.5. Implementação dos modelos de aprendizado de máquina..... | 159 |
| 5.2.5.1. Regressão linear múltipla..... | 159 |
| 5.2.5.2. Modelagem <i>Random Forest</i> | 160 |
| 5.2.5.3. Avaliação dos modelos..... | 161 |
| 5.3. RESULTADOS E DISCUSSÃO..... | 162 |
| 5.3.1. Avaliação do uso e ocupação das terras..... | 162 |
| 5.3.2. Relações pedomorfogeológicas..... | 164 |
| 5.3.3. Caracterização dos solos..... | 165 |
| 5.3.4. Caracterização e classificação dos solos nas áreas de estudo..... | 168 |
| 5.3.5. Avaliação das variáveis preditoras da umidade do solo..... | 170 |
| 5.3.5.1. Covariáveis SAR..... | 172 |
| 5.3.5.2. Avaliação do NDVI..... | 174 |
| 5.3.5.3. Análise das covariáveis pedomorfológicas..... | 175 |
| 5.3.6. Desempenho da modelagem..... | 177 |
| 5.3.6.1. Avaliação conjunta dos algoritmos..... | 180 |
| 5.3.6.2. Avaliação dos índices de umidade de solos do DF..... | 184 |
| 5.3.7. Distribuição da umidade dos solos predita pelo método <i>Random Forest</i> | 186 |
| 5.3.8. Propagação dos erros da modelagem via <i>Random Forest</i> | 190 |
| 5.4. CONCLUSÕES..... | 192 |
| CAPÍTULO 6 – RELAÇÃO ENTRE ÍNDICE DE UMIDADE DO SOLO DE SÉRIES TEMPORAIS E CLASSES PEDOLÓGICAS..... | 194 |
| 6.1. INTRODUÇÃO..... | 194 |
| 6.2. MATERIAL E MÉTODOS..... | 196 |
| 6.2.1. Fluxo de trabalho..... | 196 |
| 6.2.2. Obtenção do mapa digital de solos..... | 197 |
| 6.2.3. Estimativas dos índices de umidade do solo..... | 197 |
| 6.2.4. Coeficiente de variação da umidade do solo..... | 199 |
| 6.2.5. Índice relativo de umidade do solo em séries temporais..... | 200 |
| 6.2.6. Análise da variabilidade da umidade do solo na série temporal..... | 201 |
| 6.2.7. Cruzamento de mapas..... | 201 |
| 6.3. RESULTADOS E DISCUSSÃO..... | 202 |
| 6.3.1. Análise da variação da umidade dos solos do DF..... | 202 |
| 6.3.1.1. Umidade do solo na série temporal..... | 202 |
| 6.3.1.2. Coeficiente de variação da umidade dos solos..... | 203 |
| 6.3.1.3. Índice relativo de umidade do solo em séries temporais..... | 205 |
| 6.3.1.4. Avaliação da variabilidade da umidade do solo na série temporal..... | 206 |
| 6.3.2. Variação da umidade dos solos com base nas classes pedológicas..... | 209 |
| 6.4. CONCLUSÕES..... | 211 |
| CAPÍTULO 7 – CONSIDERAÇÕES FINAIS..... | 212 |
| REFERÊNCIAS..... | 214 |
| APÊNDICES..... | 230 |

CAPÍTULO 1

CONSIDERAÇÕES INICIAIS

1.1. INTRODUÇÃO GERAL

Os organismos vivos do planeta Terra dependem da estabilidade climática para completarem seu ciclo biológico natural. No entanto, é um tema constante de debate as mudanças no clima atribuídas, principalmente, à intensificação das ações antrópicas e a fatores naturais. Segundo o Painel Intergovernamental sobre Mudanças Climáticas das Nações Unidas (DOUVILLE et al., 2021), essas alterações climáticas são responsáveis por diversos problemas ambientais, como elevação dos níveis dos oceanos e da temperatura das águas; derretimento acelerado das calotas polares; e mudanças nos regimes de precipitação pluviométrica nos continentes; entre outras.

Dessa forma, o aquecimento global também afeta o ciclo do carbono, que está estreitamente relacionado ao ciclo hidrológico. À medida que a concentração de dióxido de carbono (CO₂) atmosférico aumenta, o ambiente físico no qual as plantas crescem é alterado de forma a interferir na disponibilidade de umidade do solo necessária para a absorção de CO₂ pelas plantas e na eficácia da remoção de dióxido de carbono, que mitigam as mudanças climáticas (WEIL e BRADY, 2019).

Cerca de 71% da superfície do planeta Terra é coberto por água, desses, aproximadamente 2,8% correspondem à água doce disponível, que por sua vez estão distribuídos, na maior parte, em geleiras e calotas polares (71%), aquíferos (18%), corpos hídricos superficiais (7%) e umidade no solo e na atmosfera (4%) (DOUVILLE et al., 2021). Esses dados revelam a importância das relações entre solo e água, que representam a base para sustentação da vida na Terra, pois, além de suprir as necessidades energéticas dos seres vivos, regulam o clima (WEIL e BRADY, 2019).

As variações na umidade do solo produzem mudanças significativas no balanço da energia da superfície do planeta (SENEVERATNE et al., 2010). Essas oscilações estão condicionadas pelas características diferenciais dos solos, como a capacidade de retenção e disponibilização de água para o ambiente, que orienta ações específicas de manejo e conservação para cada tipo de solo (KÄMPF e CURI, 2012). Portanto, as investigações acerca da variação da umidade nas diferentes classes de solos representam um parâmetro para a modelagem de processos pedogenéticos.

Nesse sentido, Demattê et al. (2018) afirmaram que os atributos, as propriedades ou classes de solos também podem ser analisados por meio do geoprocessamento de dados de sensoriamento remoto, que, associados aos sistemas de informações geográficas (SIG), conferem eficiência à análise espaço-temporal em grandes áreas com alta acurácia dos resultados. Os parâmetros físicos relacionados aos solos mais acessados por essas técnicas referem-se à: temperatura de superfície, umidade, emissividade, morfometria, reflectância e outros que são imprescindíveis à Pedologia e a diversas outras áreas do conhecimento (MENESES e ALMEIDA, 2019).

O mapeamento digital de solos (MDS) utiliza-se de técnicas como sensoriamento remoto e SIG, que proporcionam economia de tempo e recursos financeiros, com um menor impacto ambiental, pois reduzem consideravelmente o uso de reagentes e material necessário aos levantamentos, quando comparados aos métodos clássicos de mapeamento pedológico (DEMATTÊ et al., 2016). Diversos estudos pedológicos no DF foram desenvolvidos mediante ao uso de geotecnologias. O mapeamento de solos do DF foi realizado pelo Serviço Nacional de Levantamento e Conservação de Solos (FREITAS et al., 1978), em escala 1:100.000.

Embora, por vezes, esse mapeamento seja inadequado para atender aos diversos trabalhos relacionados aos solos do DF, em razão da pequena escala, ainda

corresponde à principal fonte de informações pedológicas da região. Contudo, pesquisas pontuais sobre a distribuição pedológica do DF foram desenvolvidas em escalas de 1:50.000 ou maiores por meio de diferentes geotecnologias e algoritmos, que atribuem eficiência ao processo de mapeamento (REATTO et al., 2000; LIMA et al., 2014; OLIVEIRA JÚNIOR, 2017; POPPIEL et al., 2019a; NOVAIS et al., 2021).

No que se refere aos trabalhos sobre estimativas de umidade de solos no DF, são raros aqueles que utilizam técnicas de sensoriamento remoto. As estratégias envolvem as faixas do espectro eletromagnético óptico, termal e micro-ondas. Cada faixa espectral possui potencialidades e limitações, ou seja, a escolha mais adequada depende de fatores intrínsecos às características fisiográficas e climáticas. No entanto, dados de micro-ondas apresentam melhores resultados que as demais faixas do espectro em estimativas da umidade de solos (SANO et al., 2020).

Autores ao redor do mundo têm se empenhado em implementar ou melhorar as estimativas da umidade de solos por meio de dados de sensoriamento remoto ativo via radar de abertura sintética (SAR) na banda X (BAGHDADI et al., 2012; EL HAJJ et al., 2016; GARCIA et al., 2016; SETIYONO et al., 2017), na banda C (JACOME et al., 2013; BAUER-MARSCHALLINGER et al., 2019, BENNINGA et al., 2020) e na banda L (PALOSCIA, 2013; ALEXAKIS et al., 2017; GAO et al., 2017; ZRIBI et al., 2019; DATTA et al., 2020; SEKERTEKIN et al., 2020).

Como as características diferenciais de cada classe de solo condicionam, entre outras propriedades, a variação da umidade de solos (KÄMPF e CURI, 2012), espera-se que a análise conjunta dessas informações ratifique esta afirmação e indique as áreas com capacidades distintas de manutenção da umidade de solos durante a série temporal em estudo. E, assim, sirva de base para iniciativas quanto à exploração ou

conservação dessas áreas com vistas à identificação da susceptibilidade ambiental de cada local.

Nesse sentido, o presente estudo traz uma análise quantitativa e qualitativa sobre as relações entre dois produtos baseados em modelagem de dados de sensoriamento remoto e análises em campo, os quais: a) classes de solos obtidas pelo MDS por meio de modelagem multiespectral sobre uma série temporal do satélite Landsat e b) índice relativo de umidade dos solos (IRUS), compilado via estimativas da umidade superficial do solo ao longo de um ciclo pluviométrico.

Espera-se que, com a execução da metodologia aqui proposta, informações espacializadas das classes de solos sejam obtidas, assim como a distribuição da umidade superficial dos solos em uma série temporal, o mapa de variação da umidade nesse período, além dos percentuais de áreas sobrepostas desses produtos. Há a perspectiva de que esses produtos e discussões, possam auxiliar no direcionamento de ações de conservação ou exploração dos recursos pedológicos e hídricos sob viés da sustentabilidade e que sirvam de base para trabalhos de pesquisa e extensão no âmbito socioeconômico e ambiental.

1.2. HIPÓTESES

Os solos são capazes de reter água durante certo período a depender de seus atributos e propriedades diferenciais que caracterizam as diversas classes pedológicas (WEIL e BRADY, 2019). Quando saturado, o solo abastece, gradativamente, a atmosfera por meio da evapotranspiração, e o lençol freático, pela percolação da água no perfil. Assim, considera-se que as variações na umidade de solos são influenciadas, entre outros fatores, pelos atributos intrínsecos à pedodiversidade (KÄMPF e CURI, 2012). Os atributos pedológicos e as condições de

uso e ocupação das terras apresentam relação direta com a capacidade de retenção ou disponibilização dessa água ao longo do ano (WU et al., 2020).

Nesse sentido, a variação da umidade de solos, como propriedade diferencial, ocorre pela interação dos fatores de formação dos solos (clima local, ação biológica, posição na paisagem, tipo de rocha matriz e tempo), o que remete à pedogênese, como descreveu Jenny (1941). Portanto, mapas de classes e de variação da umidade de solos podem, por exemplo, identificar áreas mais ou menos susceptíveis à degradação observadas às capacidades distintas de manutenção da umidade inerentes à cada classe de solo. Pois, as propriedades, os atributos e o manejo dos solos influenciam na variação da umidade do solo, então, um mapa de variação da umidade do solo durante certo período deverá coincidir com as classes de solos notadamente capazes de manter ou disponibilizar a água para o ambiente.

As geotecnologias potencializam a capacidade de percepção e interação humana do ambiente por meio de modelagem (JENSEN, 2009). Com suporte de processamento em nuvem, essas técnicas conferem eficiência em levantamento de recursos, observação de tendências ou recuperação de cenários diversos. O levantamento dos atributos e propriedades dos solos, por exemplo, são realizados de maneira relativamente rápida e com alto grau de confiabilidade. Dessa forma, sensores remotos, em seus níveis de operação orbital, aéreo ou terrestre, podem captar (ou emitir e captar) a energia eletromagnética de fonte natural ou artificial, que possibilita as estimativas de propriedades e constituintes dos alvos, as quais são calibradas por aferições diretas (MENESES e ALMEIDA, 2019).

A modelagem da reflectância dos solos, nas regiões do espectro visível e infravermelho de ondas curtas, de uma série temporal de dados orbitais, viabiliza a geração de mapas digitais de classes de solos (POPPIEL et al., 2019a). Já os dados

de sensoriamento remoto ativo, na faixa espectral das micro-ondas, captados durante um período pluviométrico e calibrados por dados síncronos de campo, podem modelar a variação da umidade de solos no domínio do espaço e do tempo (ZHANG et al., 2018; DATTA et al., 2020). Dentre as principais vantagens dessa técnica, está a independência das condições de iluminação ou presença de nuvens.

1.3. OBJETIVOS

1.3.1. Objetivo geral

Desenvolver uma metodologia que inter-relacione classes pedológicas com a dinâmica da água na superfície dos solos por meio de geotecnologias.

1.3.2. Objetivos específicos

- Elaborar um mapa digital de solos do Distrito Federal por meio de modelagem de dados multiespectrais de série temporal Landsat;
- Modelar a umidade superficial dos solos, durante um ciclo pluviométrico, por meio de dados de sensoriamento remoto ativo e passivo e atributos pedomorfológicos via algoritmos de aprendizado de máquina;
- Compilar um índice relativo de umidade dos solos para séries temporais;
- Relacionar classes pedológicas com a variação da umidade dos solos e ao uso e ocupação das terras longo da série temporal estudada;
- Fornecer dados e material cartográfico que direcionem as ações de conservação e exploração sustentável dos recursos solo e água.

1.4. JUSTIFICATIVA

Com o aumento da população, cresce a demanda por energia, que intensifica a pressão sobre os recursos naturais solo e água (DOUVILLE et al., 2021). Essa energia envolve a produção de alimentos, biocombustíveis e geração de energia elétrica, por exemplo. Os sistemas produtivos, por vezes sem um planejamento adequado, acarretam graves problemas sociais, econômicos e ambientais. Esse fato leva à necessidade do conhecimento aprofundado acerca dos recursos como solo e água, e do grau de exploração que estes suportam (NOVAIS e LACERDA, 2021).

Os mapas de solos disponíveis do DF estão em escalas de reconhecimento de média a baixa intensidade (1:100.000 e poucas áreas em 1:50.000), gerados de levantamentos realizados na década de 1970 (FREITAS et al., 1978; REATTO et al., 2004), portanto, inadequados para subsidiar ações como projetos e programas de desenvolvimento agrícola localizados como irrigação e agricultura de precisão. Assim, surge a necessidade de se dispor de material cartográfico atualizado, obtido por técnicas de menor impacto ao meio ambiente. As geotecnologias utilizam-se de métodos computacionais de aquisição, gerenciamento e processamento de dados do meio físico, de maneira a proporcionar a redução de tempo e custos de levantamento de dados (REDDY, 2017).

Quando comparadas aos métodos tradicionais de levantamento e mapeamento, as geotecnologias são mais eficientes, pois potencializam a capacidade perceptiva da distribuição espacial das características do ambiente, além de possibilitar o processamento simultâneo, rápido e automatizado de um grande volume de informações sobre a interação dos vários fatores que compõe este ambiente (DEMATTE et al., 2018; POPPIEL et al., 2019c; NOVAIS et al., 2021). Ademais, mapas temáticos em escala de detalhamento relacionados aos solos e à variação da

umidade superficial são fundamentais para identificar a adequação ou inadequação quanto ao uso das terras (NOVAIS e LACERDA, 2021).

A crise hídrica no DF, iniciada em 2015 e intensificada entre 2016 e 2017, foi marcada pela redução dos reservatórios a níveis críticos, que ocasionou no racionamento da água distribuída para a população e para as atividades industriais e agropecuárias (CUNHA et al., 2018; CODEPLAN, 2020b). Como consequência, houve uma desaceleração abrupta dos índices de produtividade agrícola, principalmente nas culturas dependentes de irrigação (EMATER, 2020). A crise hídrica evidenciou a dependência de sistemas produtivos mais eficientes que visem a sustentabilidade quanto ao uso racional dos recursos naturais não renováveis.

Diante do exposto, o desenvolvimento de técnicas que viabilizem informações para o gerenciamento adequado dos solos e da água é imprescindível para a sustentação dos sistemas produtivos com vistas à diminuição da pressão sobre esses, e outros, recursos. O manejo e a conservação dos solos e o uso racional da água podem evitar problemas de ordem socioeconômica e ambiental como desmatamentos, degradação do solo, assoreamento de corpos hídricos e desaparecimento de mananciais, por exemplo (NOVAIS e LACERDA, 2021).

Nesse sentido, a metodologia e os resultados desta tese representam uma fonte de informações para o desenvolvimento de ações que visem a exploração sustentável dos recursos hídricos e pedológicos. Portanto, esta pesquisa terá aplicabilidade para pesquisadores e agentes promotores do planejamento de uso e manejo do solo e da água, bem como para os gestores de políticas públicas no DF e em outras partes do mundo.

CAPÍTULO 2

FUNDAMENTAÇÃO TEÓRICA: GEOTECNOLOGIAS APLICADAS AO MAPEAMENTO DE CLASSES E ATRIBUTOS DOS SOLOS

2.1. EVOLUÇÃO CONCEITUAL DO SOLO

As abordagens terminológicas designam o solo, ou *solum*, *sōli*, em latim, como: chão, fundo, piso, base, fundação, terra. Tecnicamente, *solum* corresponde à parte superior do perfil do solo que abrange os horizontes A e B (WEIL e BRADY et al., 2019). No sentido literal, o solo é definido como o conjunto das acumulações de partículas sólidas, líquidas e gasosas que constituem a crosta terrestre, desde os depósitos geológicos até as camadas superficiais, como consta no Dicionário da Língua Portuguesa de Houaiss e Villar (2009).

Da mesma forma, a palavra *pedon*, em grego, refere-se a solo, que forma Pedologia, que corresponde à disciplina da ciência do solo que trata da morfologia, gênese e classificação do solo. Então, Kämpf e Curi (2012) afirmaram que o solo, em seu estado natural, encontra-se inconsolidado, disposto em três dimensões e tem, como unidade taxonômica, o *pedon*. Vale ressaltar que o termo grego *edaphós* também remete a solo, porém sob o viés biológico, logo, Edafologia é o estudo das relações do solo com a vida (HARPER, 2021).

Estudos realizados pelo cientista do solo Vasily Vasil'evich Dokuchaev, no fim do século XIX (DOKUCHAEV, 1879) introduziram a Pedologia como ciência responsável pelas investigações acerca da distribuição, morfologia, gênese e classificação dos solos. Assim, a Pedologia tem, como objeto de estudo, o solo. Esse material recobre a crosta dos planetas, possui área e espessura determinada e é

composto por minerais em transformação que podem conter matéria orgânica, gases e líquidos, por esta razão surge a expressão solução do solo (WEIL e BRADY, 2019).

Ao longo do tempo, diversas vertentes se propuseram a descrever o solo, de maneira a abordar a complexidade inerente a esse recurso natural não renovável. As principais correntes conceituais acerca dos solos partem da pedogênese que envolve a interação de fatores ambientais que geram processos internos. Além dos pressupostos de Dokuchaev (DOKUCHAEV, 1879; 1967), a maioria dos estudos pedológicos atuais se baseiam nos trabalhos de Hans Jenny (1941) e Marlin Cline (1961) que apresentaram formulações sobre os princípios de formação dos solos.

Posteriormente, Cline (1977) sugeriu uma definição para esse recurso ao afirmar ser o solo: um corpo natural com uma gênese definida e uma natureza distinta própria que ocupa uma posição independente nas formações que constituem a superfície da terra. Essa definição foi amplamente aceita pela comunidade científica e é adotada pelo Serviço de Levantamento de Solo dos Estados Unidos (SOIL SURVEY STAFF, 2014) que propôs a seguinte ampliação desta concepção:

“[...] Um corpo natural composto de sólidos (minerais e matéria orgânica), líquidos e gases que ocorrem na superfície da terra, ocupa espaço e é caracterizado por um ou ambos dos seguintes: horizontes ou camadas distinguíveis de o material inicial como resultado de adições, perdas, transferências e transformações de energia e matéria ou a capacidade de apoiar plantas enraizadas de forma natural no meio ambiente” (SOIL SURVEY STAFF, 2014, tradução livre)¹.

Nesse sentido, a evolução terminológica do recurso solo passa pelas considerações do físico e filósofo Thomas Kuhn (1996 [1962]) que reiterou, em sua

¹ Soil Survey Staff (2014): “a natural body comprised of solids (minerals and organic matter), liquid, and gases that occurs on the land surface, occupies space, and is characterized by one or both of the following: horizons, or layers, that are distinguishable from the initial material as a result of additions, losses, transfers, and transformations of energy and matter or the ability to support rooted plants in a natural environment”.

obra “A estrutura das revoluções científicas”, que, à medida em que novas técnicas são aplicadas nas mais variadas áreas do conhecimento, os conceitos são alterados para descrever um material, um fenômeno e uma força, entre outros. Esta conjuntura levou à evolução natural das concepções atuais do solo.

Assim, como consequência do avanço tecnológico, Van Es (2017), por meio da Sociedade Americana de Ciência do Solo (SSSA) atualizou a definição de solo ao descrever o recurso como: A(s) camada(s) de material mineral e/ou orgânico geralmente solto, que são afetados por processos físicos, químicos e/ou biológicos na (ou perto da) superfície planetária e geralmente contém líquidos, gases, biota e plantas de suporte². O autor propôs englobar os aspectos atuais dos estudos pedológicos, inclusive de outros planetas, bem como unificar os conceitos existentes.

A definição de solo adotada no presente estudo aborda a concepção no âmbito terrestre e trata-se de um compilado das propostas anteriormente apresentadas, a qual: O solo é o material inconsolidado que contém minerais, gases, líquidos e matéria orgânica, disposto entre a base da atmosfera e o topo da litosfera, formando assim, a pedosfera, que fornece suporte físico e nutricional às plantas (e a outros organismos) e que interage com a dinâmica dos eventos naturais e artificiais na interface planetária. Dessa forma, é válido ressaltar que a pedogênese vai além do intemperismo do material parental. Isto porque abrange fatores fisiográficos e ambientais como posição na paisagem e clima (água e temperatura), além de macro e micro-organismos que também modificam a matriz principal do solo (WEIL e BRADY, 2019).

² The layer(s) of generally loose mineral and/or organic material that are affected by physical, chemical, and/or biological processes at or near the planetary surface and usually hold liquids, gases, and biota and support plants.

2.2. A PEDOGÊNESE E AS RELAÇÕES SOLO-PAISAGEM

Como já mencionado, o solo é produto derivado do intemperismo físico, químico e biológico que interage com as condições climáticas por um dado período sobre as rochas próximas à superfície terrestre conhecida como pedosfera (MENDONÇA-SANTOS e SANTOS, 2006). As características geomorfológicas locais também são determinantes para a formação das diversas classes de solos. O arranjo pedológico, formado por várias categorias, ocorre principalmente em função do material parental exposto às intempéries ao longo do tempo, que determina a pedodiversidade local (LACERDA e BARBOSA, 2012).

Desse modo, esta diversidade de tipos de solos faz com que existam classes naturalmente muito produtivas e outras pouco férteis em paisagens distintas. A qualidade do solo é expressa na vegetação natural, pois solos ricos e saudáveis, em um ambiente equilibrado, favorecem o desenvolvimento de plantas mais vigorosas, com altura ou densidade superiores às plantas encontradas em solos degradados, ao considerar as mesmas condições climáticas (NOVAIS e LACERDA, 2021).

As diversas classes pedológicas se interrelacionam de maneira a formar complexos de unidades limitadas pelas características diferenciais herdadas do material e do ambiente onde se encontram. O relevo age como um dos principais fatores de formação do solo, pois exerce forte influência sobre a gênese e distribuição dos solos na paisagem, de forma a apresentar uma forte relação com os limites das unidades de mapeamento (McBRATNEY et al., 2014).

2.3. LEVANTAMENTO E MAPEAMENTO PEDOLÓGICO

A abordagem conceitual acerca do levantamento pedológico, adotada no presente trabalho, foi realizada por Santos et al. (1995), que define esse procedimento

como “um prognóstico da distribuição geográfica dos solos como corpos naturais, determinados por um conjunto de relações e propriedades observáveis na natureza”. Ou seja, as unidades observadas buscam relacionar-se com a realidade.

De acordo com Teixeira et al. (2017), um levantamento de solos identifica e separa unidades de mapeamento. Essas unidades compreendem agrupamentos de solos, criados para a representação cartográfica, com a finalidade de mostrar a distribuição espacial dos solos e suas relações com fatores ambientais como vegetação e posição na paisagem (SCHOENEGER, 2012). Portanto, o objetivo principal de um levantamento pedológico é subdividir áreas heterogêneas em parcelas mais homogêneas, de maneira que apresentem a menor diversidade de condicionantes das classes possível, em função dos parâmetros de classificação e das características para distinção dos solos (MINASNY e McBRATNEY, 2016). A Tabela 2.1 subdivide os tipos levantamentos de acordo com os objetivos.

Tabela 2.1. Caracterização de levantamentos de solos, tipos, objetivos, área examinada, número de perfis por hectare e escala do mapa-base.

| Tipos | Objetivos | Exames | Perfis | Escala do mapa-base |
|-------------------------------------|---|------------------|----------------------|----------------------------|
| Exploratório | Conhecer genericamente as potencialidades e limitações dos solos e ambientes de grandes regiões | 1/3001 a 6000 ha | 1/400000 a 800000 ha | 1:250000 a 1:1000000 |
| Reconhecimento de baixa intensidade | Executar o planejamento agropecuário estadual | 1/1001 a 3000 ha | 1/200000 a 30000 ha | 1:100000 a 1:250000 |
| Reconhecimento de média intensidade | Executar o planejamento agropecuário estadual visando a seleção de áreas para projetos | 1/601 a 1000 ha | 1/15000 a 20000 ha | 1:50000 a 1:100000 |
| Reconhecimento de alta intensidade | Executar o planejamento agropecuário estadual visando a seleção de áreas para projetos | 1/301 a 600 ha | 1/10000 a 15000 ha | 1:50000 a 1:100000 |
| Semidetalhado | Executar o plano diretor municipal, seleção de áreas para estudos de ambientes de produção de plantas | 1/21 a 300 ha | 1/250 a 600 ha | 1:25000 a 1:50000 |
| Detalhado | Elaborar projetos de irrigação | 1/1,1 a 20 ha | 1/25 a 50 ha | 1:5000 a 1:25000 |
| Ultra detalhado | Elaborar projetos de irrigação e de agricultura de precisão | 1/0,25 a 1 ha | 1/10 a 30 ha | 1:5000 ou maior |

Fonte: Adaptado de Santos et al. (1995)

As informações pedológicas contidas nos mapas também servem às mais variadas pesquisas científicas em diversos campos do conhecimento, como, por exemplo, estudos ambientais sobre as funções dos solos nos ecossistemas (PRADO et al., 2016); análises socioeconômicas e culturais voltadas à relação do homem com os solos (PARIKH e JAMES, 2012; McBRATNEY et al., 2014; TELBER et al., 2017); e, ainda, investigações acerca da qualidade dos solos como indicadores de saúde coletiva (BREVIK e BURGESS, 2014; STEFFAN et al., 2017).

Mapas pedológicos podem ainda conter informações relevantes como a susceptibilidade do solo à erosão e à degradação, as quais se prestam a direcionar ações de planejamento estratégico para o manejo e conservação, de forma a buscar os princípios da sustentabilidade ambiental (PEREZ et al., 2016). Nesse sentido, o estudo aprofundado sobre cada componente do solo é essencial para a compreensão dos processos pedogenéticos, portanto, para a classificação desses solos em um determinado sistema categórico (SANTOS et al., 2018).

Hou et al. (2020), por exemplo, realizaram um estudo multidisciplinar sobre o uso e gestão sustentável dos solos e afirmaram que a pressão e o manejo inadequado dos solos levam à degradação, o que acarreta problemas de ordem socioeconômica e ambiental. Dessa forma, a gestão de solos deve priorizar ações de manejo e conservação como medidas de mitigação de questões da atualidade, como a diminuição da biodiversidade e mudanças climáticas (ZHOU et al., 2021).

Existem basicamente dois métodos para mapeamento de solos. O primeiro método, chamado de clássico ou tradicional, emprega o método “*Clorpt*” que estabelece que o Solo (S) é resultado da interação de cinco fatores: clima (cl), organismos (o), relevo (r), material de origem (p) e tempo (t). Esse método qualitativo

foi formalizado por Jenny (1941) que propôs um modelo preditivo de classes pedológicas (Eq. 2.1):

$$S = f(cl, o, r, p, t) \quad (2.1)$$

O segundo método, denominado de mapeamento digital de solos (MDS), utiliza o modelo denominado SCORPAN (McBRATNEY et al., 2003) para explicar as relações quantitativas ou qualitativas entre solo e outros fatores ambientais. Então, considera-se que as classes ou os atributos do solo (S) são funções das propriedades do solo (s) em um dado ponto; condições climáticas (c) do ambiente em um ponto determinado; organismos (o), que incluem a vegetação, fauna e atividades humanas; relevo (r) e suas variáveis morfométricas; material de origem (p); idade (a); e posição (n) no espaço (Eq. 2.2):

$$S = f(s, c, o, r, p, a, n) \quad (2.2)$$

O modelo SCORPAN foi desenvolvido para abordar as classes de solos e os atributos inerentes em uma posição geográfica específica (coordenadas X e Y) em um determinado tempo (McBRATNEY et al., 2003). Logo, o conhecimento do impacto da localização dos solos na sua constituição e comportamento é necessário para as reflexões pedológicas (TEN CATEN et al., 2011; DEMATTÊ et al., 2016). A maioria dos estudos modernos são baseados nesse modelo teórico para mapear classes e atributos dos solos (MA et al., 2019).

Ambas as abordagens de mapeamento pedológico necessitam de amostragens representativas de solos em campo. Um levantamento de solos deve buscar a melhor descrição da distribuição espacial dos solos, de forma a considerar as características fisiográficas e ambientais, as quais são quantificadas em laboratório para os procedimentos de classificação e modelagens (CARVALHO JÚNIOR et al.,

2014). Congalton e Green (2010) afirmaram que diversos métodos de amostragem são empregados no levantamento de solos, que podem ser do tipo aleatória simples, aleatória estratificada ou sistemática.

2.3.1. Mapeamento digital de solos

Antes de iniciar as explicações sobre o mapeamento digital de solos (MDS), é válido discutir as bases conceituais acerca desse procedimento/ finalidade. Como mencionado anteriormente, um mapa, ou carta, é uma representação esquemática da realidade física de um tema, ou objeto, em uma dada escala e associado a um sistema de classificação oficial, bem como um sistema de coordenadas (McBRATNEY et al., 2003). Nesse sentido, um mapa digital de solos é alcançado quando a maior parte das etapas de extrapolação de dados é executado por técnicas computacionais, que envolvem lógica, matemática e/ ou estatística, que transforma dados pontuais na distribuição das classes de solos (CONGALTON e GREEN, 2010). Dessa forma, o escaneamento de um mapa produzido por técnicas convencionais não pode ser considerado digital, mas um mapa digitalizado.

O tipo, a quantidade e a qualidade das informações utilizadas no processo de elaboração do mapa digital de solos ditarão qual o método mais adequado. O produto do MDS também pode ser denominado como mapa pedológico, mapa digital de classes de solos (ou de atributos), carta digital, ou, simplesmente mapa de solos (MENDONÇA-SANTOS e SANTOS, 2006). No presente trabalho, utilizou-se o termo “mapeamento digital de solos” tanto para os procedimentos, como para a finalidade dos trabalhos, por considerá-lo mais adequado ao escopo do presente estudo.

As técnicas de MDS tiveram ênfase por volta de 1970 e se expandiu significativamente durante a década de 1980, principalmente em decorrência dos avanços na área de tecnologia da informação e de sensoriamento remoto (MINASNY

e McBRATNEY, 2016). O MDS é baseado essencialmente em banco de dados que espacializa as propriedades do solo obtidas por meio de amostragem e modelagem estatístico-matemática da paisagem por métodos determinísticos ou estocásticos (CARVALHO JÚNIOR et al., 2014). Dentre as geotecnologias, o sensoriamento remoto corresponde a um dos principais meios de obtenção de variáveis explicativas para a predição de classes e atributos pedológicos via MDS (MA et al., 2019).

Diversas técnicas são utilizadas nos inventários de solos, a depender do objetivo do mapeamento. Os levantamentos de solos englobam trabalhos prévios de escritório (mapa preliminar), levantamento em campo (observação, amostragem e validação), análises laboratoriais que envolvem a determinação dos compostos, processamento, interpretação dos dados com posterior elaboração dos mapas e relatórios técnicos finais (MENDONÇA-SANTOS e SANTOS, 2006).

Na prática, o MDS se apresenta como alternativa ao mapeamento tradicional, pois proporciona um método mais eficiente e econômico, com redução de tempo e custos de execução, com uma menor densidade de observações e frequência de amostragem (McBRATNEY et al., 2003). Esses fatores ocasionam uma menor geração de resíduos decorrentes de coleta de materiais de amostragem no campo e redução do uso de reagentes nas análises (ALVES et al., 2015; MA et al., 2019).

Conforme mencionado anteriormente, vários métodos são utilizados para amostragem representativa da área. O hipercubo latino, por exemplo, é um algoritmo que realiza a amostragem sistemática por meio de uma randomização de posições com base em um arquivo vetorial, que admite a inserção de conhecimento empírico do pesquisador na definição dos locais de amostragem (CARVALHO JÚNIOR et al., 2014). Esses dados são posteriormente extrapolados para estimar a posição e extensão de classes e atributos em áreas sem amostragem, mas que detém

comportamento estatístico próximo do conjunto de dados considerados como referência (McBRATNEY et al., 2003).

A compreensão dos fatores de formação dos solos é essencial para o MDS para que sejam abordadas variáveis capazes de representar o arranjo pedológico de uma área (MINASNY e McBRATNEY, 2016). Com base em dados geomorfológicos e hidrogeológicos. Ten Caten et al. (2011) realizaram o MDS e relataram que essas covariáveis representaram a distribuição dos atributos específicos de cada classe de solo. Por consequência, configuram elementos de predição da ocorrência de determinadas classes em locais e condições inerentes àquela área McBRATNEY et al. (2014). Lacerda e Barbosa (2012) enfatizaram a importância das unidades de relevo em levantamento de solos, uma vez que interferem no tempo de exposição dos materiais, na intensidade e na direção do fluxo da água no solo, além de regular as variações nos processos pedogenéticos.

O MDS pode ser executado ainda mediante o uso da espectroscopia de reflectância como variável preditora. Esta técnica utiliza-se do sensoriamento remoto em seus vários níveis de operação para registro e análise da energia eletromagnética refletida ou absorvida pelos vários tipos, atributos e classes de solos (DEMATTÊ et al., 2014). Diversos pesquisadores têm-se empenhado em realizar MDS de classes e atributos por diferentes técnicas de modelagem de dados espectrais e outras variáveis (DEMATTÊ et al., 2016; RIZZO et al., 2016; POPPIEL et al., 2019a; 2019b; 2019c; COBLINSKI et al., 2020; LIU et al., 2020; MENDES et al., 2020; NOVAIS et al., 2021).

2.3.2. Iniciativas de MDS e banco de dados no Brasil

No final do século XX, as instituições brasileiras de pesquisa se empenharam em mapear os solos em escala nacional por meio de técnicas de sensoriamento

remoto e geoprocessamento (MENDONÇA-SANTOS e SANTOS, 2006). Por exemplo, nas décadas de 1970 e 1980, o Projeto RadamBrasil realizou o levantamento dos recursos naturais, geomorfologia e solos de todo o território brasileiro, em escala exploratória. Na ocasião, foram utilizados dados de radar de abertura sintética (SAR) do sistema Goodyear Mapping System (GEMS) que operou na banda X (8 a 12 GHz) (BRASIL, 1973-1986). Desde então, levantamentos, em variadas escalas, produziram MDS por meio de técnicas de modelagem.

Em uma frente para sistematizar os estudos sobre os solos, a Embrapa criou um repositório de dados pedológicos obtidos em todo o país, o Sistema de Informação de Solos Brasileiros (EMBRAPA, 2014). Outra iniciativa semelhante gerou o Repositório Brasileiro Livre para Dados Abertos do Solo (FEBR), coordenado pelo Prof. Alessandro Samuel Rosa da Universidade Tecnológica Federal do Paraná (SAMUEL-ROSA et al., 2020).

Cabe mencionar, ainda, a Biblioteca Espectral de Solos do Brasil (<https://bibliotecaespectral.wixsite.com/esalq>), coordenada pelo Prof. José Alexandre Demattê da Escola Superior Luiz de Queiroz (ESALQ), da Universidade de São Paulo (USP). Essa biblioteca consiste em um banco de dados com um acervo de assinaturas espectrais e análises de solos de diferentes partes do país e que podem ser utilizadas em MDS e outras finalidades (DEMATTÊ et al., 2019).

Fundamentado em iniciativas como as citadas anteriormente, bem como em trabalhos pedológicos existentes, foi criado em 2018, o Programa Nacional de Levantamento e Interpretação de Solos do Brasil (Pronasolos) (<http://pronasolos.agenciazetta.ufla.br/>). Trata-se de uma iniciativa instituída pelo Decreto Nº 9.414, de 19 de junho de 2018 (BRASIL, 2018), envolve a cooperação de diversas instituições de pesquisa, organizações governamentais e não-

governamentais e possui o objetivo de mapear 1,3 milhão de km² de solos no Brasil e mais de 6,9 milhões de km² até 2048.

Polidoro et al. (2016) relataram que diferentes técnicas de levantamento e mapeamento são integradas no Pronasolos, inclusive a utilização de modelagem por pedometria e espectroscopia de solos. Essas técnicas seguem os princípios do MDS descritos por Minasny e McBratney (2016) que utilizam métodos estocásticos ou determinísticos para prever e extrapolar dados pedológicos pontuais, como variáveis morfométricas e assinaturas espectrais, para áreas sem informações de solos.

2.4. ASPECTOS PEDOLÓGICOS NA REGULAÇÃO DO CLIMA

A radiação solar é a principal fonte de energia que mantém o sistema terrestre. A energia solar que interage com os componentes do sistema terrestre é parcialmente perdida ao atravessar a atmosfera da Terra. Os componentes, por sua vez, absorvem uma fração dessa energia que é reemitida para o sistema (LIBARDI et al., 2015). O Sol emite radiação eletromagnética em comprimentos de ondas acima de 0,15 µm. Porém, mais de 99% da quantidade de energia é emitida no intervalo de 0,15 µm a 4,0 µm (MENESES e ALMEIDA, 2019). Desse modo, o balanço entre a radiação incidente (radiação de ondas curtas) nos componentes da superfície terrestre e a radiação recebida desses componentes (radiação de ondas longas) é conhecido como saldo de radiação (R_n) (Eq. 2.3) (RUHOFF et al., 2012).

$$R_n = SW_{in} - SW_{out} + LW_{in} - LW_{out} \quad (2.3)$$

Em que SW_{in} corresponde à radiação de onda curta recebida; SW_{out} é a radiação de onda curta de saída (igual a αSW_{in} , no qual α representa o albedo ou reflectância); LW_{in} corresponde à radiação de onda longa de entrada; e LW_{out} equivale

à radiação de onda longa de saída. O R_n na superfície da Terra se distribui em diferentes formas de energia: calor latente (energia necessária para transformar água líquida em vapor d'água); calor sensível (energia necessária para aquecer a atmosfera terrestre); e calor armazenado no solo (RUHOFF et al., 2012). O equilíbrio de energia na superfície de solo é expresso de acordo com a Eq. 2.4:

$$\frac{dH}{dt} = R_n - \lambda E - SH - G \quad (2.4)$$

Em que a razão $\frac{dH}{dt}$ corresponde à variação de energia dentro da camada acima do solo considerada (contempla as variáveis de armazenamento de água consideradas na Eq. 2.1); λE é o fluxo de calor latente (λ é o calor latente de vaporização da água e corresponde ao fluxo de vapor d'água); SH representa o fluxo de calor sensível; e G equivale ao fluxo de calor do solo para camadas mais profundas do perfil (SENEVIRATNE et al., 2010).

O balanço hídrico, por sua vez, expressa todas as entradas e saídas de água que ocorrem em um determinado volume durante certo período. A Eq. 2.5 modela o balanço hídrico para a camada superficial de solo que inclui a vegetação, porém, desconsidera a troca lateral entre volumes de solo adjacentes.

$$\frac{dS}{dt} = P - E - R_s - R_g \quad (2.5)$$

Em que a razão $\frac{dS}{dt}$ representa a variação do teor de água (conteúdo absoluto) para uma dada camada; P é a precipitação; E é a evapotranspiração (fluxo de vapor d'água); R_s equivale ao escoamento superficial; e R_g equivale à drenagem profunda. E inclui a evaporação direta do solo, a transpiração das plantas, a evaporação mediante ao armazenamento por interceptação, sublimação da neve, e evaporação direta de corpos hídricos, conforme descrito em Ruhoff et al. (2012).

Os balanços de água e energia estão relacionados à evapotranspiração (E , λE) que inclui as propriedades e atributos dos solos. Segundo Seneviratne et al. (2010), a umidade do solo desempenha um papel fundamental nos ciclos de água e energia, dada a influência da evapotranspiração sobre a distribuição de energia na superfície. Além do impacto do calor latente, a umidade do solo também causa alterações no calor sensível que influencia diretamente o balanço hídrico e a regulação do clima na Terra (LIBARDI et al., 2015).

2.4.1. Balanço hídrico no solo

Ruhoff et al. (2012) afirmaram que há uma relação direta entre a umidade do solo e a evapotranspiração. Espera-se que esta inter-relação seja mais intensa em zonas de transição entre climas secos e úmidos. As principais interações que correlacionam a umidade do solo, o calor latente e o calor sensível são mostradas na Figura 2.1, adaptada de Seneviratne et al. (201, na qual: as setas positivas (vermelhas) indicam processos que levam a uma secagem / aquecimento em resposta a uma anomalia negativa de umidade do solo e as setas azuis denotam feedbacks negativos potenciais (a seta azul tracejada indica a tendência de aumento da temperatura para levar a mais demanda evaporativa; se isso resultar em um aumento da evapotranspiração, isso por sua vez leva a uma nova secagem do solo e, portanto, a um ciclo de feedback positivo). Os termos (A), (B) e (C) referem-se às diferentes etapas do ciclo de *feedback*.

A maioria das alterações do sistema climático atribuídas à umidade do solo são causadas pela sua influência sobre o fluxo de calor latente (evapotranspiração) em regimes em que a umidade do solo é restrita. O teor de umidade do solo está diretamente ligado ao potencial hídrico do solo ou à capacidade de infiltração. Com a

diminuição da umidade, a capacidade de infiltração aumenta e a água remanescente torna-se menos acessível para a absorção pelas raízes das plantas; como consequência, a evapotranspiração é, então, reduzida (SENEVIRATNE et al., 2010).

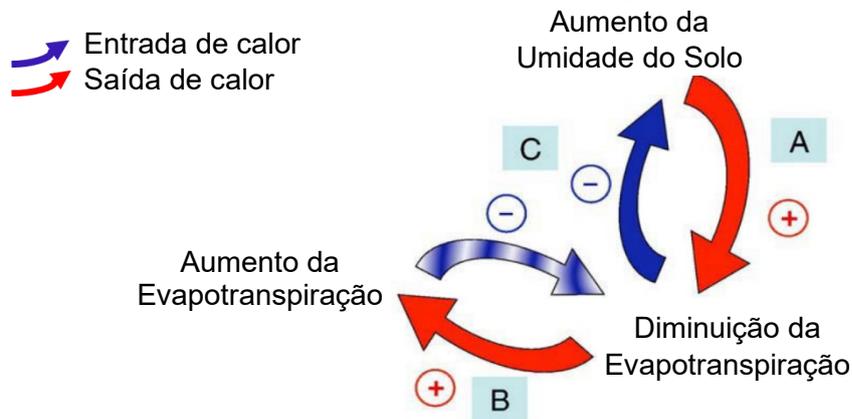


Figura 2.1. Interações entre a umidade do solo, evapotranspiração e temperatura.

Fonte: Seneviratne et al. (2010).

Dessa forma, no balanço hídrico do solo, afasta-se da concepção do solo como um reservatório de água e considera-se o movimento vertical de água no perfil, dentro de um determinado volume de solo (Figura 2.2). Para Hillel (1982), esse sistema pondera apenas a água originária da precipitação como entrada, enquanto a que sai está relacionada à evapotranspiração real e à água que percola abaixo do alcance do sistema radicular das plantas, que constitui a recarga subterrânea do lençol freático.

A figura acima ilustra, ainda, que o processo de elevação da temperatura leva a uma maior deficiência de pressão de vapor e maior demanda evaporativa, portanto, há um aumento potencial da evapotranspiração que ocasiona a redução na umidade do solo (ZHOU et al., 2020). Esse ciclo pode ir até a secagem total do solo, quando a temperatura aumenta e não pode ser atenuada por novos acréscimos de evapotranspiração, ao desconsiderar a água residual (WEIL e BRADY, 2019).

Um impacto significativo da umidade do solo no clima da superfície terrestre está relacionado às mudanças na temperatura do ar. Quanto menor a quantidade de

energia total utilizada pelo fluxo de calor latente, mais energia estará disponível para o calor sensível, o que induz ao aumento da temperatura do ar próximo à superfície do solo e contribui para a regulação do microclima nesta região (ZHOU et al., 2020).

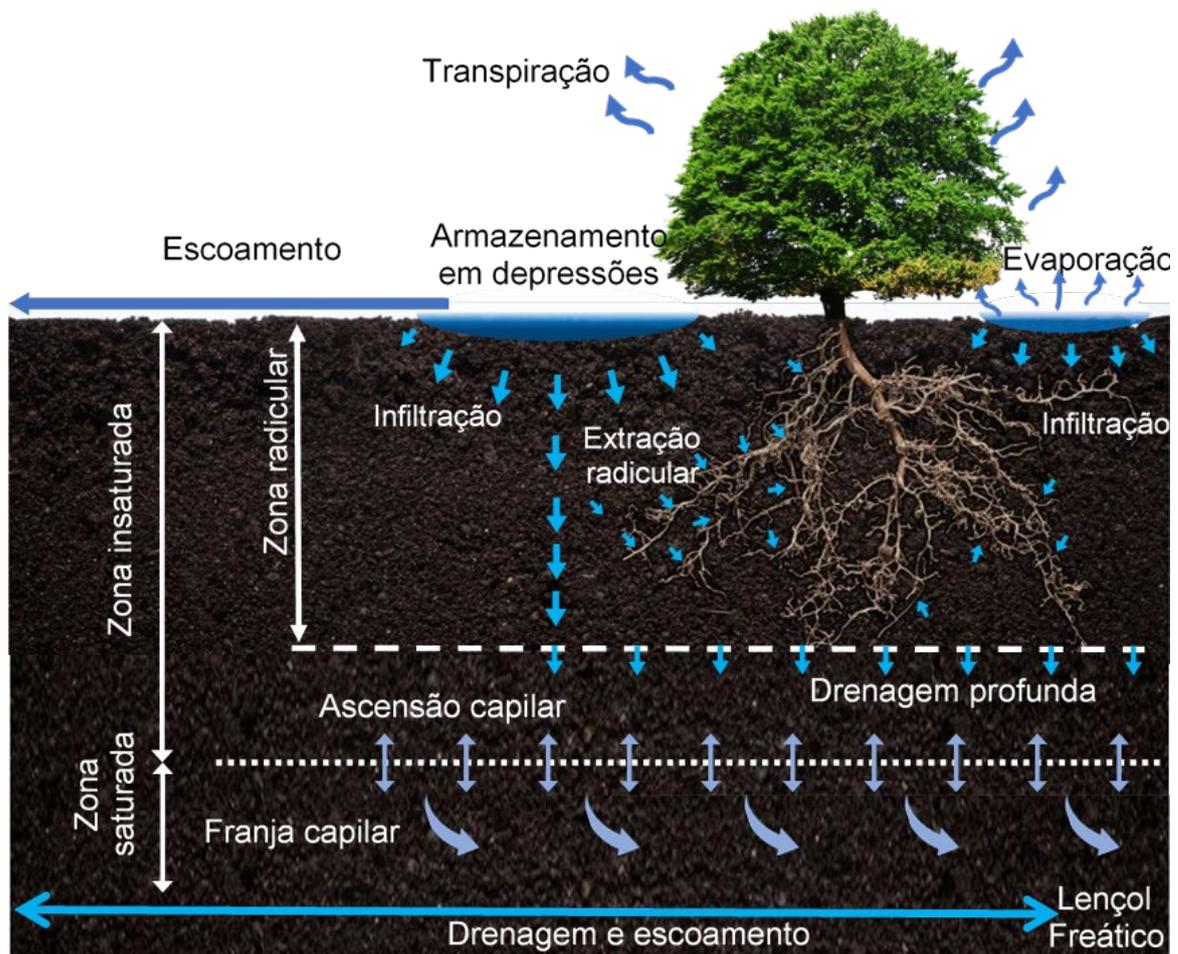


Figura 2.2. Esquema do balanço hídrico no solo. Fonte: Elaborado pelo autor com base em Hillel (1982).

2.5. IMPORTÂNCIA DA UMIDADE DO SOLO PARA A AGRICULTURA

Como mencionado anteriormente, o solo é composto basicamente por minerais, material orgânico, água e ar em proporções variadas, a depender de fatores climáticos, ambientais e antrópicos (VAN ES, 2017). Dessa forma, o conhecimento das características pedológicas como a capacidade do solo em manter a umidade por

determinado tempo é de fundamental importância para o ambiente, sobretudo no que se refere a processos biológicos, hidrológicos e atmosféricos (RUHOFF et al., 2012).

A umidade do solo corresponde à quantidade de água presente em um dado instante no perfil que está disponível para as plantas e atmosfera. Essa característica diferencial do solo é dependente das condições climáticas, da textura e da estrutura das partículas no solo (MOHANTY et al., 2017). Como os atributos e propriedades dos solos variam de acordo com a composição e o grau de evolução pedogenética, a textura determinará a área de contato entre as partículas sólidas e a água, tanto nos grânulos sem estrutura quanto em agregados do solo (KÄMPF e CURI, 2012). Por outro lado, a estrutura do solo é responsável pela distribuição dos agregados sólidos que determinam a porosidade, visto que apresentam variações nas formas, de acordo com a evolução pedogenética (LACERDA et al., 2016). Assim, a umidade do solo varia também em função da diversidade de classes pedológicas (LOPES et al., 2021).

A absorção de água e nutrientes pelas plantas é mais favorecida em solos conservados ou manejados adequadamente. Nesse sentido, a umidade das diferentes classes pedológicas está diretamente relacionada ao balanço hídrico, conseqüentemente, com a qualidade do solo, pois o manejo pode modificar algumas variáveis como a capacidade de retenção ou a disponibilização de água para o sistema solo/planta/ambiente (WEIL e BRADY, 2019; LOPES et al., 2021).

2.5.1. Principais técnicas de aferição da umidade do solo

Existem diversos meios para estimar umidade do solo *in situ*. Os métodos para determinar esta propriedade do solo podem ser classificados como diretos e indiretos (TEIXEIRA et al., 2017). Dentre as técnicas diretas, têm-se os métodos volumétrico e gravimétrico que tomam como base a relação entre a quantidade de água e o peso

de uma dada quantidade do solo seco (SCHOENEGER et al., 2012). O método gravimétrico é amplamente utilizado para representar a quantidade relativa de água no solo, o percentual de umidade na amostra em condição natural e instantânea. Ele consiste na retirada de amostras indeformadas de solo e posterior pesagem, antes e depois da secagem em estufa (normalmente a 105 °C) para determinação do conteúdo de água (TEIXEIRA et al., 2017). Com base nas alterações na massa do solo, o percentual de umidade é calculado por meio da Eq. 2.6, em que, M_a é a massa de água, M_t é a massa total e M_s é massa de solo seco.

$$US = \frac{M_a}{M_s} = \frac{M_t - M_s}{M_s} \quad (2.6)$$

As técnicas indiretas utilizam-se de sensores de contato e outras de sensores remotos para aferição da umidade do solo *in situ*. Esses sensores registram as propriedades dos solos de maneira instantânea, o que permite o monitoramento das variações da umidade no solo (MOHANTY et al., 2017). Esses métodos de estimativas da umidade do solo utilizam: a) radioatividade das substâncias na solução do solo; b) tensiometria, baseado na diferença de tensão da água entre os limites das fases; c) eletricidade das propriedades do solo como resistência, condutividade, indutância e capacitância; e d) eletromagnetismo, mediante a análise da reflectividade dos fluxos energéticos entre solo e fonte (LEÃO et al., 2021).

Além de sensores artificiais, existem avaliações da umidade dos solos realizadas por meio de métodos organolépticos que podem ser percebidas pelos sentidos humanos como tato e visão que podem estimar qualitativamente a umidade dos solos ao comparar amostras, por exemplo (SCHOENEGER et al., 2012).

A representação espacial corresponde a uma das principais limitações dos métodos de estimativas da umidade do solo. Nesse sentido, foram desenvolvidas outras formas de estimativas da umidade do solo de maneira indireta, as quais se

baseiam na medida de outras propriedades pedológicas, meteorológicas e geomorfológicas que posteriormente correlacionam-se com a umidade do solo medida *in situ*, como ocorre com o método eletromagnético com sensores remotos aéreos e orbitais (TEIXEIRA et al., 2017).

2.6. GEOTECNOLOGIAS APLICADAS AOS ESTUDOS PEDOLÓGICOS

As técnicas que envolvem aquisição, armazenamento, processamento e disponibilização de dados geospaciais são denominadas geotecnologias (REDDY, 2018). Esse conjunto de métodos, auxiliados por recursos computacionais, subsidiam a modelagem dos fenômenos naturais e artificiais do planeta Terra, bem como de outros corpos celestes que permitem um monitoramento mais eficiente dos alvos.

Nesse sentido, os métodos utilizados para representação do espaço geográfico surgiram com o início da cartografia moderna e foram potencializados pelos avanços na área da computação e advento das técnicas de sensoriamento remoto (WATERS, 2017). Esses recursos tecnológicos foram impulsionados pelo aumento da demanda global por dados e informações para o monitoramento estratégico, inicialmente com fins bélicos, dos recursos e fenômenos terrestres mediante observação e modelagem do ambiente (ALVES et al., 2015).

Geotecnologias como o Sistema Global de Navegação por Satélite (GNSS), sensoriamento remoto e cadeias de dados levantados em campo são exemplos de fontes para modelagem do ambiente. Quando estas técnicas são reunidas em um programa computacional, forma-se um Sistema de Informações Geográficas (SIG), que engloba etapas de coleta, armazenamento, processamento e análise de dados georreferenciados, bem como a produção de informação temática (WATERS, 2017).

2.6.1. Sistemas de informação geográfica

Os conceitos de SIG surgiram no século XVII com a cartografia, por meio dos estudos epidemiológicos integrados de John Snow na Inglaterra em 1854 (WATERS, 2017). Ao investigar as causas de um surto de cólera em Londres, Snow registrou os locais de incidência da doença em um mapa da cidade e concluiu que o foco estava associado a poços contaminados que foram isolados de maneira a cessar a proliferação da cólera (REDDY, 2018). A difusão dos SIGs foi ampliada a partir da década de 1960, com a liberação para a sociedade civil dos sistemas GNSS e popularização da internet (WATERS, 2017).

Em um ambiente de análise de dados geoespaciais, os SIGs correspondem a esquemas integrados de métodos que reúnem as geotecnologias. Desse modo, um SIG envolve algoritmos, equipamentos, metodologias, dados e pessoas (desenvolvedores e usuários), cujas informações são armazenadas em um banco de dados (ALVES et al., 2015; WATERS, 2017). A Figura 2.3 exibe a estrutura básica desta geotecnologia que integra os pilares conceituais de um SIG, que possibilita a coleta, armazenamento, processamento, análise de dados georreferenciados e produção e disponibilização de informação (REDDY, 2018).

Atualmente, os SIGs são dotados de uma vasta e complexa lista de algoritmos para processamento e análise de grandes volumes de dados geoespaciais, inclusive por computação em nuvem. As recentes melhorias nas interfaces gráficas e a disseminação de dados georreferenciados como imagens de satélite e mapas temáticos, contribuíram para a popularização dessa tecnologia. Sua aplicação pode ser vista em diversos setores como segurança, saúde, educação e áreas com escopo socioeconômico e ambiental como hidrologia, agricultura, exploração de petróleo, aptidão e uso do solo (WATERS, 2017).



Figura 2.3. Esquema básico de um sistema de informação geográfica. Fonte: Adaptado de Reddy (2018)

2.6.2. Processamento de dados geoespaciais

Um programa computacional baseado em SIG deve permitir o tratamento e disponibilização dos dados para diversas demandas. Dentro desses ambientes virtuais, os dados são submetidos a operações matemáticas e/ou estatísticas para alcançar objetivos definidos pelo usuário ou predeterminado por um procedimento padrão (REDDY, 2018). Os algoritmos de um SIG offline podem ser operados por meio da instalação do programa em um único computador ou mais de uma máquina, quando conectados por uma rede interna fechada (intranet) a um servidor, geralmente com maior capacidade de processamento (WATERS, 2017).

De maneira geral, um SIG pode ser executado ainda em modo online na rede mundial de computadores (internet) com a assistência de computação em nuvem, na qual diversos servidores processam uma parte dos dados, o que confere eficiência e celeridade aos procedimentos de execução dos algoritmos (REDDY, 2018).

Algumas plataformas de processamento de dados geoespaciais são executadas em modo online, os chamados SIG web, que possuem alta capacidade de processamento, pois tem suporte da computação em nuvem, o que confere eficiência nas operações de grandes volumes de dados (VITOLLO et al., 2015; AGRAWALI e GUPTA, 2017). Os dados de servidores, privados ou governamentais, são reunidos, filtrados e editados pelos usuários desenvolvedores (LAW, 2014). Há a possibilidade de disponibilização desses dados por meio de um portal próprio na internet para que o usuário final possa acessá-los ou armazená-los em computadores e dispositivos móveis, como exemplificado na Figura 2.4.

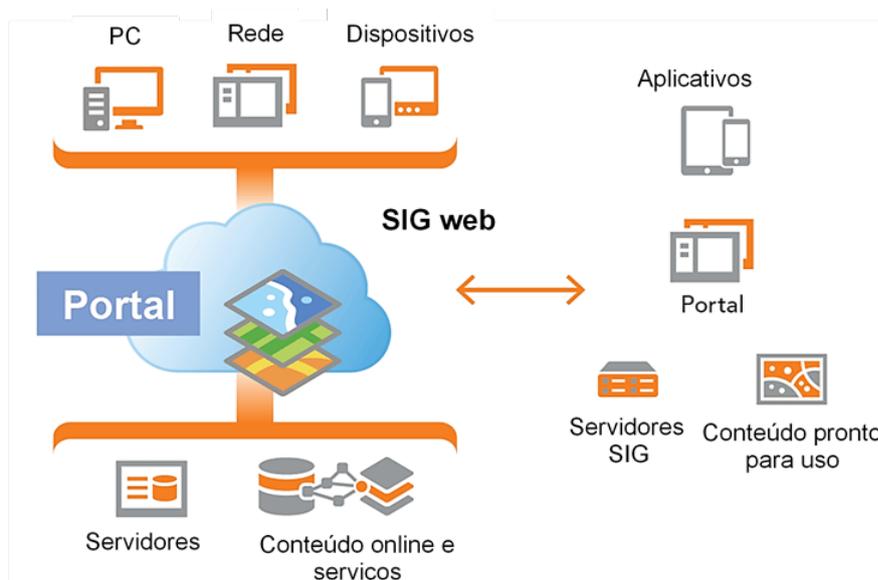


Figura 2.4. Esquema básico de um sistema de informação geográfica on-line. Fonte: Adaptado de Law (2014)

A plataforma digital Google Earth Engine (GOOGLE INC., 2021), segue alguns dos princípios de SIG web ao disponibilizar e processar dados das principais missões de sensoriamento remoto, o que permite, aos usuários, a elaboração de roteiros (*scripts*) em linguagem de programação nativa para os mais diversos fins. Os dados de sensoriamento remoto, em um contexto de geoprocessamento, exigem filtragens

para alcançar um conjunto homogêneo de bandas espectrais e parâmetros. Esses são inseridos em roteiros editados pelas empresas ou usuários, o que os torna imprescindíveis para o tratamento e análise de dados geoespaciais.

A vantagem dos SIGs offline é o controle dos processos executados, enquanto a desvantagem é a capacidade limitada de processamento da maioria dos computadores pessoais, o que prejudica a produtividade quando são executados algoritmos complexos que envolvam um volume extenso de dados (WATERS, 2017). Essas plataformas digitais podem conter códigos fechados que exigem aquisição de licença pessoal ou empresarial, como é o caso do ArcGIS® Desktop (ESRI, 2019). Por outro lado, o programa ENVI (HARRIS GEOSPATIAL SOLUTIONS INC., 2020) é voltado ao processamento digital de produtos de sensoriamento remoto. Existem ainda os SIGs de código fechado e acesso gratuito como o *Sentinel Application Platform* (SNAP) (ESA, 2021), para processamento de produtos Sentinel, mas que é capaz de tratar diversos tipos de dados.

Dentre os programas disponibilizados gratuitamente, há, por exemplo, o *System for Automated Geoscientific Analyses Geographic Information System* (SAGA GIS), dedicado a estudos hidrológicos e modelagem do terreno (CONRAD et al., 2015). O QGIS (QGIS DEVELOPMENT TEAM, 2002), por sua vez, opera de forma similar ao ArcGIS® com a vantagem de ser baseado em código aberto, que permite a inserção de funcionalidades via linguagem de programação (REDDY, 2018).

2.6.3. Modelagem de dados de sensoriamento remoto

A capacidade de predição de grandes volumes de dados tem aumentado com o avanço das tecnologias da informação (REDDY et al., 2018). Algoritmos cada vez

mais robustos, associados à rede mundial de computadores, são implementados para análises rápidas e acuradas de dados de várias naturezas (MILLER et al., 2017).

Técnicas de estatística como regressão e/ou classificação potencializam a capacidade de percepção humana da realidade, pois permite a antecipação ou recuperação de eventos e, dessa forma, a observação de tendências e padrões de comportamento dos dados para orientação, quanto a tomadas de decisão em diversos campos da ciência (HENGL e MACMILLAN, 2019).

2.6.3.1. Modelagem por aprendizado de máquina

O aprendizado de máquina, (do Inglês, *Machine Learning*) é um ramo da inteligência artificial e da ciência da computação que se concentra no uso de dados e algoritmos para imitar a forma como os humanos aprendem, o que melhora gradativamente a sua precisão (MILLER, 2017). Essa técnica utiliza-se de métodos lógicos e estatísticos em que os algoritmos são treinados para fazer classificações ou previsões de conjuntos de dados complexos.

Existem diversas técnicas de aprendizado de máquina que convergem com o seu principal objetivo, predição ou classificação de dados. O aprendizado de máquina clássico, de maneira geral, é categorizado pela forma como um algoritmo “aprende” para se tornar mais preciso nas previsões. Existem quatro abordagens básicas de aprendizado: supervisionada, não-supervisionada, semi-supervisionada e por reforço (MILLER, 2017; HENGL e MACMILLAN, 2019).

Aprendizagem supervisionada: o algoritmo recebe dados de treinamento rotulados (entrada) e mostra a resposta correta (saída). Esse tipo de algoritmo de aprendizagem usa resultados de conjuntos de dados conhecidos para prever valores de saída para novos dados de entrada (HENGL e MACMILLAN, 2019).

Aprendizagem não-supervisionada: o algoritmo recebe dados de treinamento que não são rotulados. Em vez de ser solicitado a prever a saída correta, esse tipo de algoritmo usa os dados de treinamento para detectar padrões que são aplicados a outros grupos de dados que exibem comportamento semelhante. Em algumas situações, é necessário usar uma pequena quantidade de dados rotulados com uma quantidade maior de dados não rotulados durante o treinamento. Esse tipo de treinamento é conhecido como aprendizado de máquina semi-supervisionado (HENGL e MACMILLAN, 2019).

Aprendizagem por reforço: em vez de receber dados de treinamento, o algoritmo recebe um sinal de recompensa que busca identificar padrões nos dados que atribuirão uma nota ou peso. Esse tipo de entrada é frequentemente derivado da interação do algoritmo de aprendizado com um ambiente físico ou digital, como descrito por Hengl e MacMillan (2019).

Quanto aos principais algoritmos de aprendizado de máquina, tem-se a regressão linear; regressão logística; árvore de decisão; máquina de suporte de vetor (*support vector machine*); álgebra Bayesiana; redes neurais; vizinho mais próximo (*k-NN*); *k*-média; *Random Forest*; algoritmos de redução de dimensionalidade como análise de componentes principais e análise hierárquica de grupos (MILLER, 2017).

2.6.3.2. Análise de regressão

De forma geral, uma correlação descreve a força de uma associação entre duas variáveis, com vistas à simetria dos dados. Se duas variáveis estão relacionadas, isso significa que quando uma variável muda para certo valor, a outra também mudará ou deveria mudar. Se y representa a variável dependente ou explicada e x , a variável independente ou explicativa, essa relação é descrita como regressão de y em x

(MILLER, 2017). Em estatística, a análise de regressão é uma forma de encontrar tendências nos dados de maneira a predizê-los, caso haja uma conexão entre um padrão e outro(s) (HENGL e MACMILLAN, 2019).

A análise de regressão quantifica este padrão por meio de equações e gráficos preditivos dos dados. Dessa forma, a equação de regressão representa o quanto y muda com qualquer alteração de x . Essa equação permite a determinação de uma linha de tendência em um diagrama de dispersão; no caso mais simples, trata-se de uma linha que quantifica a relação entre as variáveis (HENGL e MACMILLAN, 2019).

Quando há mais de uma variável independente, o método é conhecido como regressão linear múltipla (Eq. 2.7). De acordo com Hengl e MacMillan (2019), esse tipo de regressão é considerado um dos mais versáteis métodos de modelagem estatística multivariada, pois pode ser usado em diversas situações, porém, limita-se ao conjunto de dados em análise.

$$y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} \dots \beta_n X_{in} + \varepsilon \quad (2.7)$$

Em que y_i equivale à variável dependente; β_0 é o intercepto da inclinação da reta 1:1 em y (termo constante); $\beta_{1,2,3}$ são os coeficientes de inclinação de cada covariável; e ε , o termo de erro do modelo, conhecido como resíduo (MILLER, 2017).

Em resumo, a análise de regressão é uma forma de estatística inferencial na qual os valores de probabilidade (p) associados a cada variável determinam se as relações que uma determinada amostra apresenta podem representar a população como um todo. O valor p para cada variável independente testa a hipótese nula de que a covariável não tem correlação com a variável a ser predita. Caso não haja correlação, a associação entre as mudanças na variável independente e as mudanças na variável dependente é nula. Ou seja, não existem evidências suficientes para concluir que há um efeito daquela variável explicada (HENGL e MACMILLAN, 2019).

Vale ressaltar que, além do modelo linear, o ajuste dos dados pode ser realizado pelos métodos exponencial, polinomial, logarítmico, entre outros que se adaptarão aos objetivos e natureza dos dados. A Figura 2.5 exemplifica a dispersão de dados por meio de um modelo de regressão linear simples com a equação e coeficiente de determinação entre a variável dependente (índice de vegetação) e uma variável explicativa (precipitação pluviométrica) ao longo de um ano no DF.

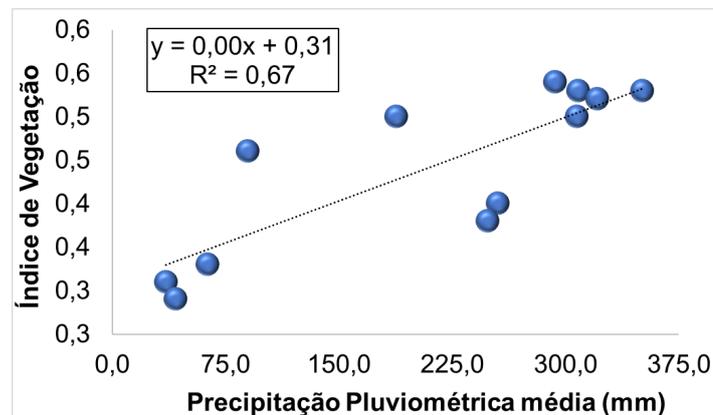


Figura 2.5. Gráfico de dispersão entre o índice de vegetação e média mensal de precipitação pluviométrica no Distrito Federal. Fonte: Elaborado pelo autor.

2.6.3.3. Modelagem por *Random Forest*

Random Forest (RF) é um algoritmo de aprendizagem de máquina que processa, de modo semi-supervisionado, um conjunto de dados para classificação ou regressão (BREIMAN, 2001). Esse método pode construir modelos de previsão por meio de árvores de decisão para fornecer estimativas mais acuradas que os métodos de regressão apresentados anteriormente. Ele se concentra em variáveis de treinamento e variáveis de teste para desenvolver as árvores de decisão independentes e obter a maior votação para definir a qual classe ou número cada árvore pertence (MILLER et al., 2017).

De acordo com Hengl e MacMillan (2019), o algoritmo RF é eficiente para classificação e moderado para regressão, pois depende de alta correlação entre as variáveis. No método, selecionam-se todas as colunas de variáveis significativas na raiz para todas as árvores de decisão. Os subconjuntos interdependentes são produzidos sob condicionantes de acurácia com penalizações ou recompensas, como nos métodos de aprendizagem por reforço (MILLER, 2017).

A técnica é geralmente associada a outros algoritmos, como o modelo que gera combinações (*ensembles*) entre as árvores e é treinada com o método *bagging* que potencializa a combinação dos modelos de aprendizado de forma a melhorar os resultados. Esse algoritmo de amostragem aleatória é usado na seleção das amostras na fonte dos dados (HENGL e MACMILLAN, 2019). Vale mencionar ainda o método de amostragem *bootstrap*, usado nas árvores, que realiza a seleção aleatória dos dados nas amostras fonte. Essas árvores não devem ser podadas, ou seja, interrompidas até que se defina a classe pertencente, e os nós ideais (relações entre os subconjuntos – folhas) são amostrados por meio do total de nós na árvore para formar o recurso de divisão ideal (HENGL et al., 2018). A Figura 2.6 esquematiza o funcionamento do algoritmo RF.

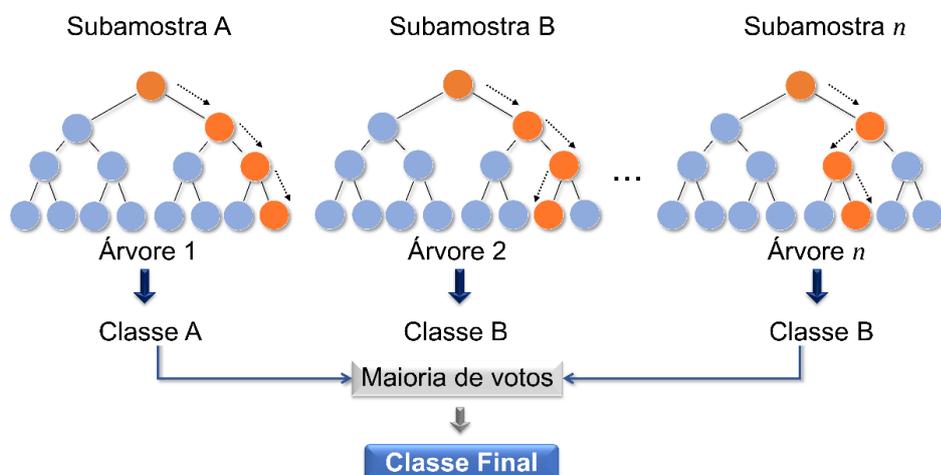


Figura 2.6. Esquema funcional do algoritmo *Random Forest*. Fonte: Elaborado pelo autor com base em Breiman (2001).

No entanto, é necessário decidir quais características são mais relevantes para a modelagem, pois, em aprendizagem de máquina, quanto mais variáveis explicativas disponíveis, maior a possibilidade de o modelo sofrer sobreajuste (*overfitting*). Nesse caso, algoritmos de redução da dimensionalidade das características explicativas são necessários (MILLER, 2017). Cada árvore cresce separadamente e a profundidade delas varia de acordo com a amostra que, ao final, a votação determinará a classe.

De acordo com Hengl e MacMillan (2019), para melhorar ainda mais a acurácia da modelagem RF, deve-se buscar a aleatoriedade e minimizar a correlação entre as covariáveis. Breiman (2001) mencionou algumas características deste procedimento: a) é relativamente robusto em relação à presença de *outliers* e ruído; b) consiste em um meio rápido de obtenção de classes; c) fornece estimativas de erro interno úteis para avaliação dos resultados como força, correlação e importância das covariáveis; d) possui execução simples; e e) facilita a interpretação dos resultados.

Por outro lado, o modelo construído ocupa uma grande quantidade de memória e opera mais lentamente que outros métodos, pois necessita iteragir com n árvores. No entanto, a capacidade de processamento e armazenamento de dados dos computadores modernos é suficientemente grande para essas tarefas. Outro aspecto é que o método *Random Forest* tem propensão ao sobreajuste, especialmente em conjunto de dados com muito ruído e baixa heterogeneidade (MILLER, 2017). Contudo, Hengl et al. (2018) relataram a irrelevância desse processo no algoritmo devido a inclusão de métodos de subamostragem como o *bootstrap*.

2.6.4. Sensoriamento remoto aplicado aos solos

Segundo Jensen (2009), o sensoriamento remoto é a tecnologia que permite a aquisição de informação, ao nível do terreno, aéreo ou orbital, sobre objetos ou

fenômenos, sem que haja o contato físico entre o sensor e o alvo. Meneses e Almeida (2019) definiram o sensoriamento remoto como a técnica de obtenção de dados e imagens da superfície terrestre por meio da detecção e da aferição quantitativa das respostas das interações nas várias faixas da radiação eletromagnética (REM) com os materiais terrestres. A Tabela 2.2 mostra a organização das faixas da REM por comprimento de onda, frequência e energia.

Tabela 2.2. Comprimentos de onda e frequências do espectro eletromagnético.

| Faixas da REM ¹ | Comprimento de onda (m) | Frequência (Hz) | Energia (eV) ² |
|----------------------------|---------------------------------------|---|---------------------------|
| Eletricidade | 5×10^5 | 50 – 60 | |
| Onda longa, televisão | $10^5 – 10^2$ | $< 3 \times 10^9$ | |
| Onda curta, rádio | $10^2 – 10^{-1}$ | $10^8 – 3 \times 10^9$ | $< 10^{-5}$ |
| Micro-ondas | $10^{-1} – 10^{-3}$ | $3 \times 10^9 – 3 \times 10^{12}$ | $10^{-5} – 10^{-2}$ |
| Luz infravermelha | $10^{-3} – 7 \times 10^{-7}$ | $3 \times 10^{12} – 3 \times 10^{14}$ | $10^{-2} – 2$ |
| Luz visível | $7 \times 10^{-7} – 4 \times 10^{-7}$ | $4,3 \times 10^{14} – 7,5 \times 10^{14}$ | 2 – 3 |
| Luz ultravioleta | $4 \times 10^{-7} – 10^{-9}$ | $7,5 \times 10^{14} – 3 \times 10^{17}$ | 3 – 10^3 |
| raios X | $10^{-9} – 10^{-11}$ | $3 \times 10^{17} – 3 \times 10^{19}$ | $10^3 – 10^5$ |
| Raios gama | $10^{-11} – 10^{-13}$ | $3 \times 10^{19} – 10^{21}$ | $> 10^5$ |
| Raios cósmicos | $10^{-13} – 10^{-20}$ | $10^{21} – 10^{25}$ | |

¹ REM = radiação eletromagnética; ² eV = elétron-volts; Fonte: Jensen (2009).

Atualmente, diversos sensores têm suprido as demandas por dados de observação da Terra e de outros astros com robustez e qualidade das informações (MINASNY e McBRATNEY, 2016). Nesse sentido, o sensoriamento remoto pode ser aplicado em diferentes ramos da ciência, dada a capacidade de registrar vários tipos de dados e em diferentes épocas, que possibilita a análise simultânea de dados relativos à interação dos vários fenômenos ao longo do tempo sobre grandes extensões de áreas (JENSEN, 2009).

Com relação aos estudos pedológicos, o sensoriamento remoto é utilizado nos três níveis de aquisição de dados (terrestre, aéreo ou orbital) e nas várias faixas de comprimento do espectro eletromagnético (MENESES e ALMEIDA, 2019). Diferentes

técnicas de processamentos de dados de SR realizam análises acerca da composição, cobertura, uso, geomorfologia, estrutura, cor, qualidade, umidade, entre outros atributos e propriedades dos solos (DEMATTÊ et al., 2016).

2.6.4.1. Espectroscopia de reflectância dos solos

As informações sobre os solos adquiridas pelo registro das variações do espectro eletromagnético relacionam-se aos diversos componentes pedológicos (HUNT e SALISBURY, 1970). Para associar observações remotas com propriedades dos solos, é necessária uma fundamentação sobre as interações da luz com a matéria. De acordo com Meneses e Almeida (2019), a REM que se propaga pelo vácuo apresenta dualidade do comportamento da natureza (onda e da energia) e é explicada pelos modelos ondulatório e corpuscular.

A radiância total refletida por um solo exposto é registrada por um sensor (L_t) em função de três fatores: a energia radiante refletida diretamente pela interface ar-solo (L_s), a energia radiante refletida pelo solo como espalhamento volumétrico (L_v) e a energia radiante refletida (espalhada) diretamente pela atmosfera (L_p). Esta relação é expressa pela Eq. 2.8:

$$L_t = L_p + L_s + L_v \quad (2.8)$$

Como consequência, a quantidade de fluxo radiante volumétrico, espalhado ou refletido de volta para a atmosfera (Figura 2.7), e ocorre em função do comprimento de onda (λ) da REM incidente, do tipo e da quantidade de constituintes orgânicos/minerais, da forma e da densidade dos minerais, da textura e estrutura e da quantidade de umidade de solo, por exemplo (MENESES e ALMEIDA, 2019).

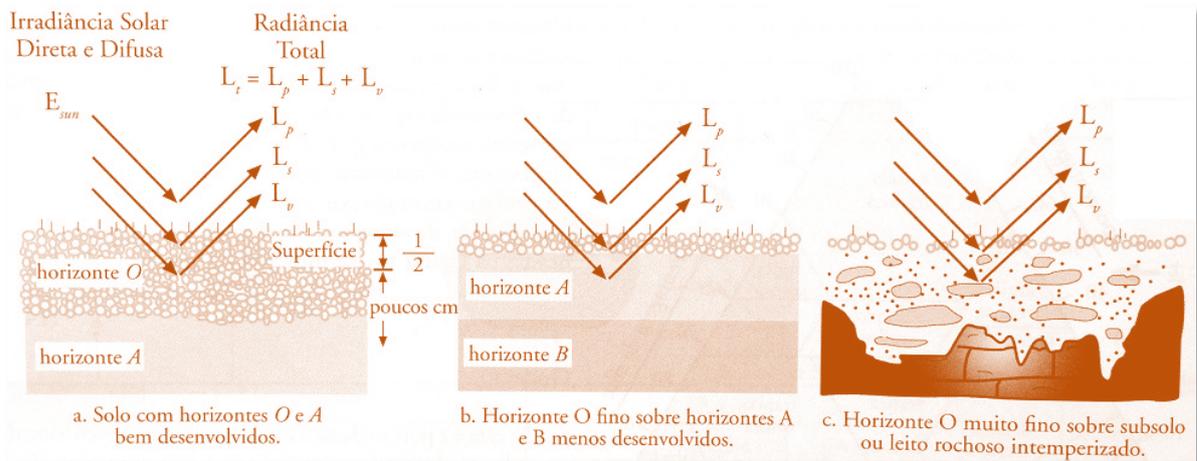


Figura 2.7. Componentes da radiação eletromagnética medida por um sensor imageador. Fonte: Adaptado de Jensen (2009).

Nesse sentido, uma parte da radiação solar direta, incidente sobre o solo exposto, é capaz de penetrar uns poucos milímetros ou até mesmo um ou dois centímetros na coluna do solo. Essa parte é refletida como espalhamento volumétrico (L_v). Com base no exposto, a energia refletida pelas superfícies equivale ao quantitativo energético incidente no solo, suprimida as porções absorvidas, transmitidas ou espalhadas (Eq. 2.9).

$$\rho\lambda(\%) = \frac{E_R(\lambda)}{E_I(\lambda)} \quad (2.9)$$

Em que a reflectância espectral $\rho\lambda$ (%) é função do comprimento de onda (λ) definida pela razão entre a energia refletida pelo objeto $E_R(\lambda)$ (radiância, $W\ m^{-2}\ sr^{-1}\ \mu m^{-1}$) e a energia incidente sobre o objeto $E_I(\lambda)$ (irradiância, $W\ m^{-2}\ \mu m^{-1}$).

2.6.4.2. Comportamento da reflectância espectral dos solos

O comportamento espectral do solo depende diretamente da composição química, física, biológica e mineralógica, como sólidos inorgânicos, matéria orgânica, ar e água, que interagem com a REM proveniente do Sol. Dessa forma, a assinatura

espectral do solo revela parte de sua composição, por meio da análise e interpretação da curva de reflectância espectral dos solos com observações e medições de bandas específicas de absorção do espectro (DEMATTÊ et al., 2014).

A cor do solo, por exemplo, é um atributo diagnóstico que pode ser analisado visualmente ou mediante técnicas de sensoriamento remoto para classificação e interpretação de solos (POPPIEL et al. 2019b). Esse atributo está relacionado com a composição mineralógica do solo (p. ex.: óxidos de ferro e minerais primários), conteúdo de matéria orgânica ou a umidade do solo (NOVAIS et al., 2021).

Geralmente, os óxidos de ferro, como a goethita (FeO-OH) e a hematita (Fe_2O_3), considerados minerais transopacos, ocorrem em solos de regiões intensamente intemperizadas, como os solos tropicais (KÄMPF e CURI, 2012). Esses componentes alteram as características químicas, físicas e morfológicas dos solos e, por conseguinte, influenciam no comportamento espectral (LACERDA et al., 2016).

Os óxidos de Fe apresentam bandas de absorção bem definidas, centradas em $0,53 \mu\text{m}$ para hematita e em $0,48 \mu\text{m}$ para goethita, e são mais intensas na presença de maiores teores de ferro (DEMATTÊ et al., 2014). Quando há a presença de minerais opacos, como magnetita e ilmenita, em geral, ocorrem baixas reflectâncias no visível e no infravermelho próximo, sem feições de absorção proeminentes desses compostos na curva espectral dos horizontes do perfil de solo (LIU et al., 2017).

Hunt e Salisbury (1970) relataram que há relação entre a cor dos solos tropicais, teor e tipo de óxidos de ferro, na qual a hematita e a goethita são os mais comuns. Assim, solos hematíticos são mais vermelhos, enquanto solos goethíticos, livres de hematita, proporcionam tons mais amarelados. O solo que apresenta os dois óxidos de ferro domina o vermelho da hematita (BAPTISTA et al., 2019; POPPIEL et

al., 2019b). A ausência de óxidos de ferro no solo confere cores acinzentadas, o qual indica um ambiente de redução, como observado por Novais et al. (2021).

No que se refere aos argilominerais mais comuns, os espectros da caulinita e da montmorillonita exibem feições de absorção intensas na região do infravermelho de ondas curtas (SWIR), centradas em 1,40 μm e 2,20 μm (LIU et al., 2020). A montmorillonita também possui água de constituição caracterizadas por duas fortes bandas de absorção em 1,9 μm e em 1,40 μm . Em compensação, solos com gibbsita ($\text{Al}_2\text{O}_3 \cdot 3\text{H}_2\text{O}$) exibem feições de absorção próximas de 1,55 μm e 2,30 μm , bem como feições relacionadas a água de constituição em 1,40 μm e 1,90 μm (HUNT e SALISBURY, 1970; LOBEL e ASNER, 2002).

De maneira geral, denomina-se matéria orgânica as misturas complexas de compostos de carbono, com características físicas e químicas variáveis. O acúmulo de substâncias húmicas escuras nos solos reduz o coeficiente de brilho e de cor, que se aproxima da coloração acromática (preto) (KÄMPF e CURI, 2012). De acordo com Demattê et al. (2014), a matéria orgânica é o principal responsável pela redução da reflectância na faixa espectral de 0,65 μm a 0,75 μm .

Dotto et al. (2018) ressaltaram que a presença de mais de 1,7% de matéria orgânica já oblitera as características espectrais dos óxidos de ferro. Esses autores também observaram que a remoção da matéria orgânica com peróxido de hidrogênio (H_2O_2), provoca um aumento da reflectância no intervalo de 0,35 μm a 2,50 μm e um aplainamento na forma dos espectros. Solos ricos em quartzo e pobres em matéria orgânica e óxidos de ferro apresentam alta reflectância (DEMATTÊ et al., 2014).

A textura (granulometria) e a estrutura do solo também exercem influência sobre a reflectância e demais propriedades (LACERDA et al., 2016). Solos de textura arenosa tendem a exibir maior reflectância que solos com textura mais fina por causa

da constituição mineralógica (rica em quartzo) e dos baixos teores de matéria orgânica, óxidos de ferro e menores teores de água (DEMATTÊ et al., 2014; 2018).

Desse modo, a diminuição no tamanho de partícula implica em um aumento da reflectância em solos de textura arenosa (COBLINSKI et al., 2020). Assim, Lacerda et al. (2016) relataram que, em algumas situações, o menor tamanho das partículas do solo, pode aumentar o albedo, pois partículas menores apresentam superfície mais uniforme, com número menor de poros para deter a luz incidente, enquanto uma maior granulometria cria superfícies mais irregulares, que provocam sombreamentos e, portanto, maior retroespalhamento interno da luz.

De acordo com Demattê et al. (2014), além dos atributos e propriedades dos solos citados anteriormente, a umidade do solo corresponde a um fator que afeta a reflectância por causa das bandas de absorção da água centradas em 0,76 μm , 0,97 μm , 1,19 μm , 1,45 μm e 1,94 μm e diminuição na intensidade do fator de reflectância tanto na região do espectro visível, quanto nos demais intervalos espectrais. É necessário ressaltar que essas bandas de absorção da água presentes nos solos não são detectadas pelos sensores devido a absorção da atmosfera nesses comprimentos de onda (MENESES e ALMEIDA, 2019).

Lobell e Asner (2002) analisaram os efeitos da umidade do solo sobre a reflectância. Dentre as propriedades investigadas por esses autores, a umidade do solo configurou um relevante parâmetro a ser considerado, principalmente entre os Luvisolos. Essa investigação identificou que a forma geral da curva de reflectância se manteve praticamente inalterada, enquanto a reflectância diminuiu à medida em que a umidade do solo aumentou, o que causou escurecimento do solo (Figura 2.8).

Com base nos resultados de Lobell e Asner (2002), é possível afirmar que a reflectância diminui em decorrência da absorção da energia eletromagnética inerente

à estrutura molecular da água. Assim, o comportamento espectral dos solos, registrado por sensores remotos, nos diferentes níveis de aquisição de dados, está sujeito, também, às variações na umidade presente no solo (DEMATTE et al., 2014).

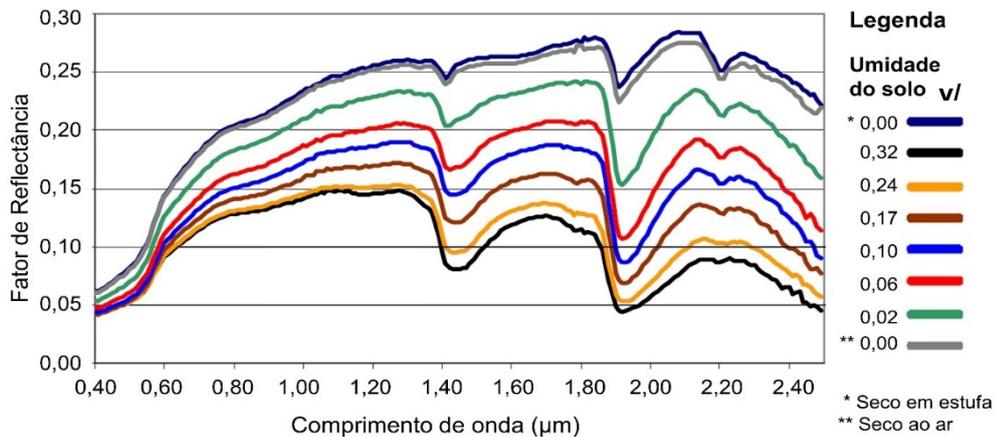


Figura 2.8. Reflectância espectral de um Luvissole com diferentes níveis de umidade.

Fonte: Adaptado de Lobell e Asner (2002).

2.6.4.3. Umidade do solo via dados de sensoriamento remoto

A qualidade do solo está intrinsecamente ligada ao teor de umidade, na qual essa propriedade pedológica confere um parâmetro a ser considerado em estudos ambientais, uma vez que o solo exerce influência direta nas trocas de água e energia na interface entre a superfície terrestre e atmosfera (TEIXEIRA et al., 2017). Como já mencionado, dentre as técnicas capazes de prever a umidade do solo, o sensoriamento remoto permite estimativas com a vantagem de captar dados nos domínios do espaço e do tempo (JENSEN et al., 2009).

Os métodos de medição *in situ* são pontuais, de difícil extrapolação para outras escalas. Em vista disso, as estimativas de umidade do solo por sensoriamento remoto têm sido consideradas promissoras, porém, com resultados relativamente insatisfatórios desde os primeiros estudos devido a interferência de vários fatores na resposta espectral relacionada a umidade do solo (BAGDHADI et al., 2012)

Apesar da utilização do sensoriamento remoto como uma via potencialmente adequada para investigações acerca da umidade do solo, as técnicas baseadas nessa ferramenta têm apresentado limitações, dentre as quais se destacam a interferência da vegetação, rugosidade do terreno e possibilidade de captura da variação da umidade do solo apenas em poucos centímetros de profundidade, a depender da frequência em que o sensor ativo opera (SANO et al., 2020). Pesquisadores utilizam estratégias diversificadas com base em dados de sensoriamento remoto para estimativas de umidade do solo nas faixas espectrais das micro-ondas (DOBSON e ULABY, 1986; SANO et al., 1998; ALEXAKIS et al., 2017; BAUER-MARSCHALLINGER et al., 2019; SEKERTEKIN et al., 2020), bem como no espectro óptico ou termal (YANG et al., 2015; ZHANG e ZHOU, 2016; WANG et al., 2018).

Desse modo, os métodos diretos e indiretos de medição da umidade do solo são, em muitos aspectos, complementares (HACHANI et al., 2019), pois os dados de sensoriamento remoto oferecem maior capacidade de cobertura espacial e temporal. Essa associação pode ser realizada desde que sejam considerados vários aspectos como o tipo de informação que o sensoriamento remoto oferece em termos de umidade do solo, observados os fatores que interagem com a energia eletromagnética (SANO et al., 2020). A seguir, é apresentado um breve panorama sobre o uso destas técnicas para estudos da umidade do solo, dividido em três subseções de acordo com a região do espectro de reflectância.

2.6.4.3.1. Umidade do solo na faixa óptica

Os sensores remotos que operam na faixa óptica do espectro (0,4 μm – 2,5 μm) conseguem capturar dados somente da superfície dos alvos, visto que a energia nessa faixa do espectro eletromagnético sofre diferentes processos de interação com

os compostos presentes nos materiais (MENESES e ALMEIDA, 2019). A utilização da reflectância da superfície nesta faixa do espectro eletromagnético, como medida direta da umidade do solo, é limitada devido à influência desses compostos nos espectros, porém, é útil para os modelos da interação entre solo, vegetação e atmosfera, baseados na transferência radiativa desse sistema (LOBELL e ASNER, 2002).

Nesse contexto, os componentes minerais e os comprimentos de onda utilizados condicionam a resposta espectral do solo de maneira a considerar a umidade do solo como fator de alteração do comportamento espectral (DEMATTE et al., 2014; 2018). A redução do fator de reflectância dos solos em função do aumento da umidade do solo devido a interação do espectro com as moléculas de água, representa um campo de estudo para investigações sobre a umidade do solo via sensoriamento remoto óptico (LOBELL e ASNER, 2002).

2.6.4.3.2. Umidade do solo na região de micro-ondas

A maioria dos modelos climatológicos e de balanço hídrico utilizam a umidade do solo como um dos parâmetros de entrada. Por isso, várias pesquisas são conduzidas na tentativa de estimar umidade do solo via sensoriamento remoto nas micro-ondas por modelos calibrados com dados de campo (MOHANTY et al., 2017).

Justificados pela capacidade de penetração nos solos (a profundidade máxima aproximada é a metade do comprimento de onda do sensor), sensores de radar são praticamente os únicos capazes de estimar umidade do solo remotamente, pois o retroespalhamento (σ°) apresenta relação linear ou logarítmica com o teor de água no solo, efeito da polarização da onda com a constante dielétrica das moléculas de água (SEKERTEKIN et al., 2018; 2020). As principais vantagens dessa abordagem referem-

se à maior cobertura espacial, consideradas as medidas *in situ* e a menor interferência dos componentes atmosféricos na captação dos dados (SANO et al., 2020).

Assim como ocorre em alguns dos métodos indiretos de medição *in situ* (*Time Domain Reflectometer* e sensores de capacitância), os sensores de micro-ondas passivos e ativos relacionam a constante dielétrica do solo com o conteúdo de água, isto é, um aumento na constante representa também um aumento na umidade do solo (MOHANTY et al., 2017). Os sensores de micro-ondas passivos (radiômetros) medem a emissão da superfície e os sensores ativos emitem pulsos eletromagnéticos que são retroespalhados pela superfície dos materiais. Esses, porém, são pouco utilizados devido a emissão de ondas pela Terra ser muito baixa (MENESES e ALMEIDA, 2019).

De acordo com Mohanty et al. (2017), as imagens de radar são sensíveis a variações no conteúdo de água presente nos solos e nas plantas, pois os materiais possuem diferentes constantes dielétricas (ϵ) que corresponde a uma propriedade física dos materiais relacionada com a capacidade de refletir REM incidente na faixa espectral de micro-ondas (JENSEN, 2009). Desse modo, solos úmidos refletem mais energia de micro-ondas do que solos secos, que absorvem mais a onda, que, por sua vez, dependem da constante dielétrica no solo (MOHANTY et al., 2017). A água pura possui constante dielétrica de 78,5, em uma temperatura de 25 °C, enquanto um solo seco possui constante dielétrica em torno de 2. Quando se aumenta o conteúdo de água nos solos, aumenta-se a ϵ , portanto, uma maior quantidade de radiação é retroespalhada (HACHANI et al., 2019). Por consequência, solos úmidos aparecem com tons mais claros em relação a solos secos em dados SAR.

Segundo Sano e Borges (2019b), a capacidade de interação das ondas eletromagnéticas na faixa de micro-ondas com o solo é influenciada pela presença de moléculas de água. Essas moléculas provocam um fenômeno de absorção da REM

que altera os valores das propriedades dielétricas do solo como a permissividade complexa. As moléculas de água, por influência das forças osmóticas e matriciais, se concentram ao redor das partículas de solo, como descrito por Weil e Brady (2019).

Análises realizadas por Dobson e Ulaby (1986) evidenciaram o papel da água presa dielectricamente nos solos. Como resultados, esses autores concluíram que: a) a permissividade complexa dos solos secos é independente da frequência na região de micro-ondas e depende da densidade do solo; b) a quantidade de água presa é controlada pela mineralogia e textura do solo (possui relação com a fração de argila do solo), que resulta em diferenças entre tipos de solos com relação à permissividade em um dado teor de umidade; e c) as oscilações dos teores de umidade preditas entre os diferentes tipos de solos são dependentes da frequência do sensor e são maiores nas frequências mais baixas (abaixo de 3 GHz), no qual os efeitos da salinidade efetiva de fluidos de solos exercem influência significativa.

Um dos desafios da técnica de estimativas de umidade do solo via dados SAR é minimizar os efeitos da rugosidade e da vegetação para maximizar a relação entre σ° e umidade do solo (SANO et al., 2020). O conteúdo de umidade do solo pode ser estimado com maior acurácia quando o terreno é desprovido de plantas e rochas e tem rugosidade superficial uniforme. Quando a biomassa é $> 0,5 \text{ kg m}^{-2}$ inviabiliza a separação das contribuições da umidade do solo e da vegetação no retroespalhamento do sinal SAR (JENSEN, 2009).

A sensibilidade do σ° à umidade do solo é inversamente proporcional ao teor de argila do solo (DOBSON e ULABY, 1986). Desse modo, Schmugge (1980) concluiu que a diferença de textura também pode ser inserida em modelos para expressar os valores de umidade do solo como um parâmetro para avaliar a capacidade de campo desses solos. Por fim, as abordagens que objetivem a estimativas da umidade do solo

baseadas em dados SAR, devem incluir as variáveis explicativas estatisticamente significantes nos modelos empíricos (MOHANTY et al., 2017).

Em uma modelagem da umidade do solo baseada em dados SAR devem ser observados os fatores que afetam o retroespalhamento como rugosidade do terreno (topografia e microrrugosidade) ângulo de incidência local e de visada, além da presença de vegetação e edificações. A redução da interferência desses fatores pode otimizar a modelagem e aumentar a acurácia das estimativas (SEKERTEKIN et al., 2020). Áreas com vegetação mais adensada, relevo movimentado ou aquelas regiões altamente antropizadas tendem a ser modeladas com maiores erros se comparado a solos expostos e planos devido a interferência dessas condições no retorno do sinal SAR (SANO et al., 2020).

2.6.4.3.3. Atributos do terreno em estimativas de umidade do solo

O relevo também influencia na pedogênese (McBRATNEY et al., 2003) e consequentemente nas características dos solos como a quantidade de água que o perfil pode comportar (KÄMPF e CURTI, 2012). Autores como Beven e Kirkby (1979) propuseram estimar a umidade do solo com base nos atributos do terreno. Essa informação pode ser obtida por um modelo digital do terreno (MDT).

Dados altimétricos de campo interpolados ou de interferometria de dados SAR são exemplos de fonte de dados para geração de um modelo digital de elevação (MDE) (BRAUN, 2021). As informações contidas nos MDE são úteis à avaliação morfométrica, tais como: declividade, hiposometria e diversos índices relacionados aos atributos do terreno, como: índice de posição topográfica (TPI), índice de rugosidade do terreno (TRI) e índice topográfico de umidade (TWI). O TPI (Eq. 2.10) compara a elevação de cada célula em um MDE para se obter a elevação média de

uma vizinhança especificada em torno dessa célula, padronizar as altitudes e viabilizar análises do relevo (WEISS, 2001).

$$TPI = z_0 - z \quad (2.10)$$

Em que *TPI* equivale à diferença entre a elevação no ponto central (z_0) e a elevação média (z) em torno dele dentro de um raio predeterminado (R).

De acordo com Weiss (2001), valores positivos de *TPI* indicam que o ponto central está localizado acima da média dos arredores, enquanto valores negativos indicam uma posição inferior à média. Os valores elevados de R mostram as unidades principais da paisagem como planícies e planaltos, ao passo que os valores baixos destacam características menores como vales e cumes que têm relação com a umidade do solo (GUTIÉRREZ et al., 2015).

O *TRI*, por sua vez, é uma técnica morfométrica desenvolvida por Riley et al. (1999) para expressar a diferença nos valores de elevação de uma célula central e das oito células imediatamente ao seu redor. Em seguida, eleva-se ao quadrado cada um dos oito valores de elevação para torná-los todos positivos e, ao final, calcula-se a média dos quadrados. O índice é obtido pela raiz quadrada dessa média (Eq. 2.11).

$$TRI = \sqrt{\sum(z_c - z_i)^2} \quad (2.11)$$

Em que, z_c é a elevação de uma célula central e z_i é a elevação de uma das oito células vizinhas ($i = 1, 2, \dots, 8$).

Não obstante, calculou-se o *TWI*, também conhecido como *TOPMODEL*, com base nos valores de elevação do *raster* de MDE e declividade, comumente utilizado em estudos hidrológicos (BEVEN e KIRKBY, 1979). O *TWI* é dado pela Eq. 2.12:

$$TWI = \ln \left(\frac{\alpha}{\tan \beta} \right) \quad (2.12)$$

Na qual α (área de captação específica) representa a área da encosta por unidade de comprimento, isto é, área acima de um certo contorno que contribui para o fluxo ao longo do contorno. De maneira geral, o TWI indica a quantidade de água que pode fluir em meio à superfície em direção à drenagem. Para dados de grade, o comprimento do contorno é equivalente ao espaçamento da grade, e $\tan\beta$ é a descendente local (BEVEN e KIRKBY, 1979). Alternativamente, esse índice pode ser calculado pela Eq. 2.13.

$$TWI = \log \left(\frac{\alpha}{T \cdot \tan\beta} \right) \quad (2.13)$$

Em que α corresponde à área de drenagem por unidade de comprimento de contorno; e T é a transmissividade lateral do solo, por esta razão, também conhecido como índice topográfico do solo (BEVEN e KIRKBY, 1979).

2.6.4.3.4. Principais missões SAR e estudos sobre a umidade do solo

Segundo a ESA (2021), as principais missões que utilizam os sensores ativos para estimativas da umidade do solo são: *Scanning Multichannel Microwave Radiometer* (SMMR), que funcionou de 1978 a 1987 com uma resolução espacial entre 27 km e 148 km; *Advanced Microwave Scanning Radiometer* (AMSR-E), que operou de 2002 a 2011 com resolução entre 38 km e 56 km; *Soil Moisture and Oceanic Salinity* (SMOS), lançado em 2009 com resolução espacial de 50 km; e *Soil Moisture Active and Passive* (SMAP), lançado em 2015 com resolução de 1 km a 9 km. Por outro lado, consideram-se os principais sensores ativos, na faixa das micro-ondas, o ERS-1 e o ERS-2, que operaram de 1991 a 2011, com resolução de 26 m; o RADARSAT-1 e RADARSAT-2, desde 1995, com resolução de 3 m a 1 km; e o ALOS-1 e ALOS-2, com uma resolução espacial de 3 m a 100 m (ESA, 2021).

A União Europeia lançou um projeto denominado Iniciativa de Mudanças Climáticas (CCI) (<https://climate.esa.int>), a qual disponibiliza, entre outras informações, um conjunto de dados de umidade do solo na profundidade de 0,5 cm a 2 cm, com resolução espacial de 0,25°, gerado por instrumentos espaciais de micro-ondas para um período de 32 anos (1978-2010) (ESA, 2021). O conjunto de dados ativos utilizados no CCI foi produzido por meio de observações dos escaterômetros da banda C, a bordo dos satélites ERS-1, ERS-2 e METOP-A. Os dados passivos foram obtidos com base em observações dos sensores Nimbus 7 SMMR, DMSP SSM/I, TRMM TMI e AMSR-E (ESA, 2021). Existem diversos outros sensores SAR orbitais multitarefa que são amplamente utilizados para as estimativas da umidade do solo, como os satélites da missão Sentinel (Sentinel-1A e Sentinel-1B), os quais serão apresentados de forma mais detalhada neste Capítulo.

Por meio dessas e de outras missões, pesquisas têm sido direcionadas para estimativas da umidade do solo mediante o uso de dados SAR pelas mais variadas técnicas de modelagem baseadas nas bandas: X (BAGHDADI et al., 2012; EL HAJJ et al., 2016; GARCÍA et al., 2016; SETIYONO et al., 2017), C (PALOSCIA, 2013; JACOME et al., 2013; BAUER-MARSCHALLINGER et al., 2019; BENNINGA et al., 2020) e L (ALEXAKIS et al., 2017; ZRIBI et al., 2019; DATTA et al., 2020; SEKERTEKIN et al., 2020).

Com o auxílio de dados SAR da banda C do satélite Sentinel-1 de diferentes épocas, Zhang et al. (2018) estimaram a umidade do solo em série temporal e observaram uma acurácia moderada para no mapeamento de umidade do solo, em escala de bacia hidrográfica sob diferentes usos, na China. Sekertekin et al. (2020) utilizaram o mesmo sensor para recuperar a umidade do solo e relataram que a umidade possui um efeito dominante sobre o retroespalhamento principalmente

próximos dos leitos dos rios em solos saturados, associados à baixa velocidade do fluxo d'água e proximidade do lençol freático com relação à superfície do solo.

Em uma análise da estimativa da umidade do solo com imagens SAR do sensor ALOS-2 (banda L) de uma série temporal contínua no sul da Austrália, Satalino et al. (2013) confirmaram a sensibilidade dos dados dessa faixa espectral às mudanças de umidade do solo, a qual indica baixos percentuais de erro na modelagem ao longo de mais de 270 observações. O mapa da estimativa da umidade do solo gerado por esses autores demonstrou o potencial de dados SAR para recuperar padrões espaciais desse atributo pedológico em áreas agrícolas não irrigadas.

2.6.5. O sistema Landsat

A série de satélites Landsat (*Land Remote Sensing Satellite*) teve início em 1966 com um projeto desenvolvido pelo governo americano dedicado à observação dos recursos naturais terrestres (USGS, 2020). A missão foi denominada inicialmente de *Earth Resources Technology Satellite* (ERTS) e somente em 1972 lançou seu primeiro satélite da série, o ERTS-1. Atualmente, o projeto encontra-se ativo e possui previsão de lançamento de outros sensores para continuidade da missão (Figura 2.9).

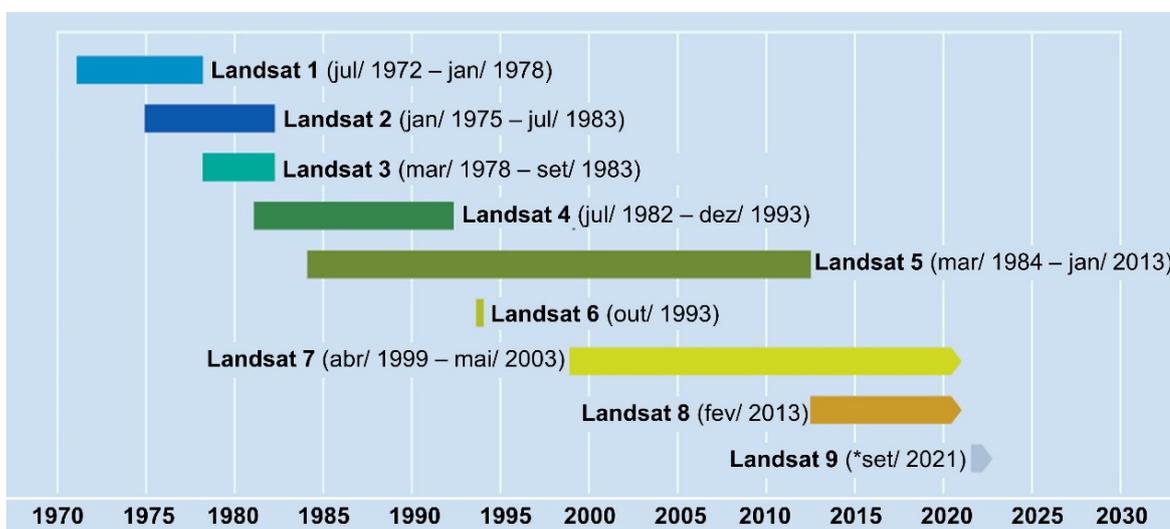


Figura 2.9. Linha do tempo da série de satélites Landsat. Fonte: USGS (2020).

Na Tabela 2.3, são exibidas as principais características dos sensores dos satélites da série Landsat (USGS, 2020). A série Landsat é dividida em grupos: o primeiro grupo é formado pelos satélites Landsat 1, Landsat 2 e Landsat 3, que operavam com os sensores *Multispectral Scanner* (MSS) e a câmera *Return Beam Vidicon* (RBV); o segundo grupo inclui o Landsat 4 e o Landsat 5, que carregavam os sensores MSS e *Thematic Mapper* (TM); o terceiro grupo era composto pelo Landsat 6 e Landsat 7 que utilizavam os sensores *Enhanced Thematic Mapper* (ETM) e o *Enhanced Thematic Mapper Plus* (ETM+), respectivamente; o quarto grupo é integrado pelo Landsat 8 e Landsat 9, esse último com lançamento previsto para 2021, de forma a garantir a continuação da missão Landsat.

Tabela 2.3. Informações gerais sobre a série de satélites Landsat.

| Satélite | Sensor | Altitude média (km) | Período orbital (min) | Resolução Temporal (dias) | Cruzamento pelo Equador (am) |
|------------------|------------|---------------------|-----------------------|---------------------------|------------------------------|
| LS1 | | | | | |
| LS2 | RBV/MSS | 917 | 103,34 | 18 | 9:30 |
| LS3 | | | | | |
| LS4 | | | | | |
| LS5 | MSS/TM | 705 | 98,20 | 16 | 9:45 |
| ¹ LS6 | ETM | 705 | 98,20 | 16 | 10:00 |
| LS7 | ETM+ | 705 | 98,20 | 16 | 10:00 |
| LS8 | OLI/TIRS | 705 | 98,20 | 16 | 10:00 |
| ² LS9 | OLI2/TIRS2 | | | | |

¹ Obs.: Landsat 6 não chegou a operar; ² Landsat 9 com previsão de lançamento em set. de 2021.

O principal objetivo do sistema Landsat é o monitoramento multiespectral em resolução espacial de 30 m da superfície da Terra. A missão Landsat tem fornecido o maior registro contínuo de dados de sensoriamento remoto de maneira gratuita a diversos campos de pesquisa (USGS, 2020). Esses estudos têm contribuído para o avanço do conhecimento sobre os fenômenos e interações que ocorrem na superfície terrestre desde o início das missões Landsat.

Por exemplo, Demattê et al. (2016; 2019), Poppiel et al. (2019a; 2019b; 2019c) e Novais et al. (2021) utilizaram dados multitemporais do Landsat e demonstraram o alto desempenho de técnicas de processamento de produtos de sensoriamento remoto multiespectral e dados de campo para mapeamentos pedológicos e de atributos dos solos. Qiu et al. (2019) testaram a capacidade que as séries temporais do Landsat possuem para expressar a dinâmica da superfície da Terra, no âmbito da atmosfera, cobertura vegetal, corpos d'água e ações antrópicas, entre outros. Outros estudos realizaram estimativas de umidade do solo por meio de índices de vegetação e bandas termais da série Landsat (ZHANG e ZHOU et al., 2016, YANG et al., 2015; WANG et al., 2018), o que demonstra a potencialidade dos dados Landsat.

2.6.6. Missões Sentinel

Desde o início dos anos 2000, a Agência Espacial Europeia (ESA), por meio da Comissão Europeia Copernicus, desenvolve o Programa Sentinel com o lançamento de satélites de observação da Terra, com o objetivo de substituir as missões mais antigas e encerradas como as missões ERS e Envisat (ESA, 2021). De acordo com Torres et al. (2012), as missões desse programa podem garantir a continuidade dos dados e evitar lacunas nos estudos durante a execução do programa. Cada missão Sentinel foca um aspecto diferente da observação da Terra, dentre as quais o monitoramento atmosférico, oceânico e terrestre, que geram dados úteis para as demandas nas esferas sociais, ambientais, econômicas e geopolíticas. As missões Sentinel são baseadas em constelações de dois satélites (A e B) que garantem menor intervalo de revisita e cobertura (ESA, 2021). Algumas informações dos satélites da missão Sentinel-1 e Sentinel-2 estão resumidas na Tabela 2.4.

Tabela 2.4. Características da constelação de satélites da missão Sentinel.

| Satélite | Sentinel-1A | Sentinel-1B | Sentinel-2A | Sentinel-2B |
|---|--------------------------|--------------------------|--------------------------|--------------------------|
| Lançamento | 03/04/2014 | 22/04/2016 | 23/06/2015 | 07/03/2017 |
| Local de Lançamento | Kourou (Guiana Francesa) | Kourou (Guiana Francesa) | Kourou (Guiana Francesa) | Kourou (Guiana Francesa) |
| Veículo Lançador | Soyuz | Soyuz | Vega | Vega |
| ¹ Órbita | P, HS | P, HS | P, HS | P, HS |
| Altitude | 693 km | 693 km | 786 km | 705 km |
| Inclinação | 98,18° | 99,2° | 98,5° | 98,20° |
| Duração da Órbita | 97,7 min | 97,2 min | 97,2 min | s.d. |
| ² Horário de Passagem | 6:00 P.M. | 6:00 P.M. | 10:30 A.M. | 09:45 A.M. |
| Período de Revisita | 12 dias | 12 dias | 5 dias | 5 dias |
| Vida útil Projetada | 12 anos | 12 anos | 12 anos | 12 anos |
| Instrumentos Sensores | SAR | SAR | SAR/ MSI | SAR/ MSI |

¹ P = Órbita Polar, Órbita HS = Heliosíncrona; ² Horário de passagem pelo equador.

Dados da missão Sentinel-1 e Sentinel-2 estão disponíveis na plataforma ESA/Copernicus, no site SciHub (<https://scihub.copernicus.eu/dhus>), ou em buscadores eletrônicos de dados geoespaciais ASF *data search* (<https://search.asf.alaska.edu>) e, ainda, via Google Earth Engine (<https://code.earthengine.google.com>) que processa grandes volumes de dados online por intermédio da computação em nuvem (GOOGLE INC., 2021).

Os satélites Sentinel-1A e Sentinel-1B foram lançados em 2014 e 2015, respectivamente, com sensor do tipo SAR (ESA, 2012a), seguidos pelos sensores multiespectrais do Sentinel-2A e Sentinel-2B, lançados em 2015 e 2017, respectivamente (ESA, 2012b) e pela constelação de dois satélites Sentinel-3A e Sentinel-3B, que foram lançados em 2016 e 2018 e transportam múltiplos instrumentos para observações dos oceanos, inclusive a topografia da superfície marítima (ESA, 2021).

O Sentinel-4 funcionará com uma carga útil dedicada ao monitoramento atmosférico a bordo do satélite Meteosat Terceira Geração-Sonda (MTG-S) em órbita geoestacionária sobre a Europa com previsão de lançamento entre 2023 e 2030. O Sentinel-5P também é dedicado a estudos da atmosfera, trata-se de uma carga útil a

bordo do satélite MetOp que monitora os gases e aerossóis que afetam a qualidade do ar e o clima. Por último, o Sentinel-6 carregará um altímetro de radar para o monitoramento da altura global da superfície do mar e climáticos (ESA, 2021).

2.6.6.1. Sentinel-1

O Sentinel-1 é composto por uma constelação de dois satélites independentes, o Sentinel-1A, em operação desde outubro de 2014, e o Sentinel-1B, em operação desde outubro de 2016. Mediante o fornecimento contínuo de dados SAR, com frequência de revisita aprimorada e cobertura global, o Sentinel-1 permite análises que exigem séries temporais mais amplas (ESA, 2012a; TORRES et al., 2012). O sensor remoto ativo a bordo do Sentinel-1 capta dados na faixa do espectro eletromagnético das micro-ondas, especificamente da banda C, em duas polarizações (VV e VH) e com periodicidade de 12 dias, ou de 6 dias, quando os dois satélites são considerados (Tabela 2.5).

Tabela 2.5. Especificações dos produtos obtidos pelo satélite Sentinel-1.

| Modo de aquisição | Tipo de Produto | Resolução Espacial | | ² NV | Cobertura espacial (km) | ³ AI (°) |
|-------------------|-----------------|---------------------|------------------------|-----------------|-------------------------|------------------------|
| | | ¹ Classe | Cel (m) | | | |
| SM | SLC | | 1,7 x 4,3 3,6 x 4,9 | 1 x 1 | 80 x 80 | 18,3–46,8 |
| | | FR | 9 x 9 | 2 x 2 | | |
| | GRD | HR | 23 x 23 | 6 x 6 | | |
| | | MR | 84 x 84 | 22 x 22 | | |
| IW | SLC | | 2,7 x 22 3,5 x 22 | 1 x 1 | 250 x 250 | 29,1–46,0 |
| | | HR | 20 x 22 | 5 x 1 | | |
| | GRD | MR | 88 x 87 | 22 x 5 | | |
| | | | | | | |
| EW | SLC | | 7,9 x 43 15 x 43 | 1 x 1 | 410 x 410 | 18,9–47,0 |
| | | HR | 50 x 50 | 3 x 1 | | |
| | GRD | MR | 93 x 87 | 6 x 2 | | |
| | | | | | | |
| WV | SLC | | 2,0 x 4,8 3,1 x 4,8 | 1 x 1 | 20 x 20 | 21,6–25,1 34,8–38,0 |
| | | MR | 52 x 51 | 13 x 13 | | |
| | GRD | | | | | |
| | | | | | | |

¹ Cel: tamanho das células; FR: *Full Resolution*; MR: *Medium Resolution*; HR: *High Resolution*; ² NV: Número de visadas; ³ AI: Ângulo de incidência. Fonte: ESA (2012a).

Os sensores a bordo desses dois satélites registram imagens em órbitas ascendente ou descendente, em quatro modos aquisição, *Stripmap* (SM), *Interferometric Wide Swath* (IW), *Extra Wide Swath* (EW) e *Wave* (WV) (ESA, 2012a). As imagens são disponibilizadas em diferentes níveis de processamentos: RAW, *Single Look Complex* (SLC) e *Ground Range Detected* (GRD). Os produtos em nível de processamento L1 GRD são projetados para o modelo elipsoide de referência (datum) WGS-84.

Os dados GRD possuem três resoluções: resolução total (FR), alta resolução (RH) e resolução média (MR) (TORRES et al., 2012). Em resumo, as cenas do Sentinel-1 possuem resoluções espaciais de 10 m, 25 m ou 40 m, duas polarizações e três modos de imageamento (ESA, 2012a). Tanto na plataforma Copernicus Hub quanto no GEE, os dados são, por definição, nomeados de acordo com os padrões de nomenclatura do Sentinel-1 (Figura 2.10).

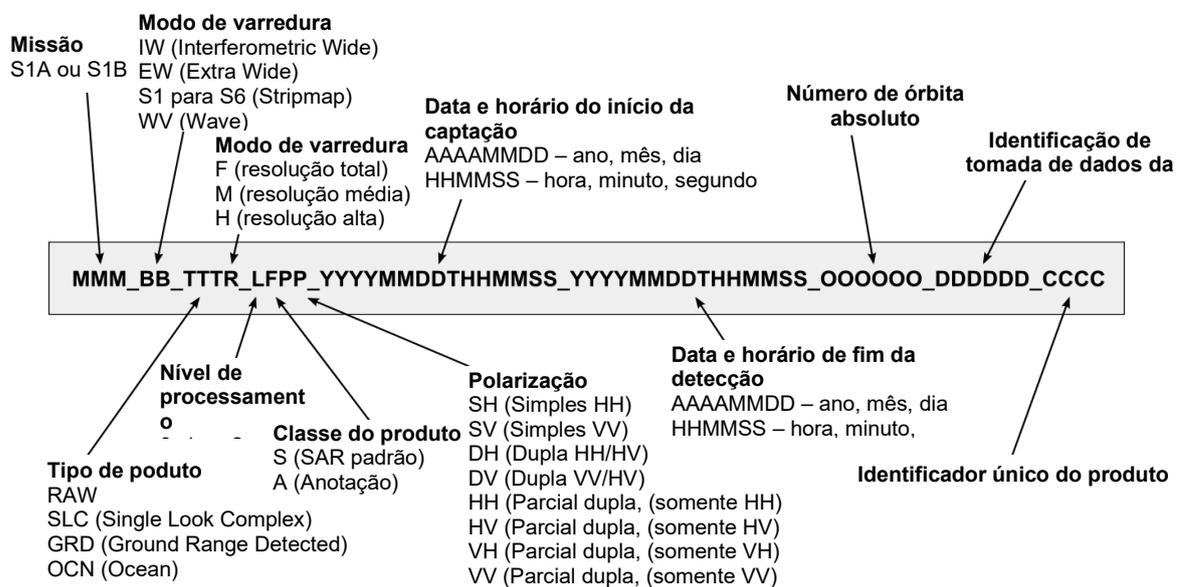


Figura 2.10. Padrão de nomenclatura dos dados Sentinel-1. Fonte: ESA (2021).

Os dados são gratuitos, o que os torna vantajosos para pesquisa e desenvolvimento de novas técnicas ou aprimoramento de métodos já existentes (SANO et al., 2020). Como mencionado, uma das formas de aquisição dos dados

Sentinel-1 é via linguagem de programação na plataforma de dados geoespaciais *Google Earth Engine*. De acordo com informações disponíveis em Google Inc. (2021), os dados SLC do Sentinel-1 ainda não podem ser processados no ambiente virtual do GEE, pois a plataforma atual não suporta imagens com valores complexos devido à impossibilidade de calculá-los durante a construção da pirâmide, sem perder as informações de fase. Assim, apenas os dados GRD são disponibilizados.

2.6.6.2. Sentinel-2

A série Sentinel-2, composta pelos satélites Sentinel-2A e Sentinel-2B, opera no espectro óptico do visível ao infravermelho de ondas curtas, com 13 bandas multiespectrais. Os dois satélites dispõem de uma resolução temporal de 5 dias e resolução espacial de 10 metros no visível e infravermelho próximo (ESA, 2012b). Os dados do Sentinel-2, disponíveis desde junho de 2015, que atendem aos estudos sobre a dinâmica da Terra. A Figura 2.11 esquematiza o posicionamento das bandas espectrais dos sistemas sensores.

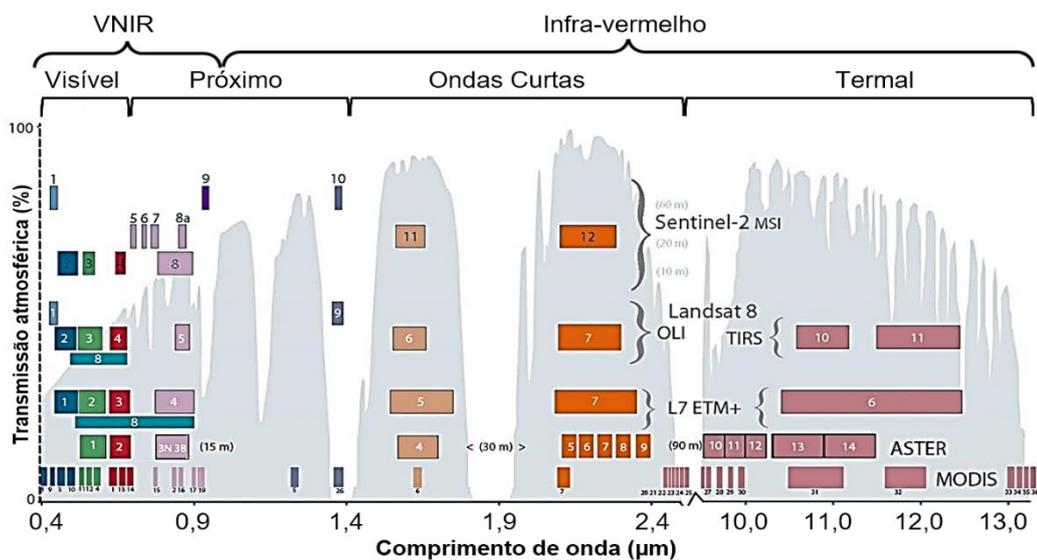


Figura 2.11. Posição das bandas espectrais de alguns dos sistemas sensores multiespectrais espaciais. MSI: *Multispectral Imager*; OLI: *Operational Land Imager*; TIRS: *Thermal Infrared Sensor*; ETM+: *Enhanced Thematic Mapper Plus*. ESA (2021).

As especificações do sensor multiespectral do Sentinel-2A (Tabela 2.6) têm levado os pesquisadores a utilizar os dados Sentinel-2 para investigações sobre os solos (GAO et al., 2017; ZHANG et al., 2020; STROMANN et al., 2020; NOVAIS e LACERDA, 2021). Esses autores relataram a versatilidade e qualidade desses dados, especialmente na região da borda do vermelho e infravermelho de ondas curtas, faixa espectral que contém a maioria das feições de absorção da reflectância relacionadas à mineralogia do solo (DEMATTÉ et al., 2014).

Tabela 2.6. Características das bandas do sensor Sentinel-2 *Multispectral Imager*.

| Banda | Faixa espectral | Comprimento de onda central (µm) | Resolução espacial (m) |
|-------|---------------------------------|----------------------------------|------------------------|
| 1 | Aerosol Costal | 0,443 | 60 |
| 2 | Azul | 0,490 | 10 |
| 3 | Verde | 0,560 | 10 |
| 4 | Vermelho | 0,665 | 10 |
| 5 | Borda do vermelho 1 | 0,705 | 20 |
| 6 | Borda do vermelho 2 | 0,740 | 20 |
| 7 | Borda do vermelho 3 | 0,783 | 20 |
| 8 | Infravermelho próximo | 0,842 | 10 |
| 8A | Infravermelho próximo | 0,865 | 20 |
| 9 | Vapor de água | 0,945 | 60 |
| 10 | Infravermelho de ondas curtas | 1,375 | 60 |
| 11 | Infravermelho de ondas curtas 1 | 1,610 | 20 |
| 12 | Infravermelho de ondas curtas 2 | 2,190 | 20 |

Fonte: Adaptado de ESA (2012b).

2.6.2.2.1. Sentinel-2 para estudos da vegetação

A vegetação desempenha um papel crucial – mas amplamente imprevisível – nas mudanças ambientais globais devido à multiplicidade de processos contribuintes em escalas espaciais e temporais amplamente diferentes. Nessa perspectiva, abordagens que levem em consideração os princípios que restringem o comportamento da planta e do ecossistema, auxiliam na compreensão dessa complexidade para análises da dinâmica da vegetação (NOVAIS e LACERDA, 2021).

A resolução espectral do Sentinel-2 permite, entre outras operações de bandas, o cálculo do índice de vegetação por diferença normalizada (NDVI) (STROMANN et al., 2020). Esse índice é utilizado amplamente para estudos da cobertura vegetal em todo o mundo desde a década de 1970, quando foi proposto por Rouse et al. (1974).

A dedução do NDVI (Eq. 2.14) partiu do comportamento espectral do pigmento das folhas das plantas, a clorofila, que absorve fortemente a luz visível (de 0,4 µm a 0,7 µm) para uso na fotossíntese. A estrutura celular das folhas, por outro lado, reflete fortemente a luz infravermelha próxima (de 0,7 µm a 1,1 µm) (ROUSE et al., 1974).

$$NDVI = \frac{\rho_{NIR} - \rho_{red}}{\rho_{NIR} + \rho_{red}} \quad (2.14)$$

Em que *red* e NIR representam os comprimentos de onda da reflectância nas regiões do vermelho e infravermelho próximo, respectivamente. Por definição, o NDVI varia entre -1,0, áreas sem vegetação e +1,0, áreas vegetadas (GAO et al., 2017).

Como exemplo da capacidade desse algoritmo em categorizar a vegetação, a Figura 2.12 exhibe o NDVI Sentinel-2 do DF registrado em setembro de 2020, época de estiagem, no qual se observa áreas sem vegetação como corpos hídricos, urbanizações e solos expostos, áreas pouco vegetadas como campos e pastagens, e áreas densamente vegetadas como matas de galerias, silvicultura e vegetação natural densa de Cerrado, como descrita por Sano et al. (2019).

O NDVI tem sido utilizado para diversos fins. Por exemplo, Demattê et al. (2018), Poppiel et al. (2019a; 2019b) e Novais et al. (2021) executaram esse algoritmo para filtrar as feições de vegetação abaixo dos índices que caracterizam solos expostos para modelagem multiespectral. Gao et al. (2017), por sua vez, utilizaram dados dos satélites Sentinel-1 e Sentinel-2 para estimar a umidade de solos a uma resolução de 100 m e relataram forte correlação entre NDVI e umidade de solos

medida em campo. Mohanty et al. (2017) reforçaram esta constatação e atribuíram ao microclima criado sobre os dosséis em vários estratos. Datta et al. (2020) também relataram esses fatores e identificaram a influência de áreas irrigadas sobre os resultados de NDVI e a umidade do solo.

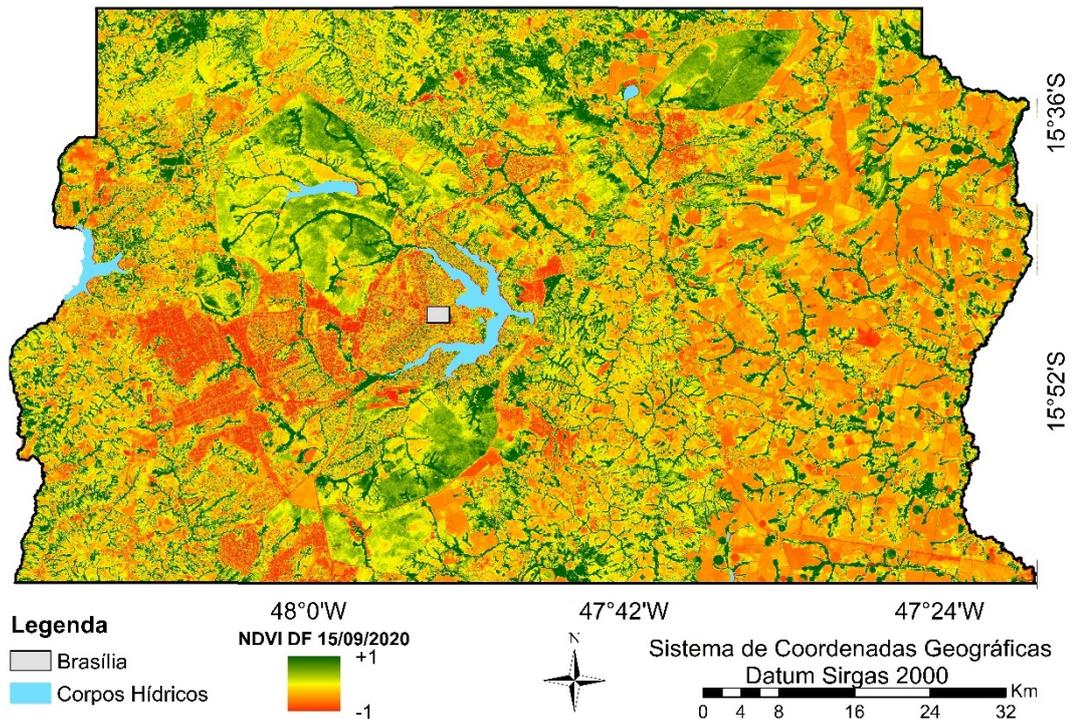


Figura 2.12. Índice de vegetação do Distrito Federal de setembro de 2020. Fonte: Elaborado pelo autor em ambiente Google Earth Engine com dados ESA (2021).

CAPÍTULO 3

CARACTERIZAÇÃO DO MEIO FÍSICO DO DISTRITO FEDERAL

3.1. ÁREA DE ESTUDO

O Distrito Federal (DF) está localizado entre as latitudes $-15^{\circ}34'$ a $-16^{\circ}20''$ e as longitudes $-47^{\circ}20'$ a $-48^{\circ}10'$ (Figura 3.1). Na região Centro-Oeste do Brasil, o DF ocupa a porção centro-leste do estado de Goiás e insere-se no domínio geomorfológico do Planalto Central do Brasil (CODEPLAN, 2020a). A região do DF está incluída na Plataforma de Aplainamento Sul-Americana, a qual, junto à Plataforma da Patagônia e à Cordilheira dos Andes, constituem o Continente Sul-Americano (KING, 1956).

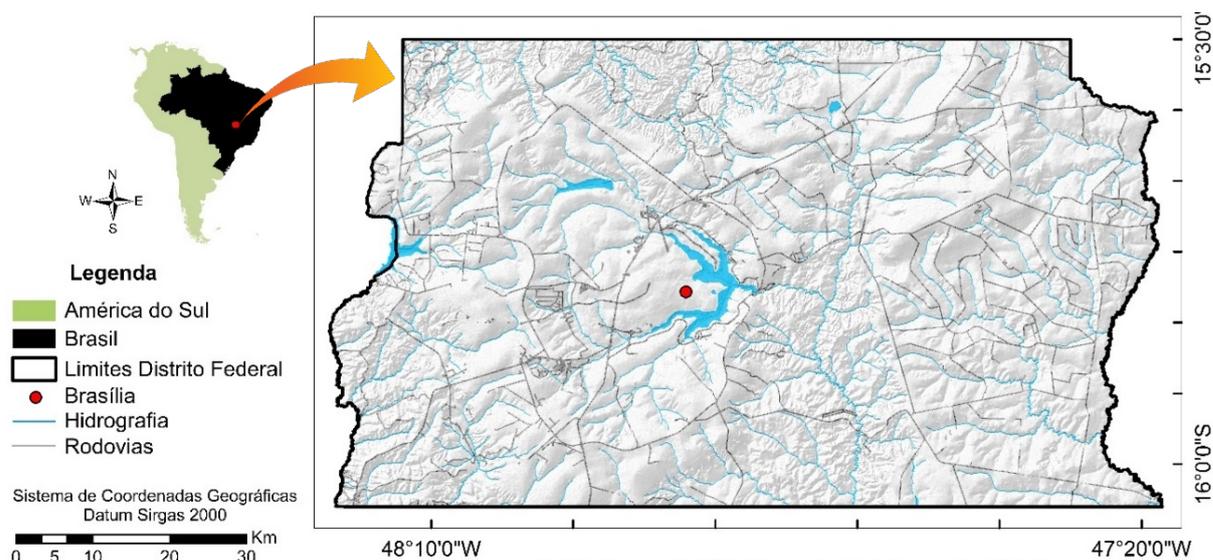


Figura 3.1. Mapa de localização do Distrito Federal. Elaborado pelo autor com dados de IBGE (2017) e CODEPLAN (2020a).

Segundo dados do IBGE (2017), o DF possui área territorial de 5.760,784 km². Com uma população estimada em aproximadamente 3 milhões de habitantes, o DF é constituído por 33 regiões administrativas (RA) (CODEPLAN, 2020a). Apresenta,

como limites naturais, o Rio Descoberto, a oeste, e o Rio Preto, a leste. As fronteiras norte e sul são representadas por linhas retas paralelas que definem o polígono correspondente ao território legal (IBGE, 2017).

O DF é circundado por municípios do estado de Goiás, exceto na parte sudeste, que possui um pequeno trecho que faz fronteira com o município de Cabeceira Grande, no estado de Minas Gerais. A região configura uma Região Integrada de Desenvolvimento Econômico (RIDE), que consiste em ações conjuntas de interesses socioeconômico e ambiental na região metropolitana do DF (CODEPLAN, 2020a).

Nesse sentido, parte da economia do DF é voltado para o setor agropecuário. Essas atividades inclui o DF como fronteira agrícola do país, pois possui números expressivos de produtividade no âmbito da agropecuária, sobretudo no leste do DF, na bacia do Rio Preto. A produção de grãos (café, feijão, milho, soja, sorgo, trigo e outros) superou mais de 760 mil toneladas em 2020, com produtividades superiores à média nacional. Além disso, o DF também se sobressai na produção de frutas e hortaliças, principalmente para o mercado interno. A produção de proteína animal também é relevante, com destaque para a produção de carne bovina, suína, aves e piscicultura, em menor escala (EMATER-DF, 2020).

3.2. CLIMA

De acordo com Silva et al. (2017), a região apresenta clima tropical, marcado pela sazonalidade, com duas estações bem definidas, chuvosa no verão e seca no inverno (Figura 3.2). Nas áreas com cotas altimétricas entre 1.000 m e 1.200 m, predomina o clima tropical de altitude do tipo Cwa (inverno seco e verão quente) (ALVARES et al., 2013). Já as áreas que possuem cotas superiores a 1.200 m, predomina o clima tropical de altitude do tipo Cwb (inverno seco e verão temperado).

Segundo os dados pluviométricos de 30 anos da estação meteorológica da Embrapa Cerrados em Planaltina, DF, a média anual de precipitação oscila entre 1.200 mm a 1.800 mm. A estação chuvosa vai de outubro a abril, enquanto a estação seca estende-se aproximadamente de maio a setembro (SILVA et al., 2017).

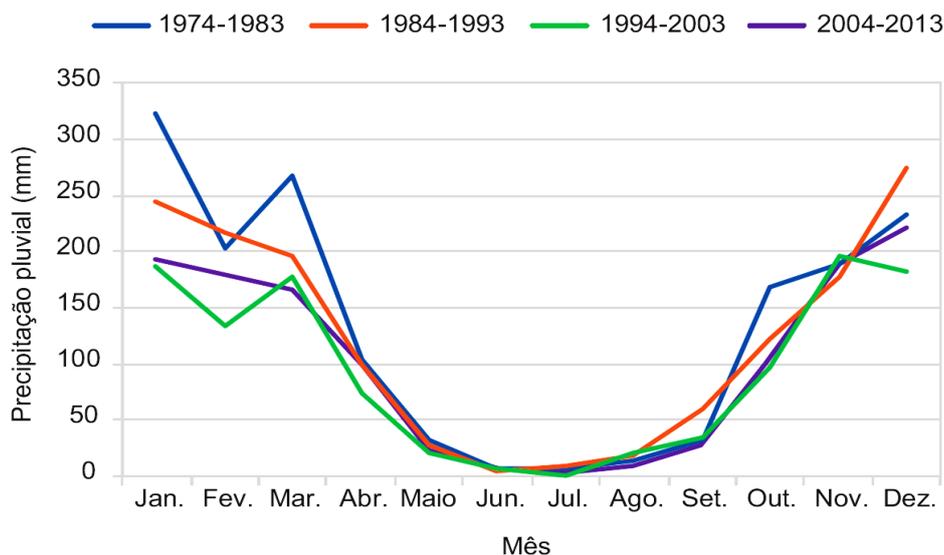


Figura 3.2. Média mensal de precipitação pluviométrica (mm) do Distrito Federal no período de 1974 a 2013. Fonte: Adaptado de Silva et al. (2017).

3.3. VEGETAÇÃO, USO E OCUPAÇÃO DAS TERRAS

O DF está inserido no domínio morfoclimático do Cerrado, com extensos chapadões recobertos por vegetação nativa em áreas preservadas com alta biodiversidade. As fitofisionomias são controladas por condições pedomorfogeológicas e climáticas específicas que favorecem a diversidade de ocorrência de espécies naturais (SANO et al., 2019).

Campos (2011) afirmou que a região apresenta importantes unidades de conservação da fauna e da flora, representadas pelo Parque Nacional de Brasília, Estação Ecológica de Águas Emendadas, Área de Proteção Ambiental do Planalto Central, além de mais de outras 100 áreas de preservação ambiental. Ribeiro e Walter

(2008) identificaram 25 fitofisionomias no Cerrado, distribuídas em três formações vegetacionais: 1) florestais (Mata Ciliar, Mata de Galeria, Mata Seca e Cerradão); 2) savânicas (Cerrado sentido restrito, Parque de Cerrado, Palmeiral e Vereda); e 3) campestres (Campo Sujo, Campo Limpo e Campo Rupestre). A maioria dessas formações são encontradas no DF.

A Figura 3.3 exibe o mapa da cobertura vegetal e uso do solo do DF em 2020 na escala de 1:25.000 elaborado pela Secretaria do Meio Ambiente do DF (SEMA, 2021), com recursos do Projeto CITInova. Esse material está previsto para ser atualizado anualmente para um monitoramento da dinâmica das atividades antrópicas e das principais no DF (Figura 3.3).

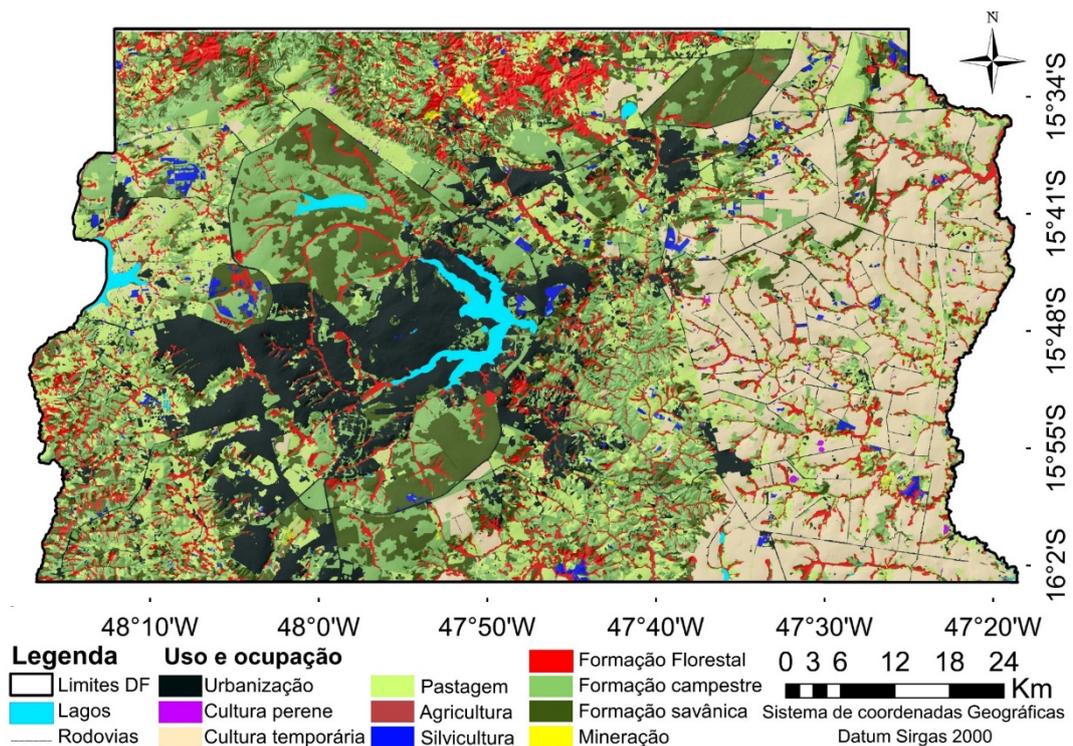


Figura 3.3. Mapa da cobertura vegetal e uso do solo do Distrito Federal. Fonte: Adaptado de SEMA (2021).

As áreas de cada classe de uso ocupação e vegetação do DF são contabilizadas na Tabela 3.1 para o ano de 2020, o qual demonstra que 48% da área esteve coberta por vegetação natural de Cerrado em suas várias fitofisionomias.

Tabela 3.1. Áreas referentes à cobertura vegetal e uso do solo do Distrito Federal.

| Classes de vegetação e uso do solo | Área | |
|------------------------------------|-------------------|---------------|
| | ha | % |
| Água | 6.051,93 | 1,05 |
| Urbanização | 85.545,50 | 14,82 |
| Cultura perene | 1.135,40 | 0,20 |
| Cultura temporária | 104.176,00 | 18,05 |
| Pastagem | 96.972,90 | 16,80 |
| Agricultura | 534,03 | 0,09 |
| Silvicultura | 5.852,83 | 1,01 |
| Formação florestal | 57.457,50 | 9,95 |
| Formação campestre | 120.155,00 | 20,81 |
| Formação savânica | 98.548,30 | 17,07 |
| Mineração | 867,78 | 0,15 |
| Total | 577.297,00 | 100,00 |

Fonte: Adaptado de SEMA (2021)

Diante do exposto, observa-se que o DF combina áreas preservadas com regiões de forte antropização (CODEPLAN, 2020a). A dinâmica de ocupação é condicionada pelo relevo (NEVES et al., 2018). Áreas urbanas e agricultura intensiva geralmente estão alocadas em relevo plano por causa das limitações tecnológicas impostas por terrenos declivosos para as atividades antrópicas (NOVAIS e LACERDA, 2021). Já as áreas com vegetação natural concentram-se em regiões de declive acentuado, exceto as áreas de proteção ambiental consolidada que, por força de leis, encontram-se preservadas (NEVES et al., 2018).

O vigor da vegetação segue as variações provocadas pela sazonalidade climática do Cerrado que também condiciona as práticas agrícolas. A Figura 3.4 exibe a curva pluviométrica média de 30 anos (INMET, 2020) comparada com a evolução do índice de vegetação por diferença normalizada (NDVI) médio, que decresce nos meses de estiagem (abril a setembro) e volta a subir nos meses em que as chuvas retornam a partir de outubro, com fechamento do ciclo chuvoso em março, como observado por Silva et al. (2017).

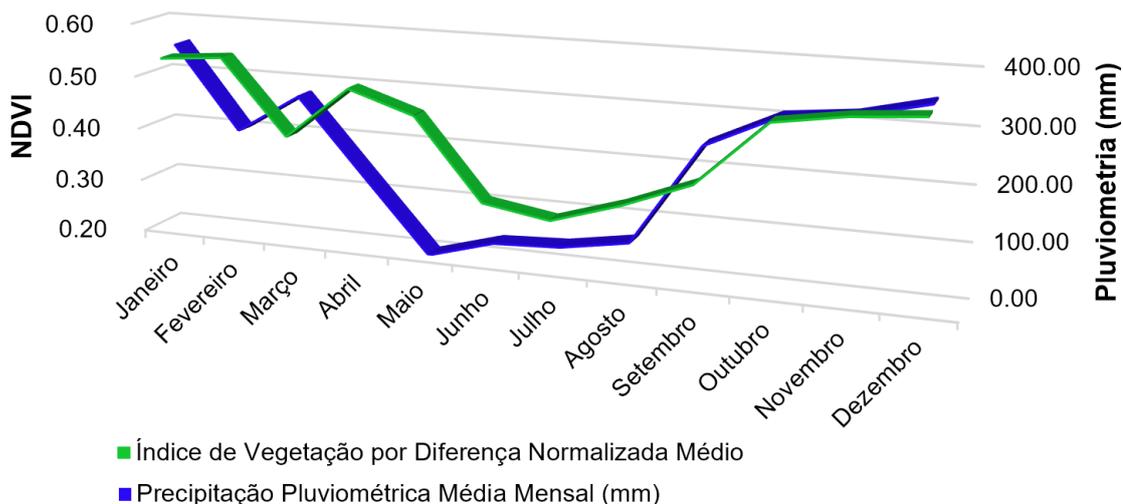


Figura 3.4. Pluviosidade média mensal e o correspondente índice de vegetação por diferença normalizada do Distrito Federal. Fonte: INMET (2020); ESA (2021).

3.4. RECURSOS HÍDRICOS

Conforme o levantamento realizado por Campos (2011), a região é centrada nas chamadas terras altas do Brasil Central, cujo fluxo fluvial abastece três das maiores bacias hidrográficas brasileiras: Paraná, Tocantins/Araguaia e São Francisco (IBGE, 2017; CODEPLAN, 2020a; 2020b). Essas estão divididas em sete subunidades, as quais são caracterizadas a seguir e ilustradas na Figura 3.5:

- **Bacia do Rio Descoberto:** Localizada a oeste do DF, tem o Rio Descoberto como limite territorial com o estado de Goiás. Essa subunidade é altamente populosa e contém uma barragem responsável por 60% do abastecimento de água no DF.
- **Bacia do Rio São Bartolomeu:** Com maior extensão no DF, essa região localiza-se na parte central e abrange as RA de Planaltina, Paranoá, São Sebastião e Santa Maria e se destaca pela paisagem dissecada.
- **Bacia do Lago Paranoá:** Localizada no centro do DF, essa microbacia comporta as RA: Guará, Lago Sul, Lago Norte e Brasília. Nessa existem dois importantes reservatórios de água: o Lago Paranoá e o Lago Santa Maria.

- Bacia do Maranhão: Situada na porção norte do DF, esta subunidade hidrográfica compreende parte das RA Brazlândia, Planaltina e Sobradinho. Caracterizada pelo relevo movimentado e áreas de vegetação preservada.
- Bacia do Rio Preto: Na porção leste do DF, tem o Rio Preto como limite entre os estados de Goiás e Minas Gerais. Caracteriza-se pela forte presença de agricultura intensiva sob sistema de Plantio Direto (SPD).
- Bacia do Rio São Marcos: Situada à sudeste, esta microbacia possui a menor área de abrangência no território do DF.
- Bacia do Rio Corumbá: Esta unidade hidrográfica compreende a parte sudoeste do DF nas RA Samambaia, Recanto das Emas, Gama e Santa Maria. Destaca-se nesta área a alta declividade e áreas de preservação ambiental.

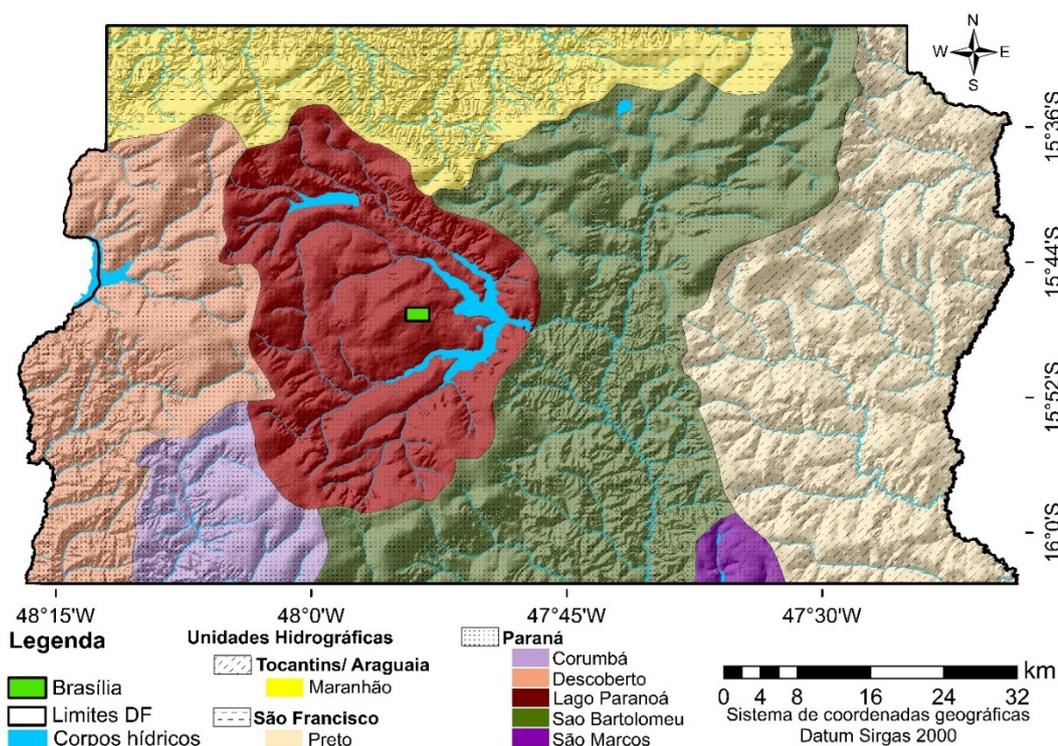


Figura 3.5. Mapa de unidades hidrográficas do Distrito Federal. Fonte: Adaptado de CODEPLAN (2020a).

A tabela 3.2 demonstra que cerca de 64% do território do DF está sob influência da bacia do Paraná e, por outro lado, apenas 13% abastece o complexo Tocantins/

Araguaia. Dentre as subunidades, a bacia do Rio São Bartolomeu ocupa uma área de mais de mil e quinhentos quilômetros quadrados, ou seja, 27,44% do território do DF.

Tabela 3.2. Áreas das unidades hidrográficas do Distrito Federal.

| Bacia Hidrográfica | Área | | Subunidade | Área | |
|---------------------|-----------------|--------|----------------|-----------------|--------|
| | Km ² | % | | Km ² | % |
| Paraná | | | Corumbá | 280,46 | 4,87 |
| Paraná | | | Descoberto | 791,43 | 13,74 |
| Paraná | 3708,05 | 64,37 | Lago Paranoá | 1004,72 | 17,44 |
| Paraná | | | São Bartolomeu | 1579,20 | 27,41 |
| Paraná | | | São Marcos | 52,24 | 0,91 |
| São Francisco | 1325,26 | 13,34 | Preto | 1325,26 | 23,00 |
| Tocantins/ Araguaia | 768,46 | 23,00 | Maranhão | 768,46 | 13,34 |
| Total | 5760,78 | 100,00 | Total | 5760,78 | 100,00 |

Fonte: Elaborado pelo autor com banco de em dados de CODEPLAN (2020a).

3.4.1. Situação dos recursos hídricos no Distrito Federal

Em 2020, a Companhia de Planejamento do Distrito Federal (CODEPLAN) traçou um panorama da situação das águas no DF (CODEPLAN, 2020b). No relatório, os autores expuseram os principais usos da água e distribuição desse recurso para a população e atividades agroindustriais. Neste material, foi advertido que o DF, apesar de estar em uma região considerada como “berço das águas do Brasil”, apresenta índices críticos de disponibilidade hídrica *per capita*, o que justifica a adoção de ações de preservação e uso racional da água.

Com o objetivo de definir diretrizes para a exploração das águas subterrâneas no DF, Campos et al. (2007) realizaram um levantamento da legislação acerca do assunto e apresentaram um SIG aplicado à gestão dos recursos hídricos subterrâneos. Os autores realizaram o mapeamento de disponibilidade hídrica para direcionar as tomadas de decisão quanto ao uso racional das águas no DF (Figura 3.6a). Observam-se os maiores índices em áreas com vegetação natural preservada. Em contrapartida, em áreas antropizadas, os índices decaem consideravelmente. Comportamento semelhante ocorreu no mapa de capacidade de retenção máxima de

água dos solos (S) (Figura 3.6b), o que reforça que o solo, em estado natural, disponibiliza água com mais facilidade para o lençol freático.

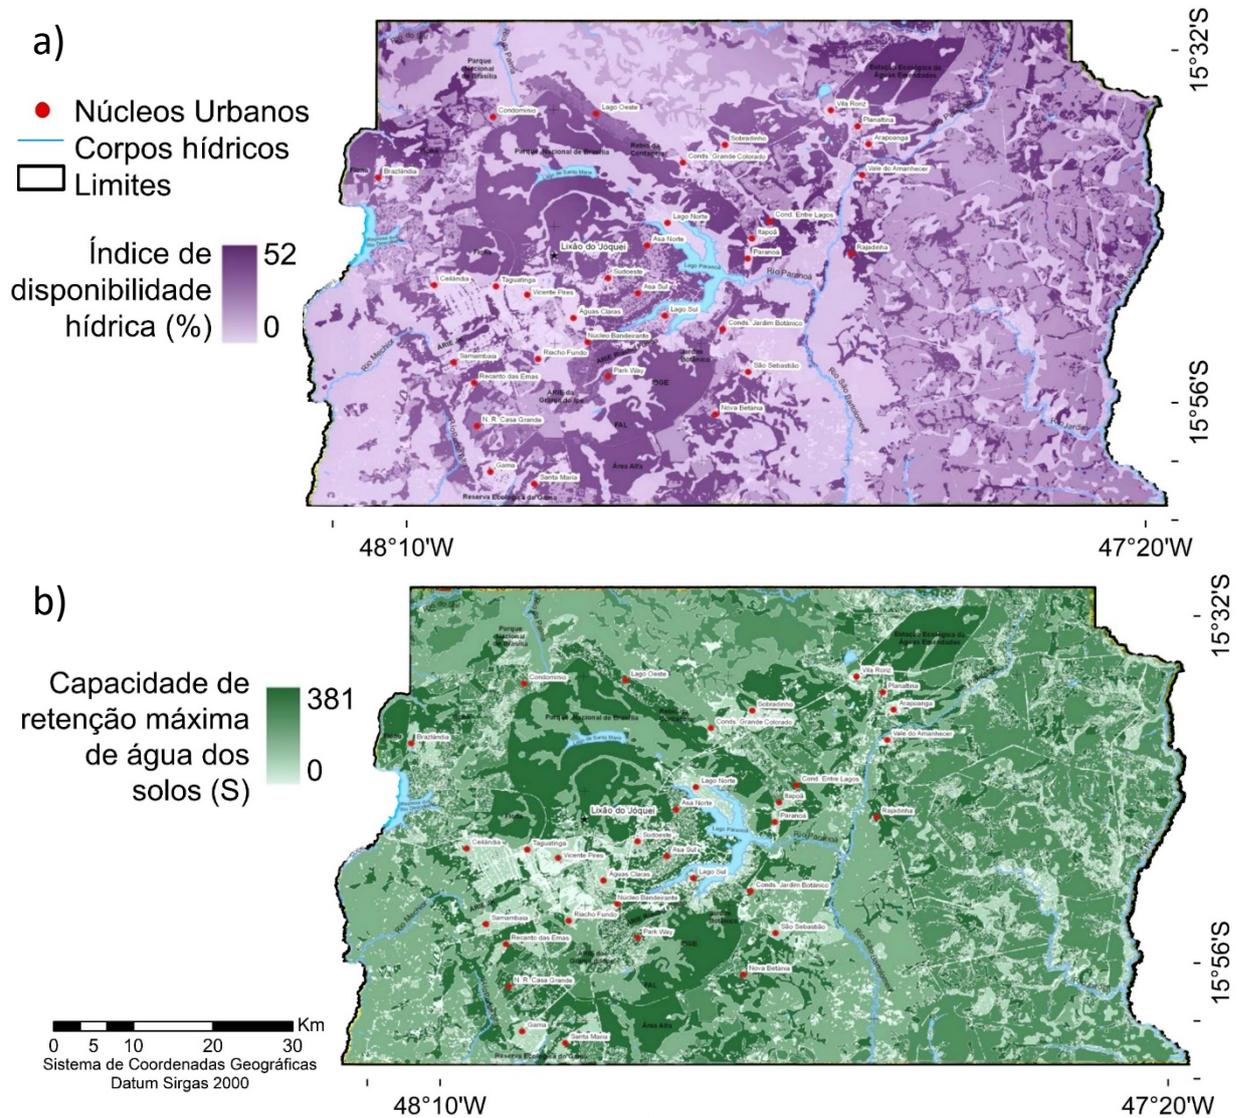


Figura 3.6. Mapas de disponibilidade hídrica (a) e Capacidade de retenção de água dos solos (b) do Distrito Federal. Fonte: Adaptado de Campos (2007).

Cunha et al. (2018), em observações sobre eventos de secas ocorridos entre 1963 e 2017 no DF, identificaram a ocupação irregular do solo, supressão da vegetação natural e aumento do consumo pela população e atividades agroindustriais como os principais responsáveis pelos eventos de deficiência hídrica na região. A análise de projeções futuras indicou redução na precipitação média anual.

3.5. GEOLOGIA

Na região do DF, predominam as rochas metassedimentares atribuídas a quatro grupos geológicos principais (Figura 3.7): Canastra e Paranoá, de idade Meso-Neoproterozóica; e Araxá e Bambuí, de idade Neoproterozóica. Essas formações estão localizadas na parte central da faixa Brasília de dobramentos e cavalgamentos (FREITAS-SILVA e CAMPOS, 1998).

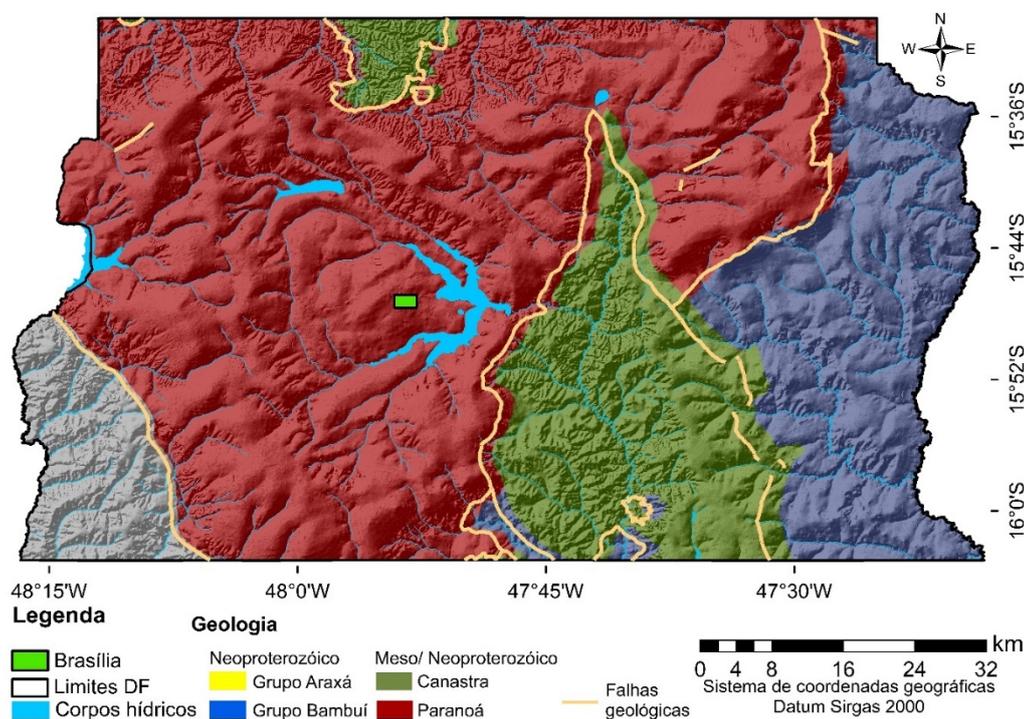


Figura 3.7. Mapa geológico do Distrito Federal. Fonte: Adaptado de Freitas-Silva e Campos (1998).

O Grupo Paranoá ocupa 65% do DF e é representado pelas seguintes subunidades (FREITAS-SILVA e CAMPOS, 1998): quartzitos médios (Q2), metassiltitos maciços, metarritmitos arenosos, quartzitos e lentes de metacalcários (S), ardósias roxas e lentes irregulares de quartzitos (A), metarritmitos, quartzitos, metassiltitos arenosos, metalamitos e metassiltitos argilosos (R3), quartzitos (Q3), quartzitos e metapelitos (R4) e ardósias e quartzitos (PC). O Grupo Canastra localiza-

se na porção central do DF, mais especificamente, nos vales dos rios São Bartolomeu e Maranhão (norte do DF) e é composto basicamente por filitos, xistos e ardósias.

3.6. CARACTERIZAÇÃO DA PAISAGEM

3.6.1. Hipsometria

As altitudes no DF variam de 1.343 m nas chapadas a 722 m em regiões de vales (CAMPOS, 2011). As terras acima de 1.000 m de altitude representam mais de 40% da área de estudo (Tabela 3.3). As regiões de chapada do DF são remanescentes da Superfície de Aplainamento Sul-Americana (KING, 1956) onde predominam as litologias do Grupo Paranoá, constituídas por ardósias circundadas por quartzitos, que, por serem resistentes ao intemperismo, foram preservadas do desgaste natural pelos processos de intemperismo (LACERDA e BARBOSA, 2012).

Tabela 3.3. Contabilização das áreas das classes hipsométricas do Distrito Federal.

| Classe | Designação | Mínimo | Média | Máximo | Amplitude | Área | |
|--------------|---------------------|---------------|---------|----------|-----------|----------|--------|
| | | ----- m ----- | | | | % | |
| 1 | 723,22 – 910,00 | 723,22 | 816,61 | 910,00 | 186,78 | 898 ,82 | 15,60 |
| 2 | 910,01 – 990,00 | 910,01 | 950,01 | 990,00 | 79,99 | 1490 ,70 | 25,88 |
| 3 | 990,01 – 1,075,00 | 990,01 | 1032,51 | 1075,00 | 84,99 | 1334 ,27 | 23,16 |
| 4 | 1.075,01 – 1,169,00 | 1.075,01 | 1122,01 | 1169,00 | 93,99 | 1249 ,73 | 21,69 |
| 5 | 1.169,01 – 1,342,22 | 1.169,01 | 1255,62 | 1342,22 | 173,21 | 787 ,26 | 13,67 |
| Total | | 4.867,26 | 618,96 | 5.486,22 | 618,96 | 5.804,27 | 100,00 |

Fonte: Elaborado pelo autor com dados de CODEPLAN (1991).

A Figura 3.8 exibe a distribuição das altitudes no DF. As cotas abaixo de 910 m são resultantes da presença de rochas sensíveis ao intemperismo, como os litotipos dos Grupos Araxá, Bambuí e Canastra, basicamente constituídas por unidades psamo-pelíticas e pelíticas metamorizadas. Essas regiões são marcadas pelo relevo movimentado e alta densidade de rios e córregos na parte central e extremos do DF, como descrito por Campos (2011).

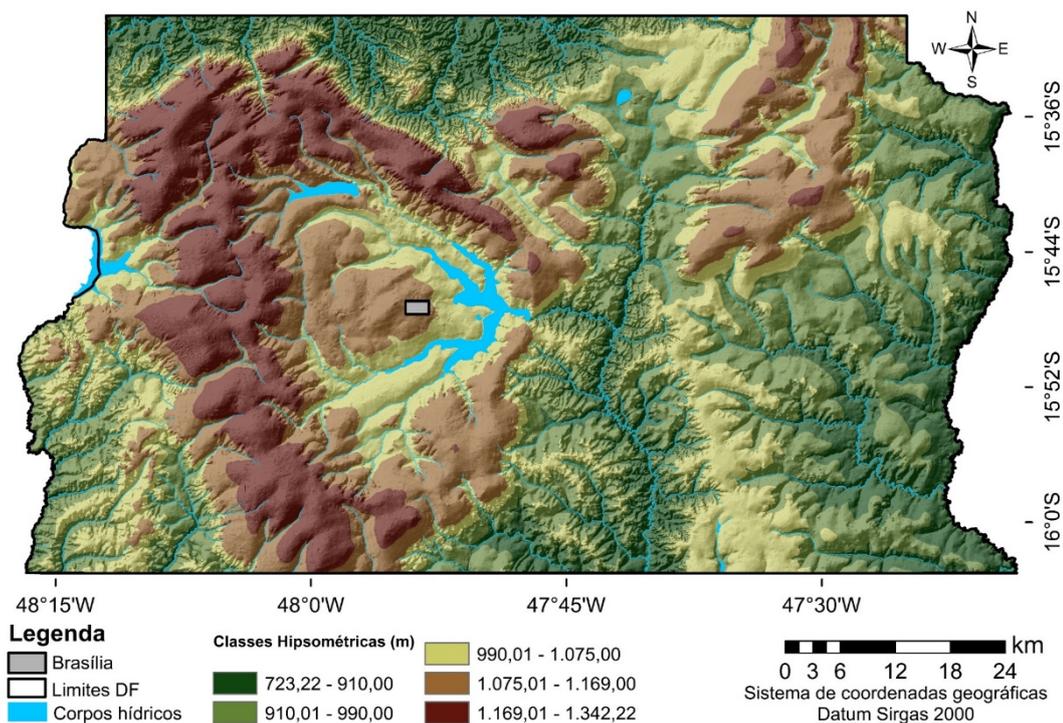


Figura 3.8. Mapa hipsométrico do Distrito Federal. Fonte: Elaborado pelo autor com dados de CODEPLAN (1991).

3.6.2. Declividade

O relevo é classificado em função da variação da declividade (SANTOS et al., 2018): plano (declividade entre 0 a 3%); suave ondulado (declividade entre 3% e 8%); ondulado (declividade entre 8% e 20%); forte ondulado (declividade entre 20% e 45%); montanhoso (declividade entre 45% e 75%); escarpado (declividade > 75%). A Figura 3.9 exibe as classes de declividade no DF.

As áreas planas a suave-onduladas somam mais de 70% do território do DF e ocorre predominantemente sobre as maiores altitudes, seguidas por elevações intermediárias que apresentam declividades suave-ondulada a forte-ondulado na maior parte do território (Tabela 3.3). Essas regiões são caracterizadas pela intensa ocupação humana, por meio de urbanizações no centro-oeste e agricultura intensiva ao leste (NOVAIS e LACERDA, 2021).

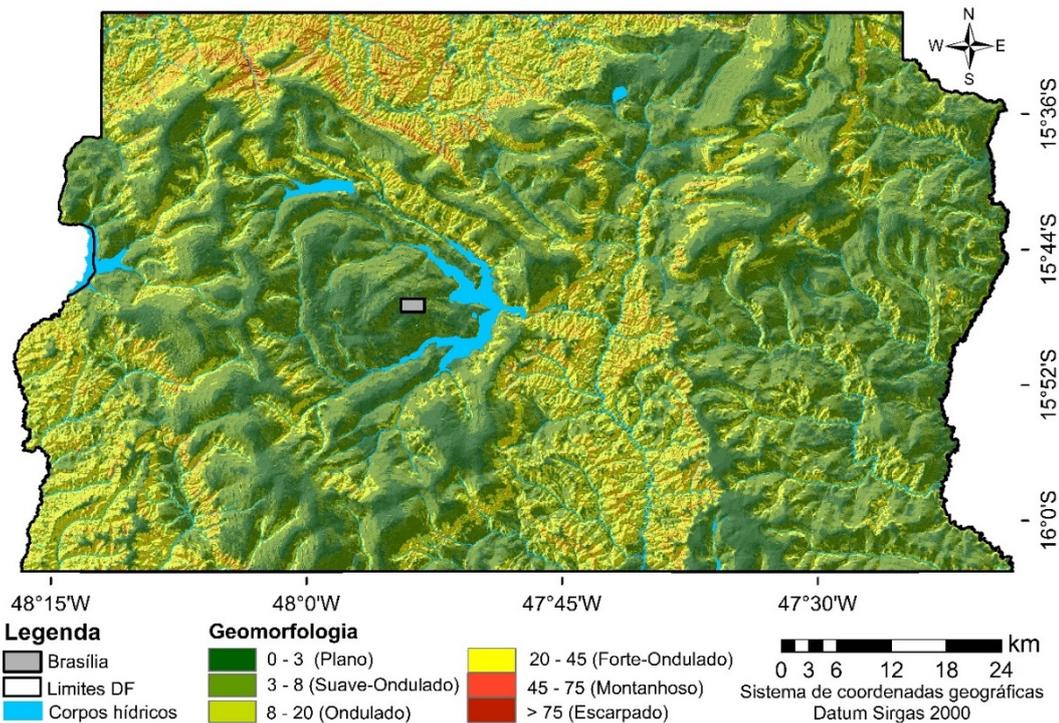


Figura 3.9. Classes de declividade do Distrito Federal. Fonte: Elaborado pelo autor com dados de CODEPLAN (1991) e classificado segundo Santos et al. (2018).

Em contraste, as áreas ao norte, oeste e centro do DF exibem uma forte dissecação do relevo, com declividades de 20% a > 75%, conforme descrito por Campos (2011). Essas regiões de menor elevação e declividades maiores coincidem com rochas mais susceptíveis ao intemperismo, como as dos Grupos Araxá e Canastra (FREITAS-SILVA e CAMPOS, 1998).

Tabela 3.4. Contabilização das áreas das classes de declividade do Distrito Federal.

| Classe | Designação | Mínimo | Média | Máximo | Amplitude | Área | % |
|--------------|----------------|--------|-------|--------|-----------|---------|--------|
| | | m | | | | | |
| 1 | Plano | 0,00 | 1,50 | 3,00 | 3,00 | 2153,01 | 37,37 |
| 2 | Suave-ondulado | 3,01 | 5,51 | 8,00 | 4,99 | 1965,23 | 34,11 |
| 3 | Ondulado | 8,01 | 14,01 | 20,00 | 11,99 | 1304,86 | 22,65 |
| 4 | Forte-ondulado | 20,01 | 32,51 | 45,00 | 24,99 | 320,56 | 5,56 |
| 5 | Montanhoso | 45,01 | 60,01 | 75,00 | 29,99 | 16,82 | 0,29 |
| 6 | Escarpado | 75,01 | 94,25 | 113,49 | 38,48 | 0,31 | 0,01 |
| Total | | | | | | 5760,78 | 100,00 |

Fonte: Elaborado pelo autor.

3.6.3. Compartimentação geomorfológica

A paisagem do DF encontra-se compartimentada em três superfícies geomorfológicas (SG) principais (PENTEADO, 1976): SG-I (1.050 m a 1.300 m de altitude), que abrange a Chapada de Contagem e Sobradinho e os pediplanos de Brasília e Planaltina; SG-II, entre as altitudes de 950 m e 1.050 m; e a SG-III, localizada nas regiões com cotas abaixo de 950 m, que engloba os vales dissecados.

Remanescentes da Superfície Sul-Americana (KING, 1956) as unidades da paisagem formam as Chapadas Elevadas, que constituem a SG-I, evoluída de atividades tectônicas e erosivas para a SG-II, que ocorrem desde áreas aplainadas a planícies onduladas, com desnível de 200 a 300 m em relação à SG-I. Pode ser relacionada ao Ciclo Velhas, descrita por King (1956). As áreas dissecadas formam a SG-III, na porção noroeste do DF, no vale do Rio Maranhão; sudoeste, bacia do rio descoberto e centro, vale do rio São Bartolomeu. Estas, drenam para grandes bacias hidrográficas do Brasil, relacionadas à transição do Ciclo Velhas para o Ciclo Paraguaçu (KING, 1956).

Com base nas propostas de subdivisão da paisagem do DF realizada por Penteado (1976), Novaes-Pinto (1987) sugeriu uma compartimentação geomorfológica do DF, a qual: SG-I: Região de Chapadas (A), Contagem (A1), Brasília (A2), Pípiripau (A3), Divisor São Bartolomeu–Preto (A4), Divisor Descoberto–Alagado (A5); SG-II: Área de dissecação intermediária (B), depressão do Rio Paranoá (B6) e vale Rio do Preto (B7) e SG-III: Região dissecada de vales (C), curso superior do Rio Maranhão (C8), alto curso do Rio São Bartolomeu (C9), curso superior do Rio São Bartolomeu (C10), alto curso do Rio Descoberto (C11), curso superior do Descoberto (C12) e alto curso do Rio Alagado (C13), (Figura 3.10).

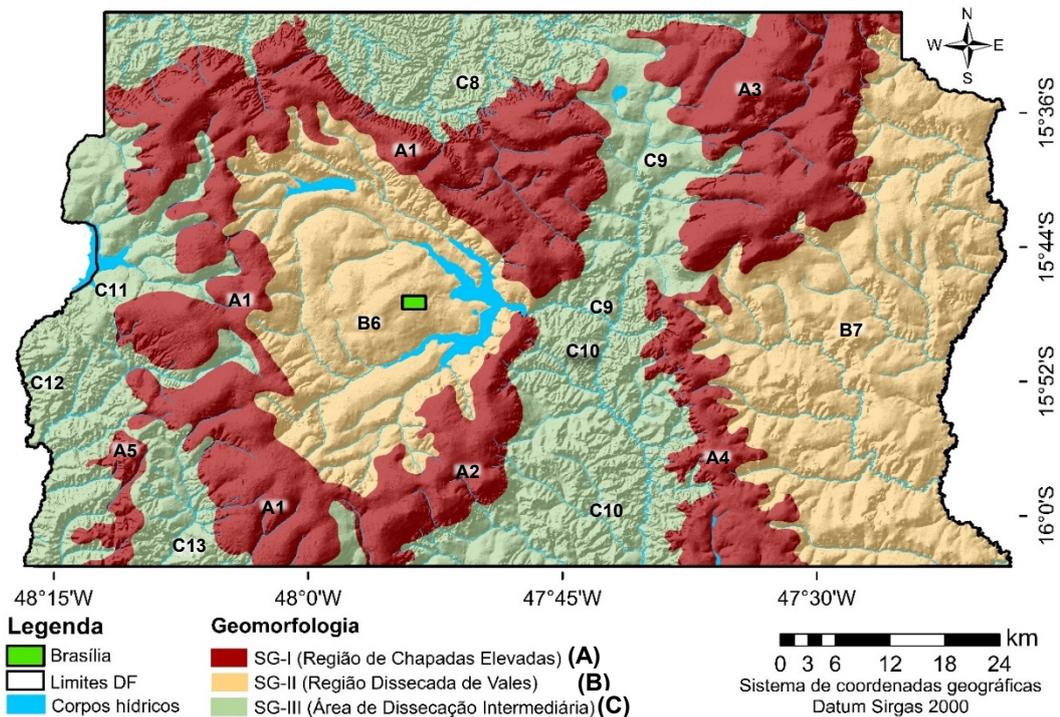


Figura 3.10. Mapa de superfícies geomorfológicas do Distrito Federal. SG-I = Região de chapadas elevadas; SG-II = Região de dissecação intermediária e SG-III = Região dissecada de vales. Fonte: Adaptado de Novaes Pinto (1987).

Com a finalidade de aprimorar as propostas de compartimentação geomorfológica do DF, Campos (2011) integrou e adaptou as abordagens do relevo realizadas por Novaes Pinto (1987), Martins e Baptista (1998) e Martins et al. (2004) para abranger as particularidades de cada região. Dessa forma, Campos (2011) categorizou a paisagem em cinco grupos principais baseado em critérios de similaridade fisiográfica da paisagem (Figura 3.11).

No primeiro grupo, a pedogênese supera a erosão e o transporte no balanço morfodinâmico e é formado pelas seguintes classes: 1) Plano Elevado (PE), caracterizado pelo padrão de relevo plano a suave ondulado, baixa densidade de drenagens, predominância de Latossolos, declividades inferiores a 10% e cotas superiores a 1.100 m; e 2) Plano Intermediário (PI), representado pelo padrão de

relevo plano a suave ondulado, baixa densidade de drenagem, predominância de Latossolos, declividades inferiores a 12% e cotas entre 950 m e 1.050 m.

No segundo grupo, a erosão e o transporte de materiais detríticos superam fortemente a pedogênese no balanço morfodinâmico e é formado pelas seguintes classes: 3) Vale Dissecado (VD), padrão de relevo ondulado a forte ondulado, elevada densidade de drenagem, ampla predominância de Cambissolos, declividades superiores a 20% e cotas inferiores a 800 m; 4) Rebordo (R), padrão de relevo ondulado, moderada densidade de drenagem, predominância de Cambissolos, declividades entre 10% e 20% e cotas entre 950 m e 1.100 m; e 5) Rampa Íngreme (RI), padrão de relevo forte ondulado a escarpado, alta densidade de drenagem, predominância de Latossolos, declividades superiores a 25% e cotas de 800 m a 1.100 m (CODEPLAN, 2020a; CAMPOS, 2011).

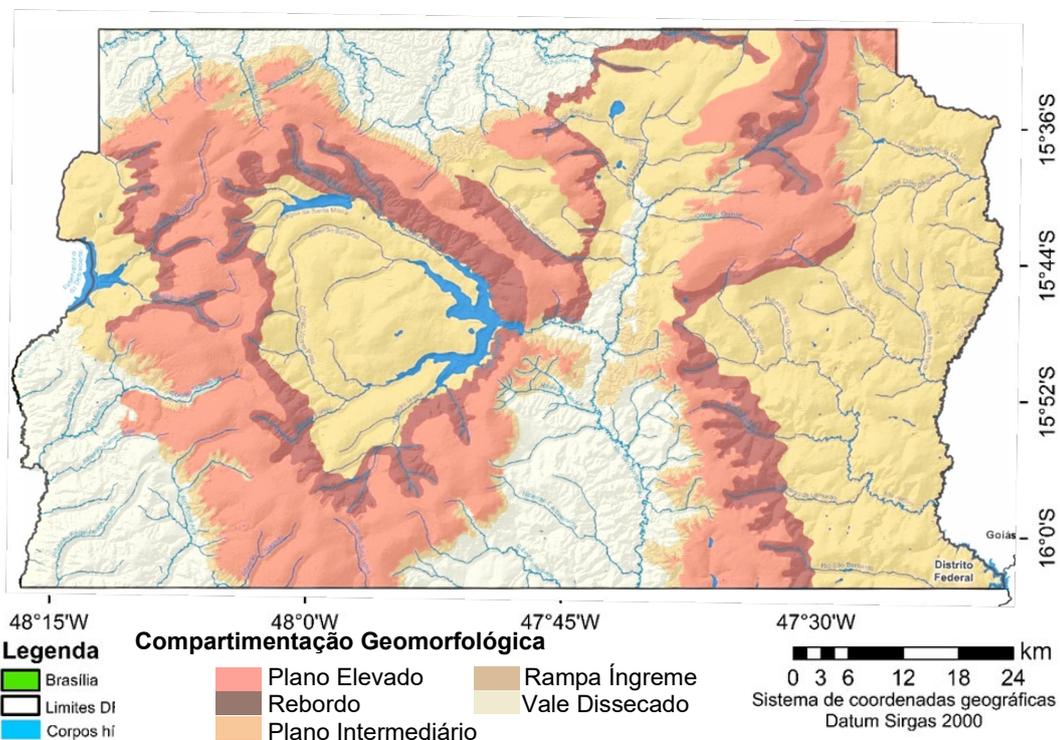


Figura 3.11. Mapa de compartimentação geomorfológica do Distrito Federal. Fonte: Adaptado de Campos (2011).

3.7. SOLOS

Os solos do DF retratam parte da diversidade pedológica da região do Cerrado (CLINE e BUOL, 1973). O mapeamento realizado pelo Serviço Nacional de Levantamento e Conservação de Solos (SNLCS) da Embrapa, na escala de 1:100.000 e por meio de técnicas de pedometria, é considerada a principal fonte de informações sobre pedodiversidade do DF (FREITAS et al., 1978). Assim, esse trabalho é o material básico para a maioria dos estudos pedológicos no DF, o qual foi atualizado posteriormente por Reatto et al. (2004) com as classes de solos do Sistema Brasileiro de Classificação de Solos (SiBCS) vigente à época. A Figura 3.12 ilustra a distribuição dos solos no DF, com atualização de legenda segundo Santos et al. (2018).

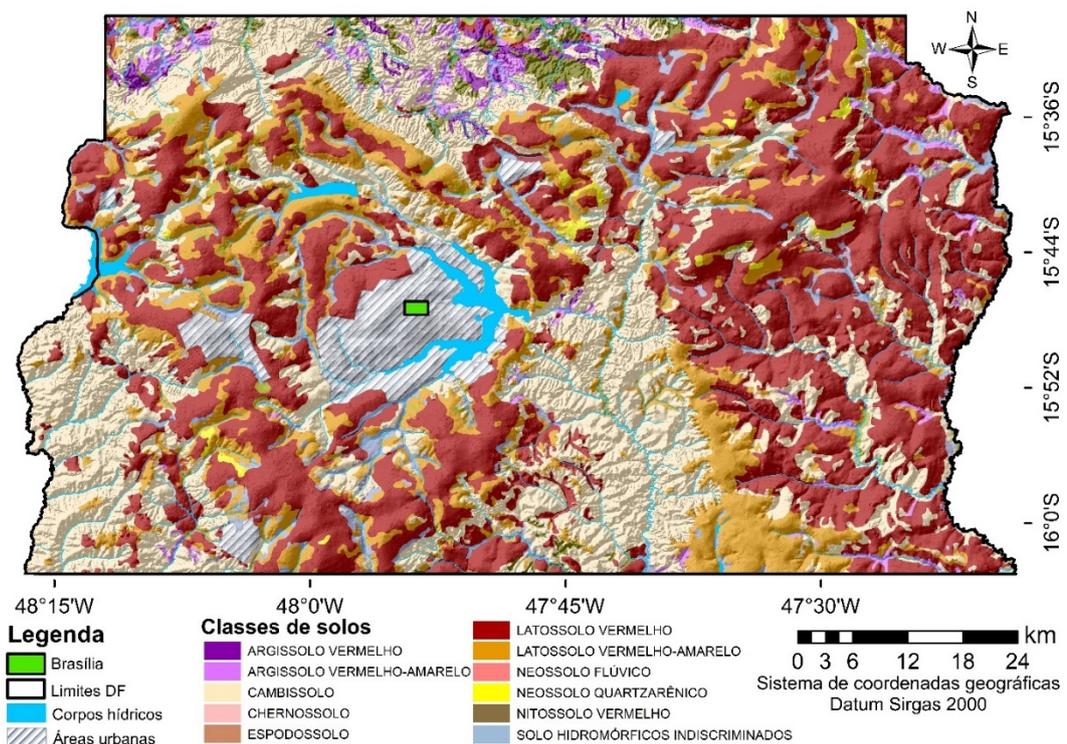


Figura 3.12. Mapa pedológico do Distrito Federal. Fonte: Adaptado de Reatto et al. (2004), classificado de acordo com Santos et al. (2018).

Conforme consta nesse mapa temático que aproximadamente 85% da pedodiversidade do DF é composta por Latossolos Vermelhos, Latossolos Vermelho-

Amarelos e Cambissolos Háplicos, seguidos por Nitossolos, Chernossolos, Gleissolos Organossolos, Neossolos Quartzarênicos, Neossolos Flúvicos e Neossolos Litólicos, em menores percentuais de área coberta (REATTO et al., 2004).

Algumas pesquisas no DF utilizaram o mapeamento digital de solos (MDS) em escala de microbacia hidrográfica. Reatto et al. (2000), por exemplo, testaram a incorporação de variáveis do terreno e atributos dos solos para predição de classes e geraram um modelo de distribuição de solos na escala de 1:50.000 em uma área-piloto do DF. Em uma abordagem semelhante, Lima et al. (2014) propuseram uma metodologia semiautomática com dados morfométricos para a criação de MDS semidetalhado a detalhado de uma microbacia. Oliveira Júnior (2017) estudou as feições geomorfológicas e MDS da porção leste do DF por meio da utilização de técnicas de pedometria em escala 1:25.000 a leste do DF, no qual obteve 60% de acurácia pelo índice Kappa e alta correlação com a geologia e a geomorfologia.

Ao utilizar modelagem multiespectral sobre dados de série temporal do sensor ASTER e biblioteca espectral de áreas com fisiografia e relações pedomorfogeológicas semelhantes, Novais (2017) conduziu um MDS de superfícies expostas em uma microbacia a leste do DF com resolução espacial de 20 m e alcançou um índice Kappa de 70%. Nessa linha, Poppiel et al. (2019) e Novais et al. (2021) realizaram um MDS na mesma área com resolução de 30 m, baseado em espectroscopia de reflectância derivada de série temporal Landsat modeladas por dados espectrais de campo.

CAPÍTULO 4

MAPEAMENTO DIGITAL DE SOLOS POR MEIO DE MODELAGEM MULTIESPECTRAL SOBRE SÉRIE TEMPORAL LANDSAT E PROCESSAMENTO EM NUVEM

4.1. INTRODUÇÃO

Informações sobre solos são imprescindíveis a exploração racional desse recurso natural não renovável. Apesar da importância dos solos para a sustentação da vida na Terra, materiais cartográficos são inadequados ou indisponíveis na maioria dos países (MA et al., 2019). A alta demanda de tempo e de recursos financeiros para levantamentos de solos está entre as causas da escassez de informações pedológicas (MINASNY e MCBRATNEY, 2016; CHABRILLAT et al., 2019).

As geotecnologias podem contornar as limitações apresentadas pelos métodos clássicos de levantamento e mapeamento (REDDY et al., 2018). A espectroscopia de reflectância, por exemplo, é uma dessas técnicas de sensoriamento remoto, a qual que consiste na captação da energia eletromagnética refletida pelos materiais (JENSEN, 2009). Muitos pesquisadores têm se empenhado em desenvolver métodos de aquisição e processamento de dados pedológicos (GENÚ et al., 2013; DEMATTÊ et al., 2014; LACERDA et al., 2016; GALLO et al., 2018; POPPIEL et al., 2019a; 2019b; 2019c; COBLINSKY et al., 2020; LIU et al., 2020; LOURENÇO et al., 2020; MENDES et al., 2020; NOVAIS et al., 2021).

Para o Distrito Federal (DF), a fonte oficial de levantamento de solos foi realizada pela Empresa Brasileira de Pesquisa Agropecuária (Embrapa) em 1978 (FREITAS et al., 1978) e atualizada em 2004 (REATTO et al., 2004), na escala de 1:100.000. Como essa escala é considerada inadequada e generalista para ações

mais localizadas de conservação ou de exploração dos solos, surge a necessidade de testar técnicas de mapeamento dos solos mais eficientes, visto a importância política, socioeconômica e ambiental que o DF representa em nível regional e nacional (CODEPLAN, 2020a).

Novais (2017), Poppiel et al. (2019b) e Novais et al. (2021) mapearam os solos em nível de microbacia hidrográfica no leste do DF, com modelagem multiespectral de série temporal de sensores remotos orbitais. Contudo, esses autores relataram a sensibilidade do método quanto à influência das condições fisiográficas, como o relevo. Ao observar esse aspecto, a modelagem deve ser executada por partes, em segmentos da área de estudo fisiograficamente semelhantes para reduzir os erros.

Como estratégia para contornar as limitações encontradas nos trabalhos anteriores, o presente Capítulo parte da hipótese de que bibliotecas espectrais compostas por membros de referência (*endmembers*) agrupados pela textura dos solos e originados de áreas fisiograficamente semelhantes podem ser modeladas individualmente sobre uma imagem sintética de solos expostos (ou rochas) ao longo de uma série temporal gerada por dados multiespectrais via computação em nuvem. Os dados matriciais resultantes, com os modelos de mistura espectral de cada segmento, representam as classes pedológicas, ou seja, o mapa digital de solos.

Uma das características do Cerrado brasileiro é a alta frequência de exposição natural dos solos devido à sazonalidade climática (SANO et al., 2019). A adoção de práticas de agricultura intensiva sob sistemas de plantio direto, bem como a diminuição da cobertura vegetal natural devido à ocupação humana, aumenta a área de solos expostos (NEVES et al., 2018; HUNKE et al., 2018; NOVAIS e LACERDA, 2021). Esse fenômeno favorece a captação de feições de solos por sensores que operam na faixa óptica do espectro eletromagnético.

A grande quantidade de dados do legado Landsat exige equipamentos com alta capacidade de armazenamento e processamento (DEMATTÊ et al., 2018). Como alternativa, o processamento em nuvem disponibilizado pela plataforma *Google Earth Engine* (GEE), por exemplo, utiliza diversas máquinas online para executar algoritmos sobre bancos de dados extensos (POPPIEL et al., 2019c; DEMATTÊ et al., 2020).

Diante do exposto, o objetivo deste Capítulo foi mapear digitalmente três superfícies geomorfológicas do DF, por meio de modelagem multiespectral com *endmembers* sobre uma imagem sintética de solos expostos ao longo de uma série temporal Landsat gerada por computação em nuvem.

4.2. MATERIAL E MÉTODOS

4.2.1. Pesquisa bibliográfica e levantamento de dados secundários

Primeiramente, foi realizada uma revisão dos estudos relacionados ao levantamento, classificação e mapeamento de solos por meio de técnicas convencionais e o uso de geotecnologias. Além disso, foram consultados métodos de determinação e estimativa de atributos dos solos, particularmente, em relação às técnicas de sensoriamento remoto e às correlações com classes e atributos de solos.

Dados geoespaciais e demais informações, necessárias à realização deste trabalho, foram levantados principalmente do banco de dados geográficos disponível no Geoportal do DF (<https://www.geoportal.seduh.df.gov.br/geoportal/>) (CODEPLAN, 2020). Como exemplo, mapas pedológicos, geomorfológicos, geológicos, hidrográficos, cartas planialtimétricas e mapas de vegetação, pontos de elevação, limites, entre outros arquivos matriciais e vetoriais.

4.2.2. Fluxo de trabalho

As principais etapas do processamento dos dados físicos, químicos e espectrais do solo são mostradas na Figura 4.1. Os atributos físicos e químicos do solo foram analisados usando estatísticas não paramétricas para produzir membros finais do solo. Esses membros finais do solo foram interpretados morfologicamente e reamostrados em seis intervalos de bandas do satélite Landsat 5 Thematic Mapper.

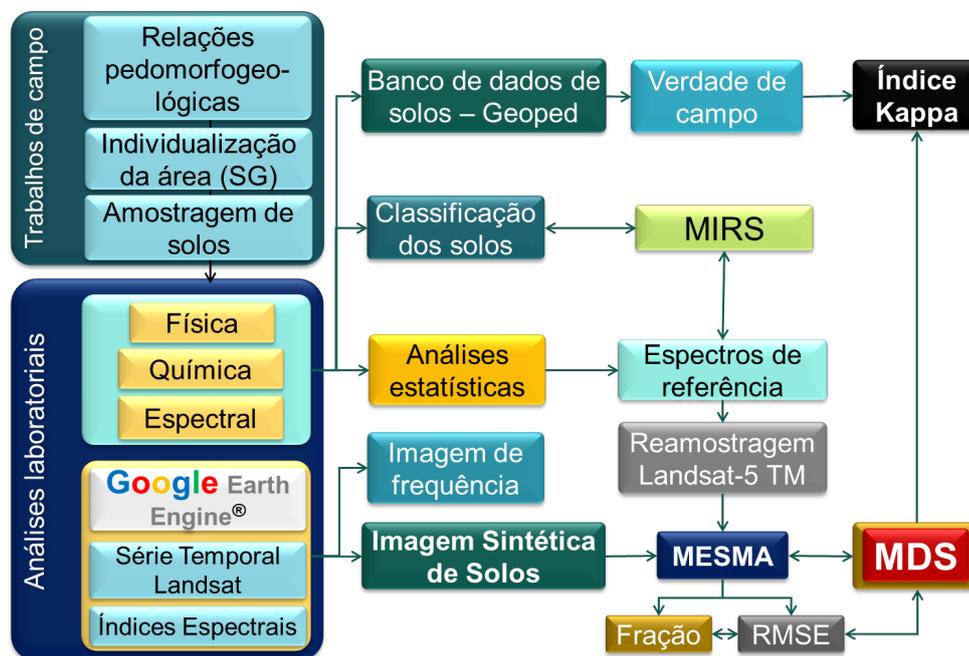


Figura 4.1. Fluxograma da metodologia de produção do mapa digital de solos da área de estudo. MIRS: interpretação morfológica de espectros de refletância; TM: sensor Thematic Mapper; MDS: mapa digital do solo; RMSE: raiz quadrada média do erro.

4.2.3. Descrição da área de estudo

Como descrito no Capítulo 3 desta tese, o DF está localizado na região Centro-Oeste do Brasil, insere-se no domínio geomorfológico do Planalto Central brasileiro e comporta três superfícies geomorfológicas (SG) remanescentes de aplainamento sul-americano de King (KING, 1956). As altitudes variam de 720 m a 1.320 m por extensas

rampas com relevo suave a suave ondulado na maior parte da área (MARTINS et al., 2004). A Figura 4.2 exibe a distribuição de 173 pontos de amostragem de solos (em vermelho) utilizados para modelagem de solos neste Capítulo ao longo das SGs. Adicionalmente, são destacados os locais escolhidos para as análises do Capítulo 5 e 6 relacionados às estimativas de umidade do solo (localizadores em azul).

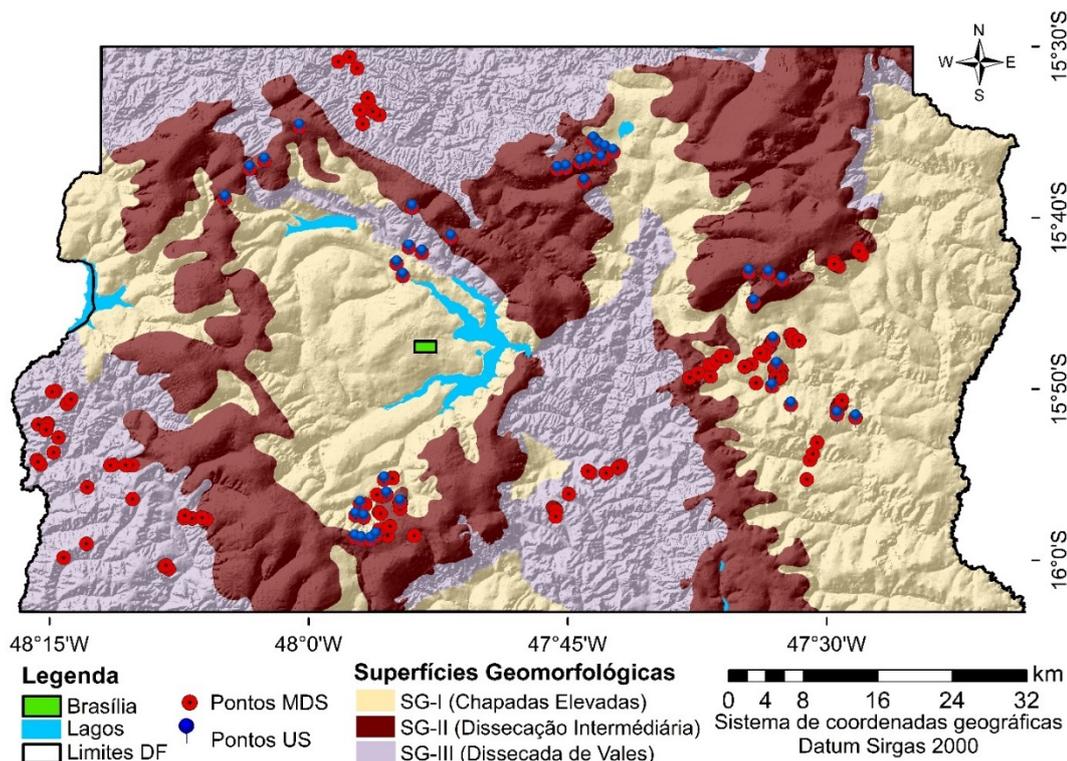


Figura 4.2. Distribuição dos pontos de amostragem de solos sobre as superfícies geomorfológicas. MDS = mapeamento digital de solos; US = Umidade superficial do solo. Fonte: Elaborado pelo autor com base em Novaes Pinto (1987).

4.2.4. Individualização da área de estudo

Para a modelagem espectral, a paisagem do DF foi dividida em superfícies geomorfológicas (SG) adaptada exclusivamente para este trabalho com base na classificação proposta por Novaes Pinto (1987) que subdividiu a região em: SG-I, Chapadas Elevadas; SG-II, Região de Dissecação Intermidiária; e SG-III, Região Dissecada de Vales. A reclassificação foi necessária devido à presença de relevos

distintos em uma mesma superfície geomorfológica, como observado por Martins et al. (2004) e Campos (2011).

Para tanto, foi utilizado um modelo digital do terreno (MDT) com células de 10 m, gerado por interpolação de arquivos vetoriais como: curvas de nível e hidrografia, em escala 1:10.000, mapa de delimitação do DF, além de nuvem de pontos de elevação com 58.379 valores distribuídos ao longo da área em estudo obtidos pela Companhia de Planejamento do DF (CODEPLAN, 1991). Esses dados foram processados pelo algoritmo *Topo to raster* do programa ArcGIS v.10.7 (ESRI, 2019).

O MDT resultante foi filtrado pela função *Focal Statistic* do pacote de aplicações *Spatial Analyst*, que reamostra os pixels ao redor de uma geometria estabelecida, retangular, com base na mediana do pixel central de maneira a suavizar as feições (SAMPAIO e AUGUSTIN, 2014). Assim, geraram-se mapas de declividade e hipsometria que, multiplicado pelo mapa geomorfológico de Novaes Pinto (1987), resultou em um mapa que detalha as três principais paisagens do DF como demonstrado na Figura 4.2 da seção anterior.

4.2.5. Amostragem e caracterização dos solos

Inicialmente, estabeleceram-se as relações pedomorfogeológicas, de acordo com a proposta de Lacerda e Barbosa (2012), para a seleção das classes de solos representativas nas três regiões geomorfológicas estudadas. A localização dos dados pré-existentes no banco de dados Geoped foi levada em consideração para coletar amostras de solos em regiões não abordadas em trabalhos anteriores para refletir a pedodiversidade local. A quantidade de pontos de coleta de solos foi proporcional à raiz quadrada da área da SG, em km², que resultou em um total de 173 pontos de

amostragem nos horizontes A, B, C ou F dos solos. As profundidades variaram de 0-20 cm, para os horizontes superficiais e 10-100 cm, para os horizontes subsuperficiais.

O levantamento e descrição dos solos em campo seguiram os manuais de coleta de solos propostos por Santos et al. (2015), Sociedade Brasileira de Ciências do Solo; Schoeneberger (2012) e Soil Survey Staff (2017), disponibilizados pelo Serviço Geológico dos Estados Unidos. A categorização dos perfis de solos foi baseada no Sistema Brasileiro de Classificação de Solos (SANTOS et al., 2018), no sistema norte-americano (SOIL SURVEY STAFF, 2015) e no sistema global (IUSS WORKING GROUP WRB, 2015). As amostras de solos foram analisadas segundo os procedimentos constantes em trabalhos de referência (SCHOENEGERGER et al., 2012; SOIL SURVEY STAFF, 2014; TEIXEIRA et al., 2017).

Para os atributos morfológicos dos solos, foi analisada a cor, segundo o sistema de cores de Munsell. Os atributos químicos considerados foram: o pH em H₂O, bases trocáveis (Ca²⁺, Mg²⁺, K⁺), soma de bases (SB), alumínio trocável (Al³⁺), fósforo assimilável, acidez potencial (H⁺ + Al³⁺), teor de matéria orgânica (MO), capacidade de troca de cátions (CTC = SB + [H⁺ + Al³⁺]), saturação por bases (V% = [SB/CTC]*100), saturação por alumínio (m% = Al³⁺/[Al³⁺ + SB]*100) e atividade de argila ([CTC*1000]/g.kg⁻¹ de argila (SCHOENEGERGER, 2012; TEIXEIRA et al., 2017). A textura representou os atributos físicos (BOUYOUCOS, 1951).

4.2.6. Análises estatísticas dos dados pedológicos

Inicialmente, foi realizada a análise da estatística descritiva no programa estatístico R, a qual foi apresentada por tabelas e gráficos de caixa sobre o conjunto de dados referentes aos horizontes diagnósticos dos perfis estudados. Ademais, técnicas estatísticas não paramétricas como a correlação de Pearson entre os

atributos e análise de componentes principais (PCA) foram utilizadas nas avaliações do comportamento dos atributos pedológicos em cada SG. Para tanto, os dados foram normalizados pelo quociente da diferença, em módulo, entre o i-ésimo valor e a média amostral pelo desvio-padrão, para execução do algoritmo PCA, como recomendou Miller (2017). A Eq. 4.1 exibe o cálculo para a normalização dos dados.

$$T = \frac{(\bar{X} - X_i)}{\sigma} \quad (4.1)$$

Em que T corresponde aos dados transformados; \bar{X} é a média amostral; X_i é o i-ésimo valor do conjunto de dados da variável; e σ corresponde ao desvio-padrão.

O algoritmo PCA reduz a dimensionalidade dos dados e aponta as variáveis que melhor explicam o conjunto (LOURENÇO et al., 2020). Portanto, o atributo do solo com maior probabilidade de representar o conjunto de dados serviu de critério para o agrupamento dos espectros dentro das classes de solo, nesse caso, a textura.

4.2.7. Espectroscopia e compilação da biblioteca espectral de solos

Os procedimentos acerca da espectroscopia de reflectância dos solos do DF geraram a biblioteca espectral de solos representativa de cada SG. Foi utilizado o espectrorradiômetro FieldSpec 4 Pro (ANALYTICAL SPECTRAL DEVICE INC, 2019). Esse sensor hiperespectral opera nas faixas do espectro eletromagnético do visível, infravermelho próximo e infravermelho de ondas curtas (de 0,35 μm a 2,5 μm). Os procedimentos-padrão e disposição dos equipamentos com relação às amostras estão descritos em Romero et al. (2018).

As informações geradas, como assinaturas espectrais de solos do DF e MDS, foram implementadas no banco de dados interno do grupo de pesquisa em Pedomorfogeologia do Laboratório de Geoprocessamento e Sensoriamento Remoto (GeoPed) da Faculdade de Agronomia e Medicina Veterinária da Universidade de

Brasília (FAV/UnB). Os dados fazem parte da Biblioteca Espectral de Solos do Brasil (<https://bibliotecaespectral.wixsite.com/esalq>), coordenado pelo Prof. José Alexandre Demattê da Escola Superior de Agricultura Luiz de Queiroz (ESALQ) da Universidade de São Paulo (USP) (DEMATTE et al., 2019).

Com os dados espectrais dos horizontes superficiais, devidamente organizados por classes de solo, calculou-se a mediana de cada grupo espectral para obtenção dos *endmembers* de cada classe pedológica. Com o intuito de verificar a concordância do comportamento espectral do *endmember*, as curvas foram submetidas à interpretação morfológica do espectro de reflectância mediante a observação da forma geral da curva espectral, bem como as feições de absorção específicas relacionadas principalmente às presenças de matéria orgânica, minerais primários e secundários, óxidos e H₂O nas amostras de solos (DEMATTE et al., 2014).

Adicionalmente, foi calculada a 2ª derivada de Kubelka-Munk (Eq. 4.2), função que padroniza os valores de reflectância em torno de um eixo 0 (SCHEINOST et al., 1998), para uma melhor observação do comportamento espectral dos alvos, como relatado por Demattê et al. (2014), Poppiel et al. (2019b) e Novais et al. (2021).

$$\frac{k}{s} = \frac{(1-R_{\infty})^2}{2R_{\infty}} \quad (4.2)$$

Em que *s* corresponde ao coeficiente de espalhamento; *k* é o coeficiente de absorção da amostra; e *R_∞* é a reflectância difusa.

Conforme descrito em Genú et al. (2013), Poppiel et al. (2019a; 2019b; 2019c) e Novais et al. (2021), os *endmembers* foram reamostrados para os comprimentos de ondas das bandas espectrais do sensor Landsat *Thematic Mapper* (TM), compatíveis com as faixas espectrais das imagens da série temporal Landsat para posterior modelagem (USGS, 2020).

4.2.8. Imagem multitemporal de solos expostos

Uma imagem sintética de solos é composta pelo número de vezes em que a superfície do solo esteve exposta e foi registrada por um sensor remoto ao longo em uma série temporal. É expressa pela mediana dos pixels sobrepostos, de maneira a ampliar as áreas com solos e ou rochas expostas. A técnica foi proposta e denominada de *Synthetic Soil Image* (SySI) por Demattê et al. (2018). Além desse produto, gera-se uma matriz com a frequência com que as feições de solos passaram pelos filtros arbitrados ao longo da série temporal sob análise.

Por meio da plataforma *on line* de processamento de dados geoespaciais GEE (<https://code.earthengine.google.com>), foi elaborado um *script*, mediante programação em linha de comando, editado em linguagem própria do sistema GEE. O algoritmo foi elaborado com base na proposta de Poppiel et al. (2019b), que processaram uma série temporal Landsat de 1984 a 2018 no estado de Goiás, Brasil.

Por conseguinte, o comando compilou uma imagem multitemporal desde a década de 1984 até 2020, uniformizados segundo os intervalos das bandas do Landsat 5 TM: B1 (0,45–0,52 μm), B2 (0,52–0,60 μm), B3 (0,63–0,69 μm), B4 (0,76–0,90 μm), B5 (1,55–1,75 μm) e B7 (2,08–2,35 μm) (ROY et al., 2016). Índices espectrais foram implementados para remoção de feições como nuvens, vegetação, áreas urbanizadas, lagos, queimadas e resíduos de cultura (palhada) sobre a série temporal dentro de um polígono determinado em volta da área estudada, como consta em Gallo et al. (2018); Poppiel et al. (2019b) e Demattê et al. (2020).

4.2.9. Modelagem espectral dos solos

Para modelar a condição de mistura espectral presente nas imagens, foi utilizado, em ambiente de sistema de informações geográficas (SIG) (ENVI v. 5.3.1)

(HARRIS GEOSPATIAL SOLUTIONS, INC., 2020), o modelo de análise de mistura espectral com múltiplos membros de referência (*Multiple Endmember Spectral Mixture Analysis* – MESMA), proposto por Roberts et al. (1998). O método MESMA é um algoritmo do pacote de aplicativos VIPER Tools que permite a análise simultânea de vários *endmembers*, de modo a realizar combinações automáticas e escolher o modelo com menor erro (CRABBÉ et al., 2019). A modelagem foi executada separadamente sobre a SySI seccionada pelo vetor das três SGs, com um *buffer* de 300 m e com os espectros de referência correspondentes a cada SG.

Como métricas para avaliação da modelagem, obtém-se uma imagem com os valores de fração dos *endmembers* e outra com os valores de raiz quadrada do erro médio (RMSE) (Eq. 4.3) e uma imagem dos modelos correspondentes ao MDS (ROBERTS et al., 1998). Vale ressaltar que as classes Gleissolo e Organossolo foram desconsideradas previamente da modelagem por ocuparem áreas que permanecem recobertas por vegetação.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4.3)$$

Em que y equivale aos valores observados; \hat{y} são os valores estimados; e n corresponde ao número de amostras.

Após a implementação do algoritmo, as imagens com os modelos foram mosaicadas e convertidas em um único arquivo, o qual foi suavizado pela aplicação de um filtro de mediana com janela 5 pixels x 5 pixels. Em seguida, o arquivo *raster* foi convertido para o formato *shapefile* (shp) e legendado com cores contrastantes para facilitar a visualização do mapa digital de classes de solos. então, calculou-se as áreas correspondentes às classes pedológicas por meio da tabela de atributos dos

vetores. A escala cartográfica foi definida pela razão entre a resolução espacial do *raster* e a acuidade visual, que alcançou 1:100.000 (CONGALTO e GREEN, 2010).

4.2.10. Validação do mapa digital de solos

O dado vetorial resultante foi submetido à amostragem aleatória estratificada, com pontos distribuídos proporcionalmente e de forma randômica dentro dos polígonos das classes de solos, sobre os quais foram atribuídos pesos de acordo com a área correspondente (CONGALTON e GREEN, 2010). A verificação da verdade de campo ocorreu por meio de 417 pontos com informações de solos obtidas em saídas de campo e dados pedológicos disponíveis no BD Geoped em posições diferentes daquelas utilizadas para a modelagem. O desempenho dos modelos foi baseado nos erros e acertos em uma matriz de confusão para cálculo do índice Kappa (CONGALTON e GREEN, 2010).

4.3. RESULTADOS E DISCUSSÃO

4.3.1. Caracterização e classificação dos perfis de solos

Os 173 perfis de solos foram considerados representativos da pedodiversidade do DF. Essa consideração foi baseada nas constatações em campo, por meio do estabelecimento das relações pedomorfogeológicas ao longo das SGs (determinadas na seção 4.2.3 e ilustradas na figura 4.1), as quais foram baseadas na proposta de Novaes Pinto (1987). Estas relações também constam em pesquisas anteriores sobre o tema no DF (REATTO et al., 2000; 2004; LIMA et al., 2014; LACERDA e BARBOSA, 2012; POPPIEL et al., 2019a; NOVAIS et al., 2021).

Constatou-se que, dentre os solos da SG-I, houve a predominância dos Latossolos em áreas planas a suave-onduladas, seguidos pelos Plintossolos Pétricos

e demais classes em menor proporção nas declividades mais acentuadas da paisagem. Lacerda e Barbosa (2012), ao estudar os solos das Chapadas Elevadas do DF, relataram a ocorrência de solos de textura muito argilosa a média em Latossolos Vermelhos e Latossolos Vermelho-Amarelos, herdados da litologia local quando constituídos por metarritmitos argilosos ou argilo-arenosos.

Similarmente, a SG-II constitui uma região intermediária com predominância de LV e LVA. Ao longo das drenagens ocorrem solos hidromórficos como Plintossolos, Gleissolos e Organossolos. Já na SG-III, constatou-se a maior pedodiversidade devido à litologia calcária e relevo mais declivoso, que originam solos de fertilidade natural alta, como os Argissolos e Nitossolos descritos por REATTO et al. (2004).

4.3.2. Classificação dos solos estudados

A Tabela 4.1 dispõe os dados de 15 variações de classes de solos, ao considerar-se o nível de família, quinto nível categórico do Sistema Brasileiro de Classificação de Solos (SiBCS) (SANTOS et al., 2018), seguidos das classes correspondentes nos sistemas global (IUSS WORKING GROUP WRB, 2015) e americano (SOIL SURVEY STAFF, 2014).

As quantidades de perfis por classes e pedodiversidade por SG evidenciam que são regiões distintas, tanto no tipo de solos, quanto nas proporções das classes. Cabe destacar que litologias diferentes podem produzir a mesma classe de solo, ou em litologias semelhantes ocorrerem solos diferentes, uma vez que há dependência dos demais fatores de formação que direcionam a pedogênese local (NOVAIS e al., 2021; LACERDA e BARBOSA, 2012).

Tabela 4.1. Classificação de solos, distribuição dos perfis por superfície geomorfológica e relação de *endmembers* de cada classe.

| ¹ SiBCS | ² T. | ³ WRB/ FAO | ⁴ Soil Taxonomy | ⁵ SG | | | ⁶ N. | ⁷ End. |
|--|-----------------|--------------------------|-------------------------------|-----------------|-----------|-----------|-----------------|-------------------|
| | | | | I | II | III | | |
| LATOSSOLO VERMELHO típico – LVd | a. | Rhodic | Dystric | 13 | 11 | 2 | 29 | LV-I |
| | ma. | Ferralsol | Rhodustox | 8 | 12 | 5 | 22 | LV-II |
| LATOSSOLO VERMELHO- AMARELO Distrófico típico – LVAd | a. | Haplic | Typic | 7 | 5 | 3 | 15 | LVA-I |
| | ma. | Ferralsol | Haplustox | 6 | 9 | 5 | 20 | LVA-II |
| PLINTOSSOLO PÉTRICO Concrecionário típico – FFc | a. | Endopetric | Petroferric | 3 | 4 | 5 | 12 | FF-I |
| | ma. | Plinthosol | Plinthaquox | 2 | 5 | 8 | 15 | FF-II |
| PLINTOSSOLO HÁPLICO típico – FXd | ma. | Haplic | Haplic | | | | | |
| | | Plintosol | Plinthaquox | | 4 | | 4 | FX |
| NEOSSOLO REGOLÍTICO típico – RRd | a. | Dystric | Typic | 1 | 9 | 7 | 17 | RR |
| | | Regosol | Ustorthent | | | | | |
| GLEISSOLO HÁPLICO tb típico – GXbd | a. | Haplic | Aquic | | 3 | 1 | 4 | GX |
| | | Gleysol | Ustorthent | | | | | |
| ORGANOSSOLO HÁPLICO típico – OXy | a. | Haplic | Typic | | 2 | 2 | 4 | OX |
| | | Histosol | Haplohemist | | | | | |
| CAMBISSOLO HÁPLICO tb típico – CXbd | a. | Haplic | Typic | 2 | 2 | 4 | 8 | CX |
| | | Cambisol | Dystrustept | | | | | |
| NEOSSOLO QUARTZARÊNICO Órtico típico – RQo | aren | Dystric | Typic Quartzi- pzament | 5 | 1 | | 6 | RQ |
| | | Arenosol | | | | | | |
| ARGISSOLO VERMELHO Eutroférico típico – Pvef | a. | Rhodic | Ferric | | | 6 | 6 | PV |
| | | Acrisol | Rhodustalf | | | | | |
| ARGISSOLO VERMELHO-AMARELO Eutroférico típico – PVAef | a. | Haplic | Ferric | | | 5 | 5 | PVA |
| | | Acrisol | Haplustalf | | | | | |
| NITOSSOLO VERMELHO chernossólico – NVem | a. | Rhodic | Mollic | | | 6 | 6 | NV |
| | | Nitisol | Rhodustalf | | | | | |
| Total | | | | 47 | 67 | 59 | 173 | |

¹ Subgrupo, Sistema Brasileiro de Classificação dos Solos (SANTOS et al., 2018); ² T.: Textura do solo, a.: argilosa, ma.: muito argilosa, aren.: arenosa; ³ Sub-ordem, *World Reference Basis for Soil Resources* (IUSS WORKING GROUP WRB, 2015); ⁴ Subgrupo, *Soil Taxonomy* (SOIL SURVEY STAFF, 2015); ⁵ SG: Superfície Geomorfológica; ⁶ Q. Quantidade de perfis; ⁷ End.: *Endmember*.

4.3.3. Análise de dados pedológicos

4.3.3.1. Estatística descritiva

Os resultados da estatística descritiva dos principais atributos dos solos nos horizontes diagnósticos (A, B, C ou F), estão dispostos na Tabela 4.2. Os dados demonstraram solos muito argilosos a arenosos (em menor proporção), com pH ácido

e altos teores de alumínio, em todas as superfícies estudadas. Lacerda e Barbosa (2012) atribuíram estas características ao substrato geológico da região, formado basicamente por rochas pelito-psamíticas.

Tabela 4.2. Estatística descritiva dos atributos dos solos por superfície geomorfológica.

| Atributos/ Parâmetros | Argila | Silte | Areia | pH | Al ³⁺ | ¹ SB | ² T | ³ V | ⁴ m | ⁵ MO |
|--|--------------------|---------|----------|------------------|-------------------------------------|-----------------|----------------|----------------|--------------------|-----------------|
| | g.kg ⁻¹ | | | H ₂ O | Cmol _c .dm ⁻³ | | | % | g.kg ⁻¹ | |
| Horizontes Diagnósticos (A, B, C ou F) | | | | | | | | | | |
| Superfície Geomorfológica I | | | | | | | | | | |
| Média | 359,7 | 95,8 | 544,5 | 5,3 | 0,5 | 1,7 | 7,3 | 22,7 | 26,0 | 37,1 |
| Erro-padrão | 77,8 | 17,8 | 91,3 | 0,2 | 0,1 | 0,4 | 0,7 | 3,7 | 7,1 | 3,3 |
| Mediana | 264,2 | 80,1 | 650,4 | 5,2 | 0,5 | 1,4 | 6,7 | 19,0 | 29,0 | 34,0 |
| *DP | 269,7 | 61,6 | 316,3 | 0,6 | 0,3 | 1,3 | 2,3 | 15,2 | 15,9 | 10,4 |
| Variância | 72718,3 | 3794,9 | 100042,7 | 0,3 | 0,1 | 1,7 | 5,2 | 231,0 | 251,5 | 107,9 |
| Mínimo | 44,9 | 10,5 | 120,7 | 4,7 | 0,0 | 0,8 | 4,5 | 12,2 | 0,0 | 25,8 |
| Máximo | 792,2 | 213,1 | 930,8 | 6,8 | 1,1 | 5,3 | 11,1 | 80,4 | 40,0 | 53,7 |
| Contagem | 48,0 | 48,0 | 48,0 | 48,0 | 48,0 | 48,0 | 48,0 | 48,0 | 48,0 | 48,0 |
| Superfície Geomorfológica II | | | | | | | | | | |
| Média | 505,1 | 312,9 | 182,2 | 5,0 | 0,8 | 2,1 | 8,8 | 23,9 | 28,5 | 33,2 |
| Erro-padrão | 43,9 | 41,3 | 67,9 | 0,1 | 0,2 | 0,3 | 0,5 | 3,5 | 5,5 | 1,8 |
| Mediana | 501,5 | 290,7 | 106,3 | 5,0 | 0,5 | 1,7 | 8,3 | 19,0 | 24,5 | 31,5 |
| *DP | 131,6 | 123,8 | 203,8 | 0,5 | 0,9 | 1,4 | 2,1 | 14,5 | 21,9 | 7,3 |
| Variância | 17321,5 | 15320,3 | 41521,3 | 0,3 | 0,7 | 1,8 | 4,6 | 211,1 | 481,5 | 53,1 |
| Mínimo | 248,3 | 46,4 | 67,3 | 3,7 | 0,0 | 0,7 | 6,3 | 6,2 | 0,0 | 22,0 |
| Máximo | 684,4 | 453,0 | 707,2 | 6,2 | 3,7 | 5,7 | 14,6 | 61,9 | 80,0 | 44,0 |
| Contagem | 66,0 | 66,0 | 66,0 | 66,0 | 66,0 | 66,0 | 66,0 | 66,0 | 66,0 | 66,0 |
| Superfície Geomorfológica III | | | | | | | | | | |
| Média | 427,5 | 310,8 | 261,7 | 5,3 | 0,5 | 4,2 | 3,3 | 7,9 | 33,8 | 9,1 |
| Erro-padrão | 25,6 | 28,4 | 26,8 | 0,1 | 0,1 | 0,2 | 0,7 | 0,8 | 2,4 | 4,9 |
| Mediana | 399,2 | 288,5 | 248,1 | 5,2 | 0,3 | 4,0 | 1,8 | 5,9 | 28,7 | 0,6 |
| *DP | 81,0 | 89,9 | 84,8 | 0,4 | 0,6 | 1,2 | 4,8 | 5,6 | 16,4 | 15,4 |
| Variância | 6557,6 | 8081,4 | 7189,1 | 0,1 | 0,3 | 1,5 | 22,8 | 31,8 | 269,2 | 238,3 |
| Mínimo | 325,6 | 161,6 | 155,4 | 4,7 | 0,0 | 2,2 | 0,5 | 3,0 | 15,0 | 0,0 |
| Máximo | 568,6 | 493,4 | 465,6 | 6,5 | 2,1 | 7,2 | 25,7 | 34,0 | 85,0 | 49,0 |
| Contagem | 59,0 | 59,0 | 59,0 | 59,0 | 59,0 | 59,0 | 59,0 | 59,0 | 59,0 | 59,0 |

¹ pH em H₂O; ² Soma das bases; ³ Capacidade de troca catiônica; ⁴ Saturação por bases; ⁵ Saturação por alumínio; Matéria orgânica no solo; * Desvio-padrão.

A Figura 4.3 auxiliaram na observação das diferenças entre os atributos físicos dos solos nas diferentes superfícies, com destaque para os solos muito argilosos na SG-III e arenosos na SG-I. A presença de Neossolos Quartzarênicos e demais classes com textura média nas bordas das chapadas elevadas do DF colaboraram para a maior granulometria da SG-I e SG-II (LACERDA et al., 2016).

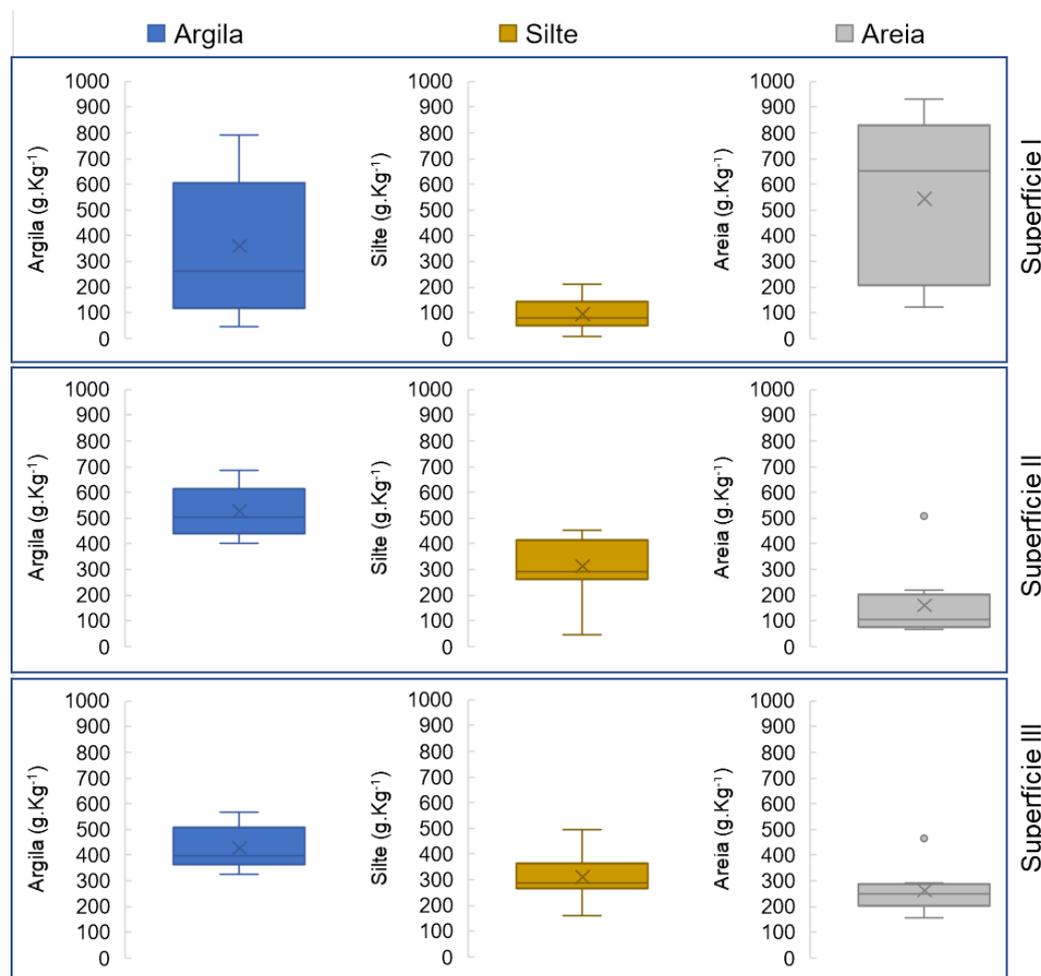


Figura 4.3. Gráfico de caixa com a distribuição empírica dos dados de textura dos solos nas três superfícies geomorfológicas.

Em geral, os solos também apresentaram baixos teores de bases trocáveis e presença de alumínio, típicos em ambiente de Cerrado, cujas rochas pelíticas são pobres de micro e macronutrientes. Contudo, esse fator pode ser contornado com correção e adubação dos solos. Como consequência, a capacidade de troca catiônica (CTC) média esteve abaixo de 50%, o que configura solos distróficos (Figura 4.4), com valores de fertilidade natural e matéria orgânica baixos, comum em solos tropicais (CARVALHO et al., 2014; FINK et al., 2014).

Os atributos químicos variaram entre as classes nas três superfícies estudadas. Como ilustra a Figura 4.4, os solos das SG-I e SG-II exibiram valores de pH em H₂O

próximos e a SG-III mostraram solos mais ácidos e maiores teores de matéria orgânica, devido aos pontos de coleta estarem, em sua maior parte, em áreas de vegetação natural. Os altos percentuais de saturação por alumínio refletem os solos sem correção da acidez como descrito por Fink et al. (2014). Por outro lado, as práticas de correção e adubação na SG-II, elevaram os percentuais de saturação por bases em áreas sob sistema de plantio direto (SPD) (NOVAIS e LACERDA, 2021).

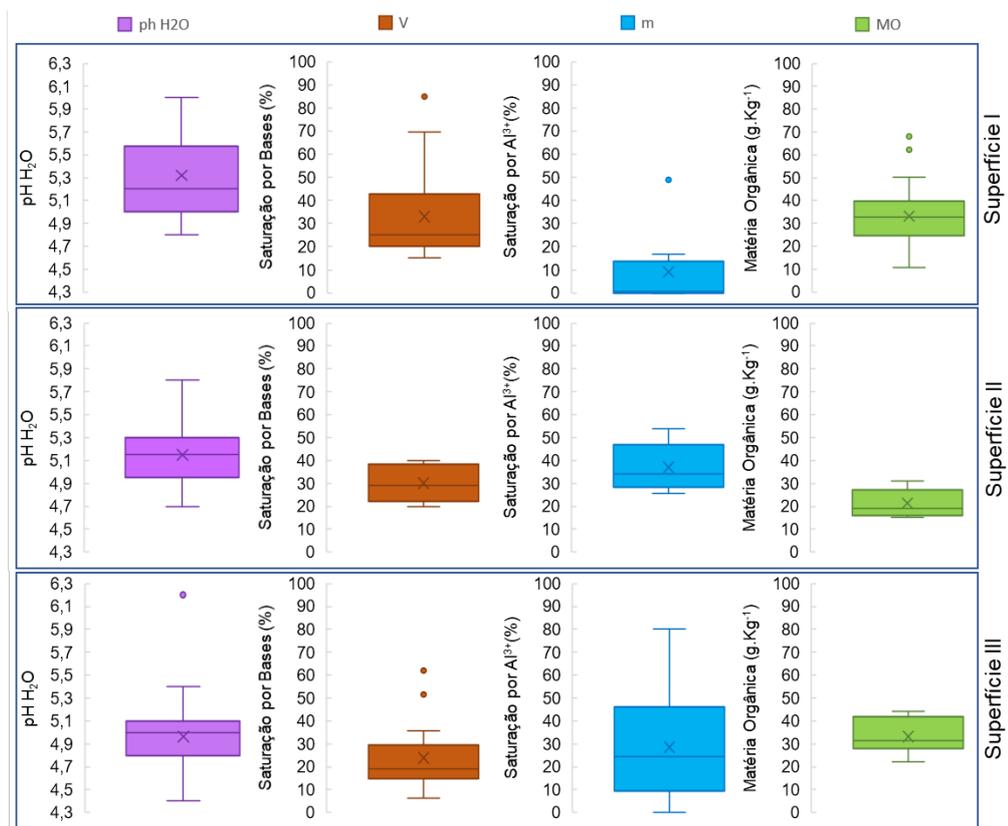


Figura 4.4. Gráfico de caixa com a distribuição empírica dos dados dos atributos químicos dos solos nas três superfícies.

Ainda sobre a Figura 4.4, nota-se que os teores de matéria orgânica estiveram dentro da normalidade na SG-I e SG-II, pois a maior parte das áreas de amostragem estavam sob SPD, que preserva a palhada sobre a superfície do solo. Além dos solos como OX e GX, que são tipicamente ricos em material orgânico, aqueles solos sob

vegetação natural e sob agricultura em SPD também contribuíram para maiores teores de matéria orgânica, como observados por POPPIEL et al. (2019a).

Com relação aos solos da SG-III, os perfis ao norte do DF apresentaram alta fertilidade natural, como as classes PV, PVA, NV e outros com gradiente textural e caráter eutrófico. Esses solos diferem quimicamente dos demais devido às litologias carbonatadas, contudo a amostragem desses, não foi suficientemente capaz de alterar o comportamento geral dos dados pedológicos analisados nesta região, como descrito por Souza et al. (2006).

4.3.3.2. Correlação e análise de principais componentes

A Figura 4.5 exibe os gráficos de correlação de Pearson e os resultados das PCAs entre os sete atributos dos solos investigados. Os valores de correlação mostraram-se variados entre a textura e os atributos químicos, como pH em H₂O, V%, m% e matéria orgânica. Devido à pedogênese em ambientes tropicais e rochas pobres em bases, os solos são naturalmente ácidos e com elevados teores de Al³⁺ nas argilas (CARVALHO et al., 2014). Similarmente, Poppiel et al. (2019a) observaram alta correlação positiva entre os valores de V% e pH em H₂O na SG-II.

As práticas de correção do pH, em áreas de agricultura, com calagem e gessagem, neutralizam os efeitos tóxicos causados pelo Al³⁺. Esta característica justifica a correlação negativa com o pH em H₂O, os baixos valores de m% e elevação do V% encontrados nos solos das SG-II e SG-III (Figura 4.5b e 4.5c, respectivamente). Os demais resultados de correlação foram considerados redundantes, devido às covariáveis possuírem autocorrelação ou colinearidade, como os teores de silte e valores de saturação por bases, por exemplo.

Os gráficos de autovalores e autovetores (Figura 4.5) demonstraram que 85% dos conjuntos de dados podem ser explicados pelas cinco primeiras variáveis em todas as SGs. Essas, foram relacionadas à textura do solo, contudo, os procedimentos de normalização dos dados podem influenciar no desempenho do algoritmo de forma a tender para aqueles valores com uma escala maior (LOURENÇO et al., 2020). Apesar disso, os valores de matéria orgânica, pH e saturação por Al^{3+} se mostraram representativos para os conjuntos de dados, como observado por Novais et al. (2021).

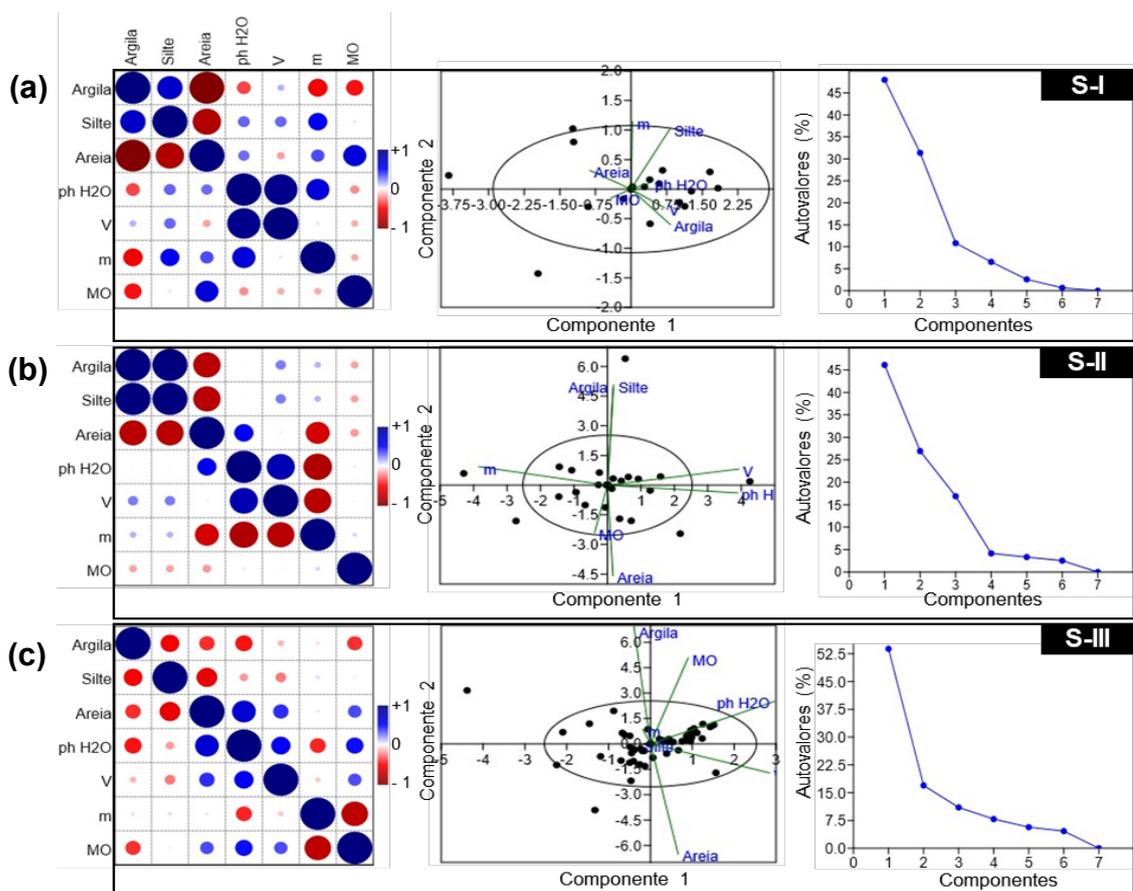


Figura 4.5. Correlação de Pearson, análise de componentes principais e gráfico de autovalores dos atributos dos solos nas SG-I (a), SG-II (b) e SG-III (c).

4.3.3.3. Comportamento espectral dos *endmembers*

As assinaturas espectrais dos Latossolos Vermelhos (LV) (Figura 4.6a) exibiram feições de absorção típicas de óxidos de ferro como hematita – Ht (0,577 e

0,85 μm) e goethita – Gt (0,445 e 0,950 μm) (BAPTISTA e TEOBALDO, 2017), além da caulinita – Ct, em uma inflexão do lado esquerdo da feição de absorção em 1,4 μm , relacionada à água adsorvida (LIU et al., 2020). Já a feição da gibbisita – Gb pode ser observada em 2,265 μm , como afirmou Demattê et al. (2014).

De modo semelhante aos LV, os espectros dos Latossolos Vermelhos-Amarelos (LVA) (Figura 4.6b), porém com fator de reflectância menor. Notadamente, as feições de Ht foram mais proeminentes nos LV, enquanto as feições de Gt foram mais acentuadas nos LVA (Figura 4.6b). A curva do LVA-II demonstrou um maior teor de MO que, associada à sua textura mais fina que o LVA-I, rebaixou o albedo, sobretudo no espectro VNIR.

Os espectros dos Plintossolos Pétricos (FF) (Figura 4.6c) alcançaram níveis de reflectância máximos de 0,35 μm , para o FF-I, e 0,5 μm , para o FF-II, influenciados pela textura muito argilosa associada ao efeito atenuante da matéria orgânica sobre as feições das curvas (DEMATTE et al., 2014). Apesar disso, foi possível observar feições dos óxidos de Fe em pontos específicos, como nos espectros LV e LVA, com predominância de Gt em relação à Ht, além das feições de absorção de Ct (1,4 μm e 2,205 μm), de grupos hidroxila (1,4 μm) e de traços de Gb (em 1,9 μm e 2,265 μm), como também observado por Baptista et al. (2019). Vale ressaltar que as amostras de FF foram analisadas na fração terra fina seca ao ar, que representa uma matriz latossólica, já que os fragmentos maiores (petroplintitas) são descartadas durante o fracionamento (NOVAIS et al., 2021).

Os fatores de reflectância dos espectros de referência dos RR e RQ, na representação acima (Figura 4.6d), oscilaram entre 0,4 μm e 0,5 μm . Os óxidos de Fe exibiram os menores picos de absorção no espectro de referência do RQ. Da mesma forma, as feições de Ct e Gb alcançaram menor reflectância. Também foi observado

um maior efeito obliterante proveniente da matéria orgânica no RQ em relação ao RR. Notou-se, ainda as feições mínimas de típicas de absorção por água, de Ct e de Gb.

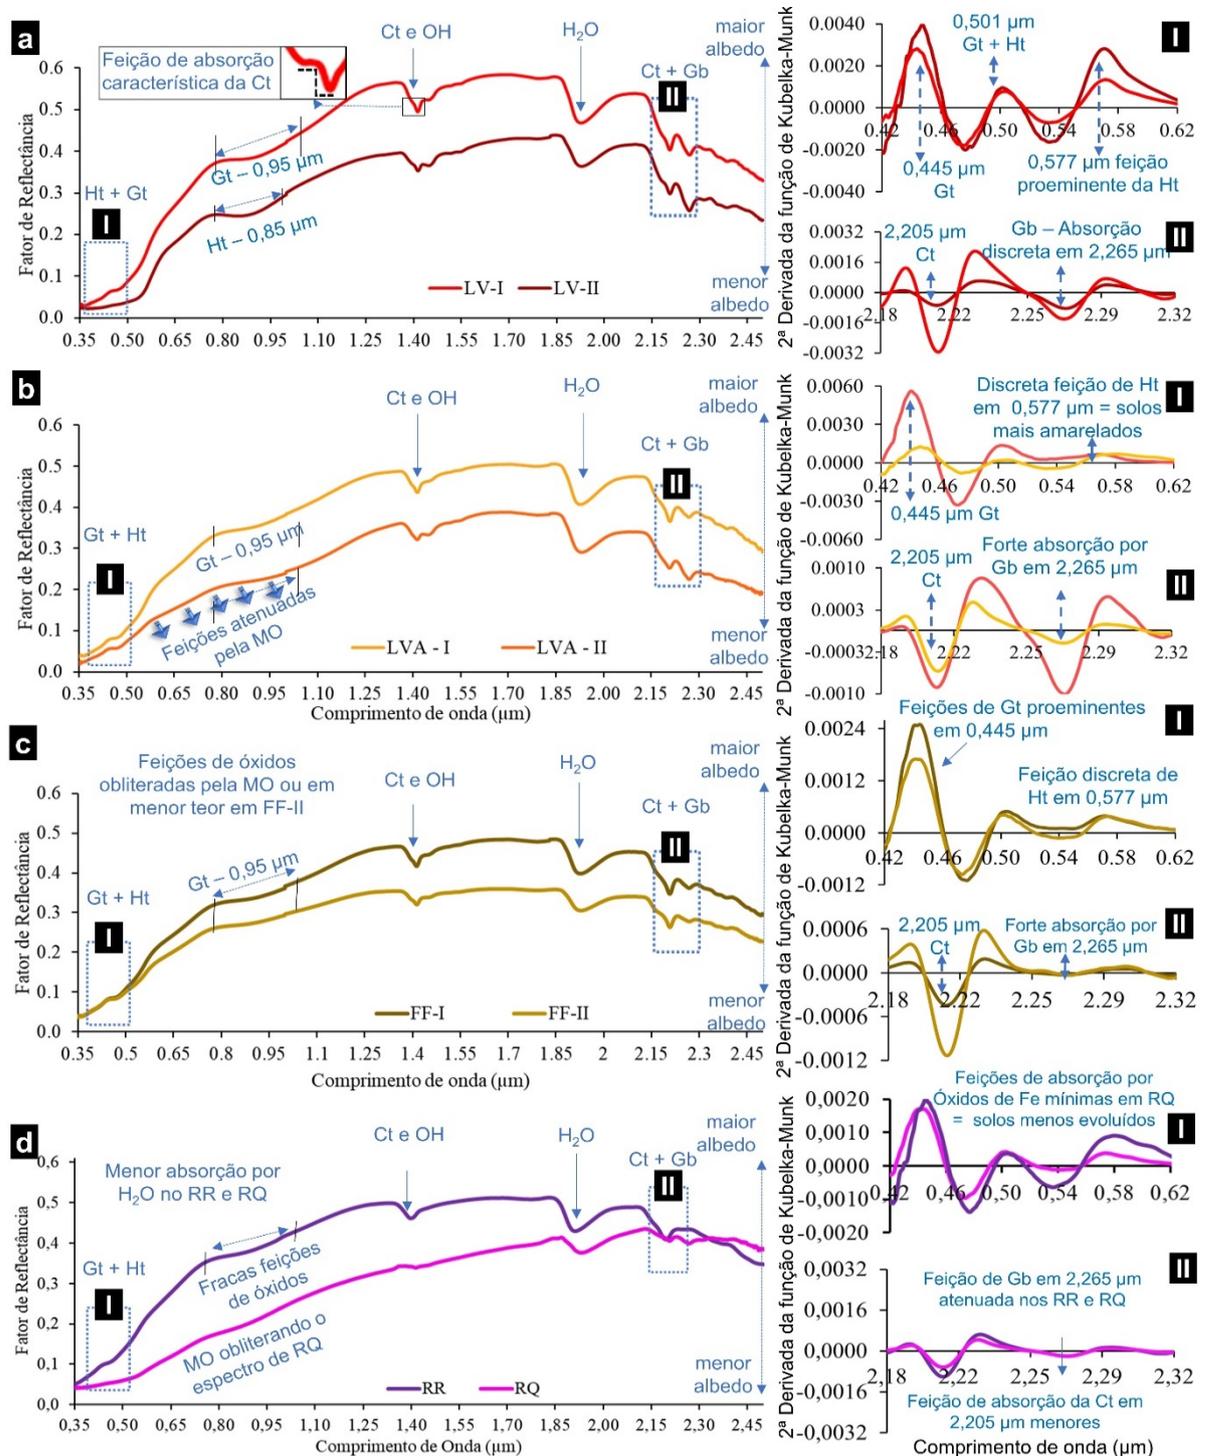


Figura 4.6. Comportamento espectral (a) Latossolos Vermelhos (LV-I e LV-II), (b) Latossolos Vermelhos-Amarelos (LVA-I e LVA-II), (c) Plintossolos Pétricos (FF-I e FF-II) e (d) Neossolo Regolítico (RR) e Neossolo Quartzarênico. Ht: Hematita, Gt: Goethita; Ct: Caulinita; Gb: Gibbsita; MO: Matéria orgânica.

Os espectros das classes PV e PVA são exibidos na Figura 4.7a, os quais demonstraram aspecto que remete ao comportamento espectral dos Latossolos, com a diferença de possuírem um menor albedo devido à granulometria e presença de feições de minerais primários, como também foi observado por Rizzo et al. (2016). Esses endmembers demonstraram absorção acentuadas por óxidos de ferro, sobretudo no PV em que prevalece a Ht em relação à Gt (NOVAIS et al., 2021).

De maneira semelhante, o espectro de referência do NV (Figura 4.7b) apresentou feições características de minerais primários e forma geral típica de solos tropicais altamente intemperizados com suas feições de óxidos mais proeminentes que as demais classes, como relatado por Rizzo et al. (2016). Um único *endmember* representou a classe dos Cambissolos Háplicos Distróficos argilosos – CX (Figura 4.7b) que demonstrou feições de minerais mais destacadas, especialmente na proporção de Gt, Ht e Ct em relação a Gb, como descrito por Baptista et al. (2019) ao analisarem a reflectância dos solos tropicais. Assim, o espectro do CX demonstrou um comportamento peculiar quanto à presença de feições de óxidos de ferro. Demattê et al. (2012) afirmaram que esta classe apresenta comportamentos variados. Como se trata de uma categoria intermediária no aspecto pedoevolutivo e geomorfológico, pode assumir características similares às classes às quais estão associadas.

Os solos hidromórficos contêm um teor de matéria orgânica elevado, o que oblitera algumas feições espectrais que caracterizam os solos (NOVAIS et al., 2021). No caso dos GX e OX (Figura 4.7c), essa característica é marcante nos horizontes superficiais, que causou uma forte absorção, principalmente na região do espectro visível com um alto albedo na faixa do infravermelho (1,25 μm a 2,50 μm). As feições relativas aos argilominerais foram obliteradas pela MO em ambos os espectros.

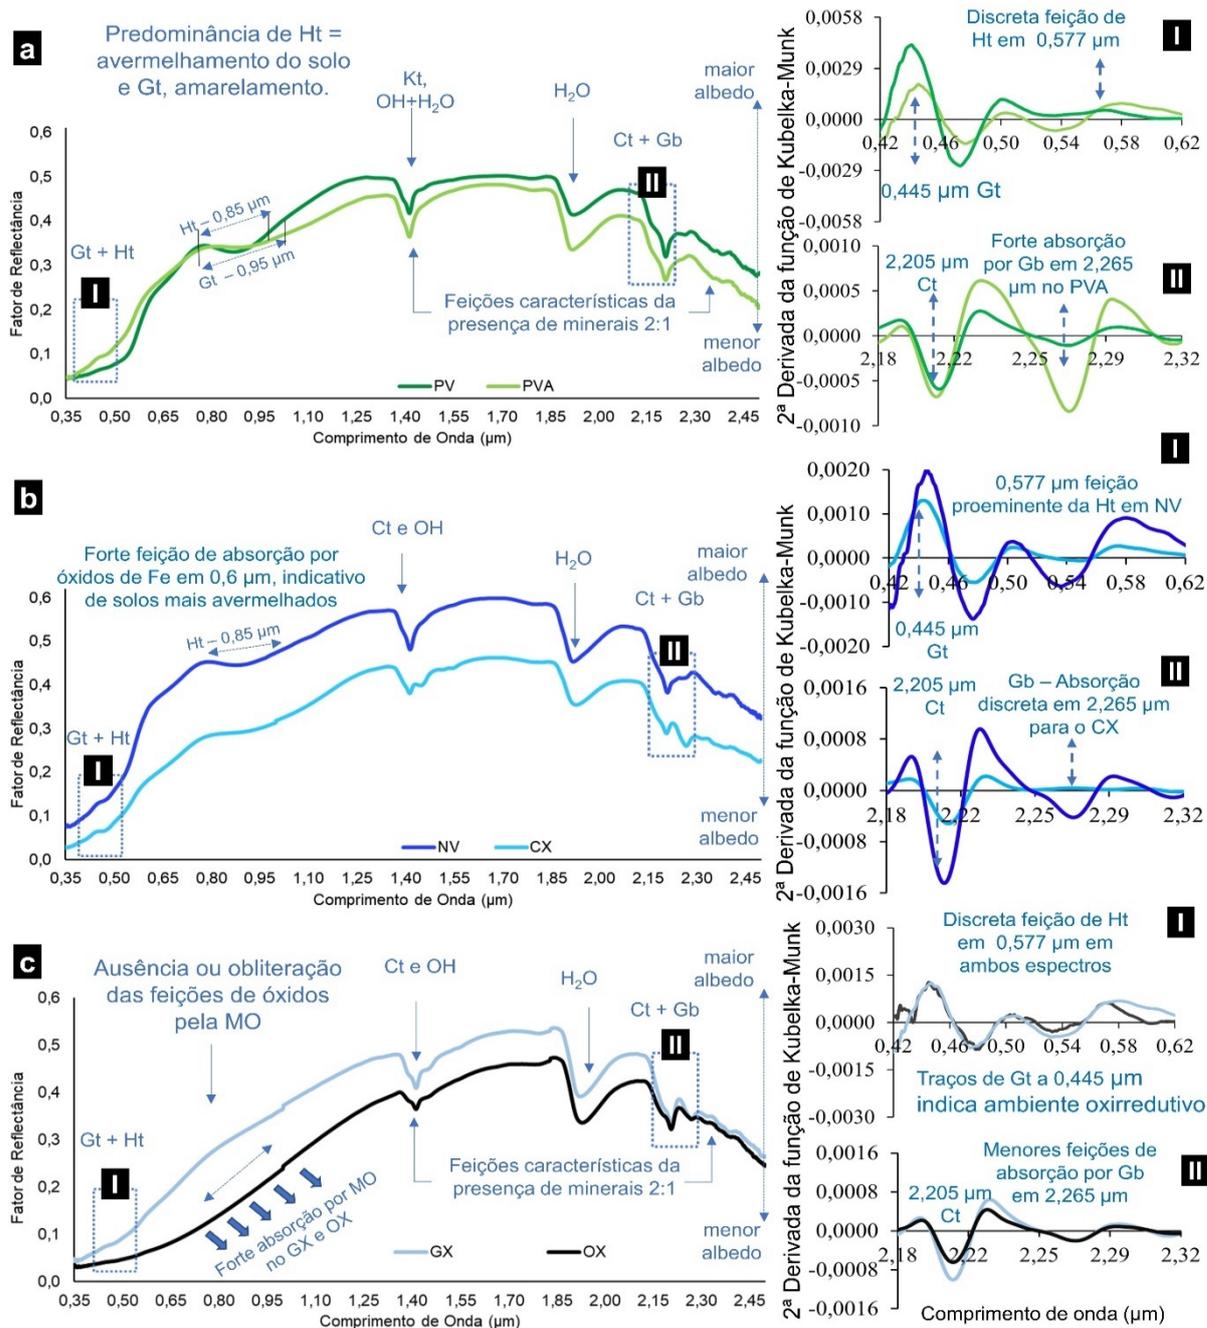


Figura 4.7. Comportamento espectral do (a) Argissolo Vermelho (PV) e Argissolo Vermelho-Amarelo (PVA), (b) Nitossolo Vermelho (PV) e Cambissolo Háplico (CX) e (c) Gleissolo Háplico (GX) e Organossolo Háplico (OX). Ht: Hematita, Gt: Goethita; Ct: Caulinita; Gb: Gibbsita; MO: Matéria orgânica.

4.3.4. Análise da imagem sintética de solos e rochas expostas

Séries temporais de dados de sensoriamento remoto possibilitam o acompanhamento da dinâmica dos alvos (SANO e BORGES, 2019). Nesse sentido,

a aplicação do *script* na plataforma GEE, disponível em Poppiel et al. (2019b), viabilizou a compilação da imagem sintética de solos/rochas expostas SySI (DEMATTÊ et al., 2018). Esse algoritmo contabilizou as áreas onde houve ao menos um registro de solo exposto em cada superfície geomorfológica. Os dados obtidos por meio da multiplicação da área do pixel pela quantidade de pixels da SySI de cada SG estão organizados na Tabela 4.3.

Tabela 4.3. Contabilização das áreas de solos expostos por superfície geomorfológica e total.

| Sup. | Área útil | | | Área suprimida | | | SySI Total | | |
|--------|-------------|-------------------|----------------|----------------|-------------------|----------------|-------------|-------------------|----------------|
| | Pixels | ¹ área | ² % | pixels | ¹ área | ² % | pixels | ¹ área | ² % |
| SG-I | 1.306.402,0 | 1.175,8 | 20,4 | 592.158,0 | 532,9 | 9,3 | 1.898.560,0 | 1.708,7 | 29,7 |
| SG-II | 1.589.283,0 | 1.430,4 | 24,8 | 983.718,0 | 885,3 | 15,4 | 2.573.001,0 | 2.315,7 | 40,2 |
| SG-III | 1.179.166,0 | 1.061,2 | 18,4 | 750.141,0 | 675,1 | 11,7 | 1.929.307,0 | 1.736,4 | 30,1 |
| Total | 4.074.851,0 | 3.667,4 | 63,7 | 2.326.017,0 | 2093,4 | 36,3 | 6.400.868,0 | 5.760,8 | 100,0 |

*Superfície; ** área do pixel = $9 \cdot 10^{-4}$ km²; ¹ área em quilômetros quadrados (km²); ² Percentual com base na área total do Distrito Federal (5.760,8 km²).

A maior área útil foi encontrada na SG-II. Apesar do alto percentual de supressão de feições de solos expostos, causado pelas áreas urbanas, a área nesta região foi incrementada pela forte presença de agricultura, especialmente sob SPD no leste do DF (HUNKE et al., 2014). O registro de solos expostos na SG-I também foi prejudicado pela presença de área urbana, que foi suprimida pela metodologia de geração da SySI pela aplicação de máscara (DEMATTÊ et al., 2018).

Uma série temporal mais robusta tem potencial de fornecer dados que melhorarem a modelagem (SANO e BORGES, 2019). Neste trabalho, foram alcançados 63,7% da área total do DF. Esse número, considerado alto, foi obtido em decorrência práticas agrícolas sob SPD, amplamente adotado na região Centro-Oeste do Brasil, associado ao clima do Cerrado com época de estiagem com baixa umidade relativa do ar, o que favorece a exposição natural dos solos, especialmente em áreas

savânicas e campestres do Cerrado (SANO et al., 2019a). A Tabela 4.4. lista alguns estudos no Brasil e no mundo que utilizaram métodos semelhantes para extração de feições de solos e alcançaram resultados próximos aos deste trabalho.

Tabela 4.4. Estudos que utilizaram imagem sintética de solos expostos.

| Autoria | Região do estudo | Período de imageamento | Porcentagem |
|------------------------|--------------------------------|-------------------------------|--------------------|
| Demattê et al. (2016) | Brasil, Sudeste e Centro-Oeste | 1984-2012 | 85 |
| Diek et al. (2017) | Platô suíço | 1984-2016 | 43 |
| Rogge et al. (2018) | Alemanha | 1984-2014 | 26 |
| Gallo et al. (2018) | Brasil, Sudeste | 1984-2017 | 53 |
| Fongaro et al. (2018) | Brasil, Sudeste | 1984-2011 | 68 |
| Demattê et al. (2018) | Brasil, Sudeste | 1984-2018 | 68 |
| Poppiel et al. (2019a) | Brasil, Centro-Oeste | 1984-2018 | 74 |
| Poppiel et al. (2019b) | Brasil, Centro-Oeste | 1984-2019 | 100* |
| Demattê et al. (2020) | Global | 1985-2015 | 34 |
| Novais et al. (2021) | Brasil, Centro-Oeste | 1984-2020 | 81 |

*Área ampliada por meio de interpolação pelo método de krigagem sobre a SySI.

A Figura 4.8 exibe o percentual de solos expostos por SG. Convém salientar que a área urbana cobre boa parte da região de estudo, sobretudo a SG-II, o que prejudica a captação de solos expostos pela metodologia adotada (DEMATTE et al., 2018). Feições de atividades antrópicas como edificações, pavimentos, telhados de cerâmica e amianto, entre outros materiais, possuem reflectâncias similares às dos solos (BAPTISTA et al., 2019), razão pela qual optou-se por excluir esses alvos mediante recortes nos polígonos referentes às SG. Em contrapartida, Novais e Lacerda (2021) ressaltaram que essa área é marcada pela ação antrópica para fins de agricultura intensiva, que expõe o solo periodicamente, que favorece a captação de feições de solo exposto por sensores orbitais.

A SG-III foi a que menos contribuiu para a SySI na região. Essa região mais dissecada do relevo comporta boa parte das Áreas de Preservação Permanentes (APP) e reservas legais do DF. Geralmente, elas permanecem recobertas por vegetação durante o ano, contudo, em épocas de estiagem severa a moderada, a

vegetação de cerrado expõe parcialmente o solo (NOVAIS e LACERDA, 2021). Além disso, as queimadas suprimem a biomassa vegetal, e até que se regenere, o solo é registrado pelos sensores orbitais (NEVES et al., 2018).

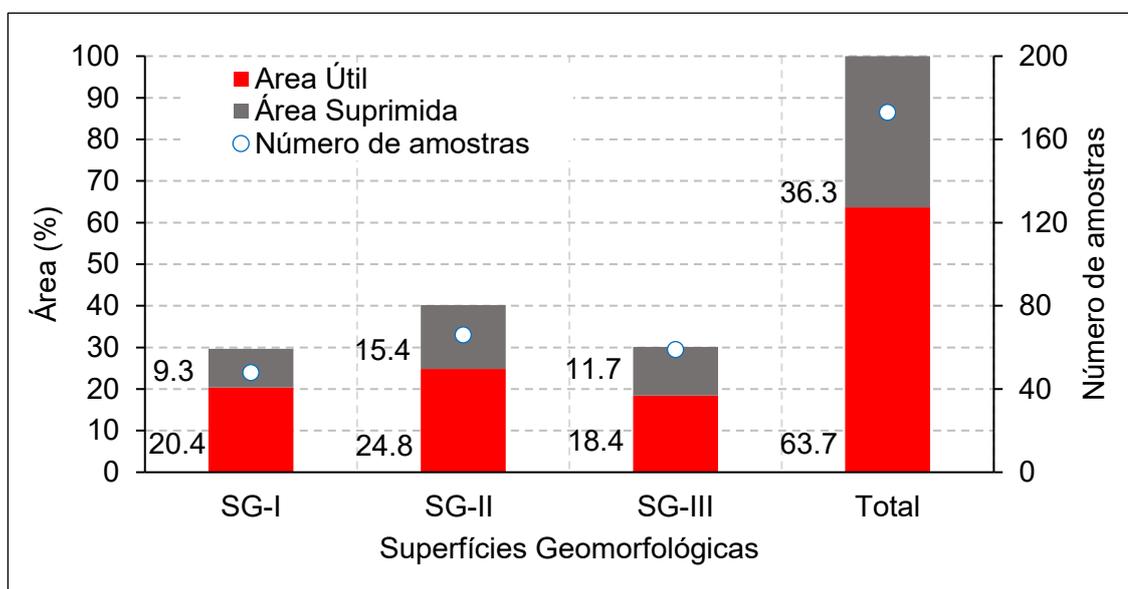


Figura 4.8. Gráfico integrado com a porcentagem de área útil e suprimida e o número de amostragem por superfície estudada.

A imagem sintética de solos expostos, com a aplicação da composição em falsa-cor (R5G4B3). Os contrastes entre os fatores de reflectância dos solos na banda 5 (SWIR I, 1,55 μm – 1,75 μm) e na banda 3 (vermelho, 0,63 μm – 0,69 μm) do sensor TM causam esta coloração nas feições de solos (DEMATTÉ et al., 2018; 2020). Dessa forma a equalização de histograma acarretou diferentes tons em roxo, os quais representam solos argilosos, que destacam as faixas espectrais do vermelho e SWIR I, em tons magenta, aqueles solos com textura mais grossa, portanto que refletem mais na região do SWIR II do Landsat TM 5 (Figuras 4.9a, 4.9b e 4.9c), essas se encontram ampliadas e mosaicadas no Apêndice A.

Nesse sentido, a SG-I (Figura 4.9a) exhibe extensas áreas com feições de solos expostos homogêneos devido à paisagem plana e presença de atividades antrópicas.

Da mesma forma, na porção leste do DF, na SG-II (Figura 4.9b), demonstram padrões poligonais que denotam áreas agrícolas consolidadas. Por outro lado, a imagem da SG-III (Figura 4.9c) exibiu feições fragmentadas causadas por irregularidade na frequência de exposição dos solos, sobretudo em regiões de vegetação natural.

Ainda na figura 4.9c, a SG-III apresentou tons mais escuros que as demais (em roxo). Esse fato pode ser atribuído às sucessivas queimadas que ocorreram na área durante o período de imageamento avaliado. A técnica de extração de feições de solos exposto registrou o intervalo entre o fim da queimada e a rebrota da vegetação. Apesar da aplicação dos índices espectrais, o efeito residual da vegetação na mistura espectral altera a curva de reflectância, como observado por Poppiel et al. (2019a; 2019c) e Novais et al. (2021).

Ademais, a metodologia captou áreas urbanizadas que passaram pelas máscaras no processo de geração da SYSI e rodovias que foram contabilizadas como feições de solos expostos. Vale ressaltar que a metodologia utilizada para a compilação da imagem de solos expostos encontra-se em constante desenvolvimento (DEMATTE et al., 2018; 2020). Portanto com o aumento da quantidade de dados disponíveis no legado de imagens Landsat e a implementação de índices espectrais que filtrem as feições de solos expostos podem melhorar a qualidade dos dados.

O mosaico com a frequência de registros de feições de solos expostos nas três SGs é exibido na Figura 4.9d, a qual demonstra que aproximadamente 36% de toda a extensão do DF estiveram sem registro de solos expostos ao longo da série temporal avaliada. Essas regiões coincidem com as áreas urbanizadas e as áreas de preservação, em maior parte sobre a SG-III. Por outro lado, 52,51% obtiveram entre 1 e 40 registros em áreas de vegetação natural e zonas urbanas não suprimidas.

Áreas com frequências maiores que 120 registros representam regiões fortemente antropizadas como urbanizações, rodovias, além de mineração, áreas que passaram pelos filtros arbitrados no processo de elaboração da SySI. O leste do DF é marcado pela intensa exploração agrícola sob sistema de plantio direto (SPD). Notadamente, esse fato contribuiu para o incremento na frequência em que os solos expostos e foram captados pelo sensor orbital (DEMATTE et al., 2018).

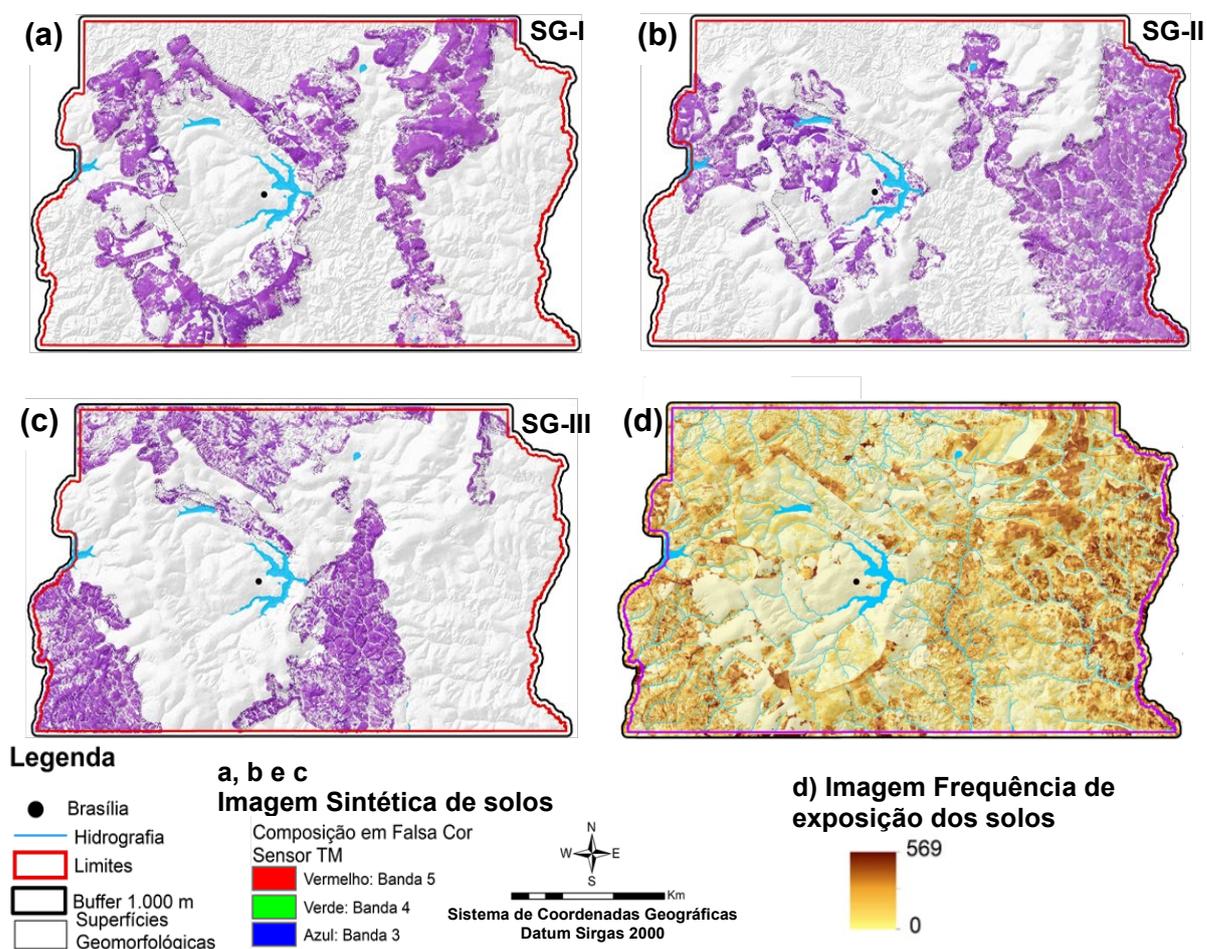


Figura 4.9. Imagem sintética de solos e rochas expostas nas superfícies geomorfológicas SG-I (a), SG-II (b) e SG-III (c) e Imagem de frequência e percentuais de exposição dos solos do Distrito Federal (d).

4.3.5. Desempenho da modelagem espectral

4.3.5.1. Avaliação dos erros de predição

O método MESMA modelou 100% dos pixels da SySI em todas as superfícies analisadas, ou seja, cada informação dos pixels foi modelada pelo menos por um espectro de referência. Além dos modelos de mistura espectral, o processamento gerou uma imagem de RMSE, no qual é possível observar o melhor ajuste (menor erro) (Figura 4.10a). Os tons em rosa claro indicam valores baixos de RMSE (a partir de 0%), e tons vermelho escuro, valores máximos (2,5%) de RMSE.

Os erros médios foram 1,71%; 1,63% e 2,37%, para as SG-I, SG-II e SG-III, respectivamente. Os maiores percentuais de erro na SG-III ocorreram devido a menor quantidade de dados de solos expostos registrados na série temporal, além do efeito residual das queimadas e relevo acidentado, condições opostas às observadas nas SG-I e SG-II. Poppiel et al. (2019a) alcançaram valores de erro em torno de 0,03 na mesma região, e atribuíram esse resultado à pequena extensão da área de estudo somado às condições ambientais que favoreceram o registro de feições de solos. Novais et al. (2021), também obtiveram baixos percentuais de erro (1,3%) na modelagem multiespectral com múltiplos *endmembers* na porção leste do DF.

A fração global dos espectros de referência modelados (Figura 4.10b) foi considerada alta, com proporção média geral de 71%, o que significa que três de cada quatro partes dos pixels contribuíram para a modelagem pelo método MESMA. Os tons em azul escuro indicam maiores percentual de fração de *endmember* utilizado coincidiu com as áreas da SG-I nas áreas planas das chapadas elevadas e as áreas de agricultura consolidadas da SG-II, a leste do DF.

Na SG-III, ocorreram os menores valores de fração de *endmembers* modelados (áreas em azul claro). Esta área contém vegetação natural que dificulta a captação de pixels de solos expostos pela metodologia. Resultados semelhantes foram identificados por Poppiel et al. (2019a) e Novais et al. (2021) em modelagens via algoritmo MESMA no DF. Assim como na imagem RSME, as regiões em matizes que variam do branco ao cinza claro representam os locais suprimidos, sem informações espectrais para a modelagem (NOVAIS et al., 2021).

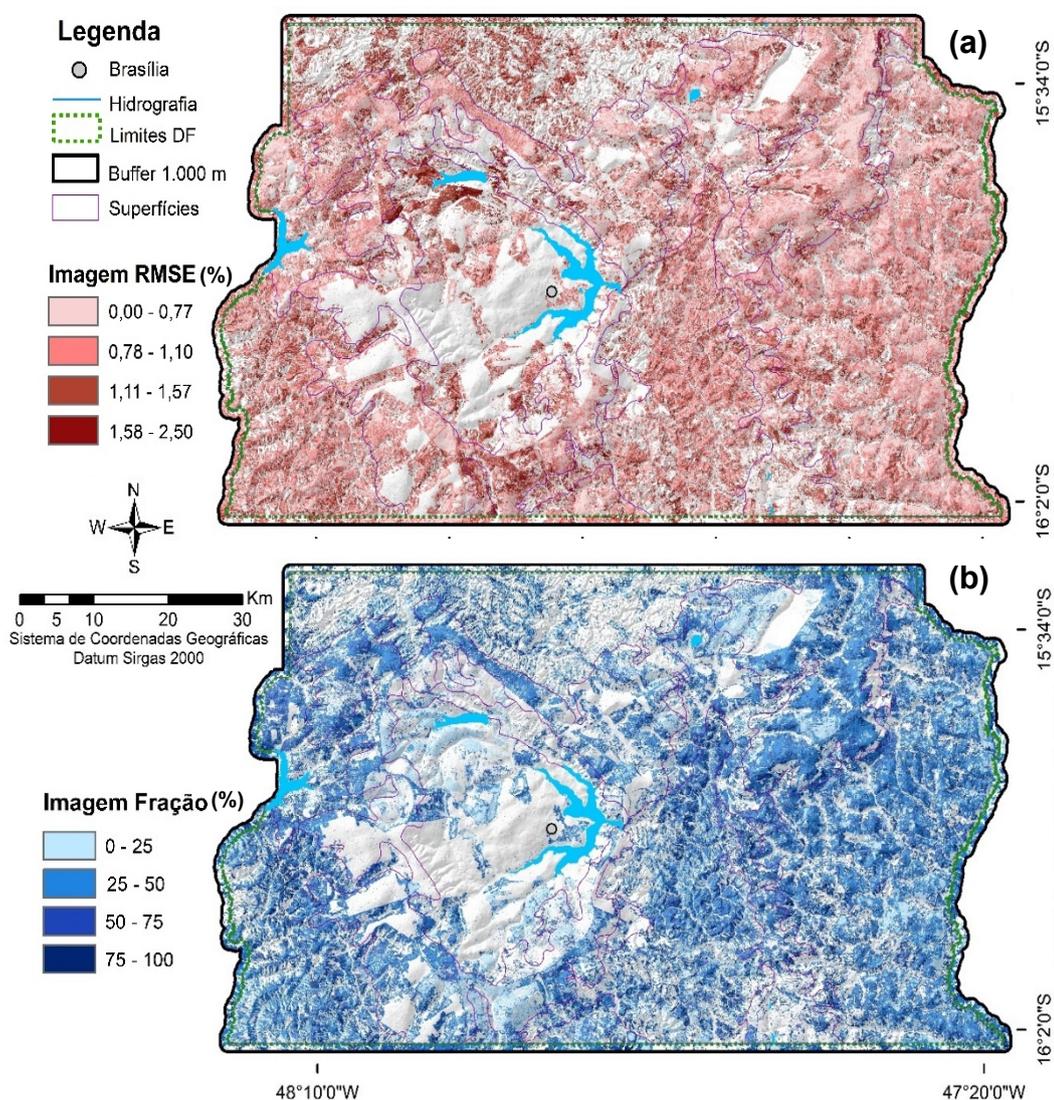


Figura 4.10. Imagem da raiz quadrada média do erro da modelagem (a) e Imagem-fração dos espectros de referência modelados (b). As regiões em cores branca e cinza claro representam os locais suprimidos.

4.3.6. Espacialização dos modelos de mistura espectral

4.3.6.1. Modelagem de solo por superfície geomorfológica

Na SG-I, cerca de 1.176 km² foram mapeados, ou seja, aproximadamente 69% da área individualizada, sem considerar a área *buffer* determinada (Figura 4.11a). Essa área corresponde a 20,4% de toda extensão territorial do DF, computados pelos pixels captados pela metodologia de geração da SySI ao longo da série temporal estudada. Entretanto, 533 km² da SG-I foram suprimidas pelos mesmos motivos discutidos na seção 4.3.4, portanto, não foram mapeadas.

Ainda sobre a SG-I, 80% dos solos da área foram modelados como Latossolos. Em segundo lugar, aparecem os Plintossolos, seguidos pelos Neossolos Regolíticos, com 14 e 7, respectivamente, nas variações de texturas encontradas na área. Os resultados concordam com os estudos realizados na região de chapadas elevadas do DF por Lacerda e Barbosa (2012), que verificaram a predominância de solos mais intemperizados na SG-I.

Os modelos identificaram todos os espectros de referência na SySI ao longo da SG-II (Figura 4.11b). Há uma ampla predominância de Latossolos. Quanto aos CX, ocorrem em faixas de transição associadas às classes LVA e FF, em que a profundidade do solo propicia a formação de um horizonte intermediário B incipiente entre as camadas superficiais e o regolito ou petroplintita (SANTOS et al., 2018). Os resultados alcançados nessa região concordam com os mapeamentos realizados (FREITAS et al., 1978; REATTO et al., 2004, LIMA et al., 2014; NOVAIS, 2017; OLIVEIRA JÚNIOR, 2017; POPPIEL et al., 2019a; NOVAIS et al., 2021).

Com menor representatividade espacial, as classes RQ e CX também foram detectadas pelo método MESMA na SG-I e SG-II. De maneira geral, os Neossolos

Quartzarênicos ocorrem pontualmente em condições pedomorfogeológicas específicas e estão associados aos afloramentos quartzíticos em declividades planas a suave-onduladas nas bordas das Chapadas Elevadas do DF (LACERDA e BARBOSA, 2012).

Com relação à SG-III, a porção oeste do DF, a metodologia captou a presença de Argissolos e Nitossolos, porém, por serem pontuais, foram suprimidos pelo processo de filtragem da imagem que continham os modelos, como ilustra a Figura 4.11c. Os Plintossolos Pétricos, predominantes nessa região, possuem textura de muito argilosa a arenosa, são distróficos, pouco profundos, moderadamente ácidos, mal drenados (quando hidromórficos), com séria restrição à percolação de água, que apresentam alagamento temporário e escoamento lento (KÄMPF e CURI, 2012).

Os FF predominaram nessa região, porém, como observado em campo, essa classe ocorre associada principalmente a RR, CX e LVA em relevo suave-ondulado a forte-ondulado (0 a 20% de declive), como em vertentes e terços inferiores das encostas, onde há movimentação lateral de água significativa (NOVAIS et al., 2021). As plintitas presentes nos perfis dos FF, quando endurecidas de maneira irreversível, transformam-se gradualmente em petroplintitas (LACERDA e BARBOSA et al., 2012).

Com menor representatividade espacial, os CX normalmente ocorrem em faixas de transição associadas às classes LVA e FF. Os resultados encontrados neste trabalho se aproximam daqueles alcançados em mapeamentos realizados na região, os quais foram descritos por Freitas et al. (1978); Reatto et al. (2004); Lima et al. (2014). Ainda nesta SG, ocorreram os Plintossolos Háplicos caracterizados por uma fina camada de MO sobre horizonte plíntico e estão relacionados aos campos de murundus, descritos por Baptista et al. (2013).

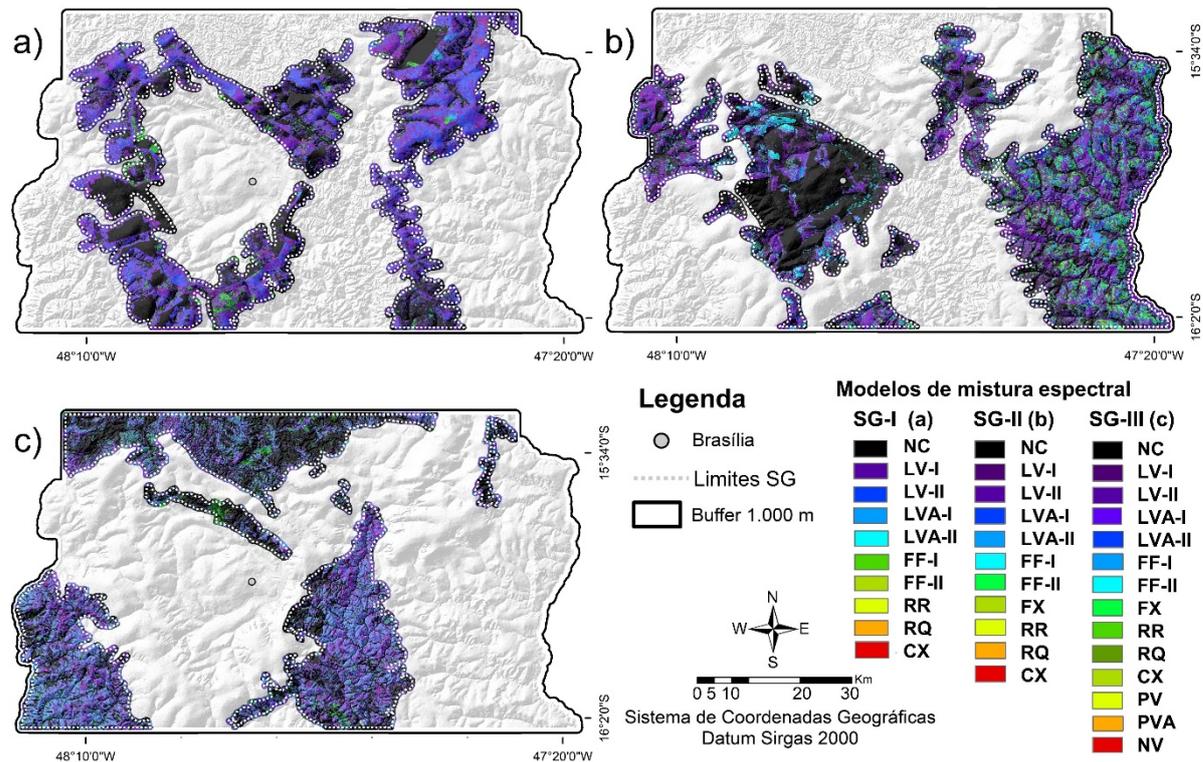


Figura 4.11. Distribuição dos modelos espectrais da SG-III. Distribuição dos modelos espectrais da SG-II. Não computado, LV-I = Latossolo Vermelho argiloso; LV-II = Latossolo Vermelho muito argiloso; LVA-I = Latossolo Vermelho-Amarelo argiloso; LVA-II = Latossolo Vermelho-Amarelo muito argiloso; FF-I = Plintossolo Pétrico argiloso; FF-II; Plintossolo Pétrico muito argiloso; FX = Plintossolo Háplico muito argiloso; RR = Neossolo Regolítico argiloso; RQ = Neossolo Quartzarênico Órtico; CX = Cambissolo Háplico argiloso; PV = Argissolo Vermelho muito argiloso; PVA = Argissolo Vermelho-Amarelo muito argiloso; NV = Nitossolo Vermelho muito argiloso.

4.3.6.2. Contabilização das áreas mapeadas e não mapeadas

As áreas e porcentagem de cada classe mapeada estão dispostas na Tabela 4.5, que destaca a predominância de Latossolos, que estão de acordo com os levantamentos realizados por Freitas et al. (1978), Reatto et al. (2004), Lacerda e Barbosa (2012), Lima et al. (2014); Oliveira Jr. (2017), Novais (2017), Poppiel et al. (2019a) e Novais et al. (2021). As classes RQ, nas SG-I e SG-II, e PV, PVA e NV, somente na SG-III, somaram apenas 1,5% da área mapeada.

A Tabela 4.5 também traz os percentuais de áreas modeladas na SG-III, bem como de regiões excluídas na metodologia. Ao todo, cerca de 1.061 km² foram mapeados, 61,12% da área total e 18,42% de todo o DF. Como já discutido, a SG-III, Região Dissecada de Vales, se distingue das demais pelo relevo fortemente movimentado com morrotes declivosos que configuram áreas de proteção ambiental, cobertos por vegetação natural campestre de Cerrado, o que levou à eliminação de 38,88% da área dessa região, como relataram Neves et al. (2018).

Tabela 4.5. Contabilização das áreas mapeadas e não mapeadas por superfície geomorfológica e total.

| Classe de solo | Textura | SG-I | | SG-II | | SG-III | | Integração | |
|--------------------|---------|-----------------|--------|-----------------|--------|-----------------|--------|-----------------|---------------|
| | | Área | | Área | | Área | | Área | |
| | | km ² | % |
| LV-I | arg. | 506,87 | 43,11 | 658,39 | 46,03 | 149,51 | 14,09 | 1314,78 | 35,85 |
| LV-II | m. arg. | 184,48 | 15,69 | 188,23 | 13,16 | 119,12 | 11,22 | 491,83 | 13,41 |
| LVA-I | arg. | 121,81 | 10,36 | 67,66 | 4,73 | 97,99 | 9,23 | 287,45 | 7,84 |
| LVA-II | m. arg. | 108,99 | 9,27 | 150,47 | 10,52 | 99,63 | 9,39 | 359,10 | 9,79 |
| FF-I | arg. | 88,65 | 7,54 | 64,79 | 4,53 | 204,44 | 19,26 | 357,89 | 9,76 |
| FF-II | m. arg. | 52,79 | 4,49 | 137,31 | 9,60 | 187,25 | 17,64 | 377,36 | 10,29 |
| FX | m. arg. | | | 58,64 | 4,10 | 40,27 | 3,79 | 98,91 | 2,70 |
| CX | arg. | 40,09 | 3,41 | 31,47 | 2,20 | | | 71,56 | 1,95 |
| RR | m. arg. | 69,96 | 5,95 | 70,80 | 4,95 | 113,92 | 10,73 | 254,68 | 6,94 |
| RQ | aren. | 2,12 | 0,18 | 2,57 | 0,18 | | | 4,69 | 0,13 |
| PV | m. arg. | | | | | 18,35 | 1,73 | 18,35 | 0,50 |
| PVA | m. arg. | | | | | 17,61 | 1,66 | 17,61 | 0,48 |
| NV | m. arg. | | | | | 13,15 | 1,24 | 13,15 | 0,36 |
| Área Mapeada | | 1175,76 | 68,81 | 1430,35 | 61,77 | 1061,25 | 61,12 | 3667,36 | 63,66 |
| Área Não Mapeada | | 532,94 | 31,19 | 885,35 | 38,23 | 675,13 | 38,88 | 2093,42 | 36,34 |
| Área da Superfície | | 1708,70 | 100,00 | 2315,70 | 100,00 | 1736,38 | 100,00 | 5760,78 | 100,00 |

LV-I = LATOSSOLO VERMELHO Distrófico típico argiloso; LV-II = LATOSSOLO VERMELHO Distrófico típico muito argiloso; LVA-I = LATOSSOLO VERMELHO-AMARELO Distrófico típico argiloso; LVA-II = LATOSSOLO VERMELHO-AMARELO Distrófico típico muito argiloso; FF-I = PLINTOSSOLO PÉTRICO Concrecionário típico argiloso; FF-II = PLINTOSSOLO PÉTRICO Concrecionário típico muito argiloso; FX = PLINTOSSOLO HÁPLICO Distrófico típico muito argiloso; CX = CAMBISSOLO HÁPLICO tb Distrófico típico argiloso; RR = NEOSSOLO REGOLÍTICO Distrófico típico argiloso; RQ = NEOSSOLO QUARTZARÊNICO Órtico típico; PV = ARGISSOLO VERMELHO Eutroférico típico muito argiloso; PVA = ARGISSOLO VERMELHO-AMARELO Eutroférico típico muito argiloso; NV = NITOSSOLO VERMELHO Eutroférico chernossólico muito argiloso.

Ao todo, o algoritmo conseguiu mapear 63,66%, ou seja, 3.667,36 km² da área do DF foram cobertos pelo modelo. Isso corresponde à totalidade de pixels captados pela metodologia de geração da SySI ao longo da série temporal estudada, como

relatado por Poppiel et al. (2019a). As áreas não mapeadas somaram 2.093,42 km² (36,34%), excluídas principalmente pelas feições de áreas urbanas e vegetação perene. Na SG-II, houve proporções das classes semelhantes a SG-I.

4.3.6.3. Avaliação do mapa digital de solos expostos do DF

As proporções das áreas das classes pedológicas das regiões estudadas, identificadas pela implementação da modelagem MESMA acompanharam a pedodiversidade do DF (FREITAS et al., 1978; REATTO et al., 2004). A contabilização das respectivas áreas está disposta na Figura 4.12. Cerca de 75% da área mapeada é composta pela classe dos Latossolos. Em segundo lugar, aparecem os Plintossolos Pétricos, seguidos pelos Neossolos Regolíticos, nas diferentes texturas (NOVAIS et al., 2021). Quanto às classes representativas da SG-III, cerca de 39,41% da área foram modeladas como Latossolos e 29,77% da área foi mapeada como Plintossolos Pétricos, seguidos pelos RR, com 23,11%, nas diferentes texturas encontradas.

Ainda na Figura 12, foi possível observar a predominância dos Latossolos em quatro subtipos que ocupam 75% da superfície do DF e cerca de 20% referem-se aos Plintossolos Pétricos, que diferem dos Latossolos por apresentarem camadas lateríticas internas nos seus perfis. Essas duas classes de solos são altamente intemperizadas típicos de solos tropicais. Poppiel et al. (2019b) e Novais e Lacerda (2021), relataram a presença das classes Plintossolos e Neossolos regolíticos na SG-II, em áreas onde o relevo se acentua, tanto no topo dos morrotes, quanto nas bases, ocorrem Latossolos (REATTO et al., 2004).

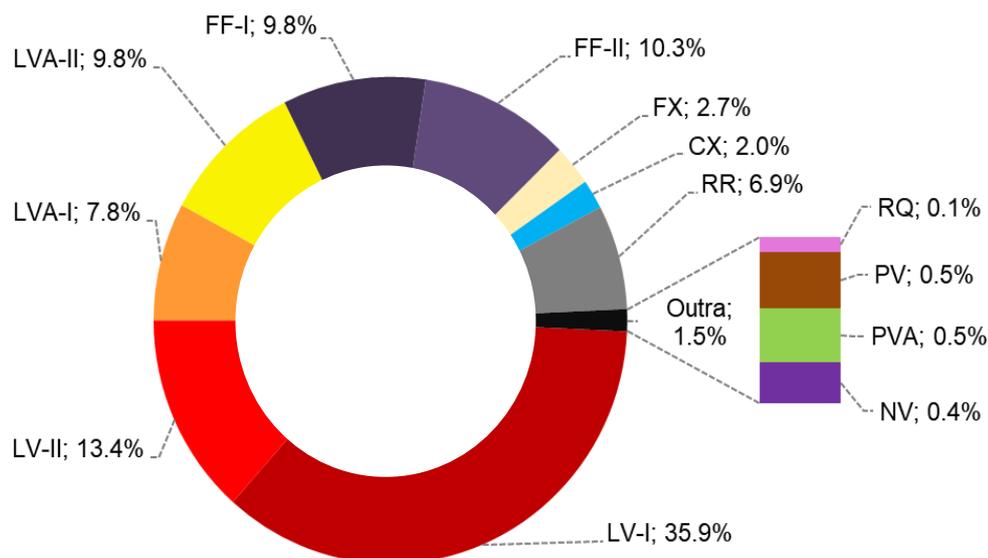


Figura 4.12. Percentuais de contribuição das classes no MDS do Distrito Federal. LV-I = LATOSSOLO VERMELHO Distrófico típico argiloso; LV-II = LATOSSOLO VERMELHO Distrófico típico muito argiloso; LVA-I = LATOSSOLO VERMELHO-AMARELO Distrófico típico argiloso; LVA-II = LATOSSOLO VERMELHO-AMARELO Distrófico típico muito argiloso; FF-I = PLINTOSSOLO PÉTRICO Concrecionário típico argiloso; FF-II = PLINTOSSOLO PÉTRICO Concrecionário típico muito argiloso; FX = PLINTOSSOLO HÁPLICO Distrófico típico muito argiloso; CX = CAMBISSOLO HÁPLICO tb Distrófico típico argiloso; RR = NEOSSOLO REGOLÍTICO Distrófico típico argiloso; RQ = NEOSSOLO QUARTZARÊNICO Órtico típico; PV = ARGISSOLO VERMELHO Eutroférico típico muito argiloso; PVA = ARGISSOLO VERMELHO-AMARELO Eutroférico típico muito argiloso; NV = NITOSSOLO VERMELHO Eutroférico chernossólico muito argiloso.

A observação do MDS gerado (Figura 4.13), ampliado e reagrupado no Apêndice B), revela que, nas áreas planas e altas, predominam os LV argilosos circundados, em cotas mais baixas, por LV muito argilosos, texturas herdadas da litologia formada por rochas pelíticas do Grupo Paranoá (LACERDA e BARBOSA, 2012). De maneira semelhante, quanto ao arranjo das classes, os LVA de topo são mais argilosos do que os das partes mais baixas das topossequências, e, frequentemente, estão associados a camadas de impedimento que dificultam a

percolação da água no perfil. Ocorrem, normalmente, em vertentes suaves do relevo onde a umidade preserva a goethita em detrimento da hematita (NOVAIS et al., 2021).

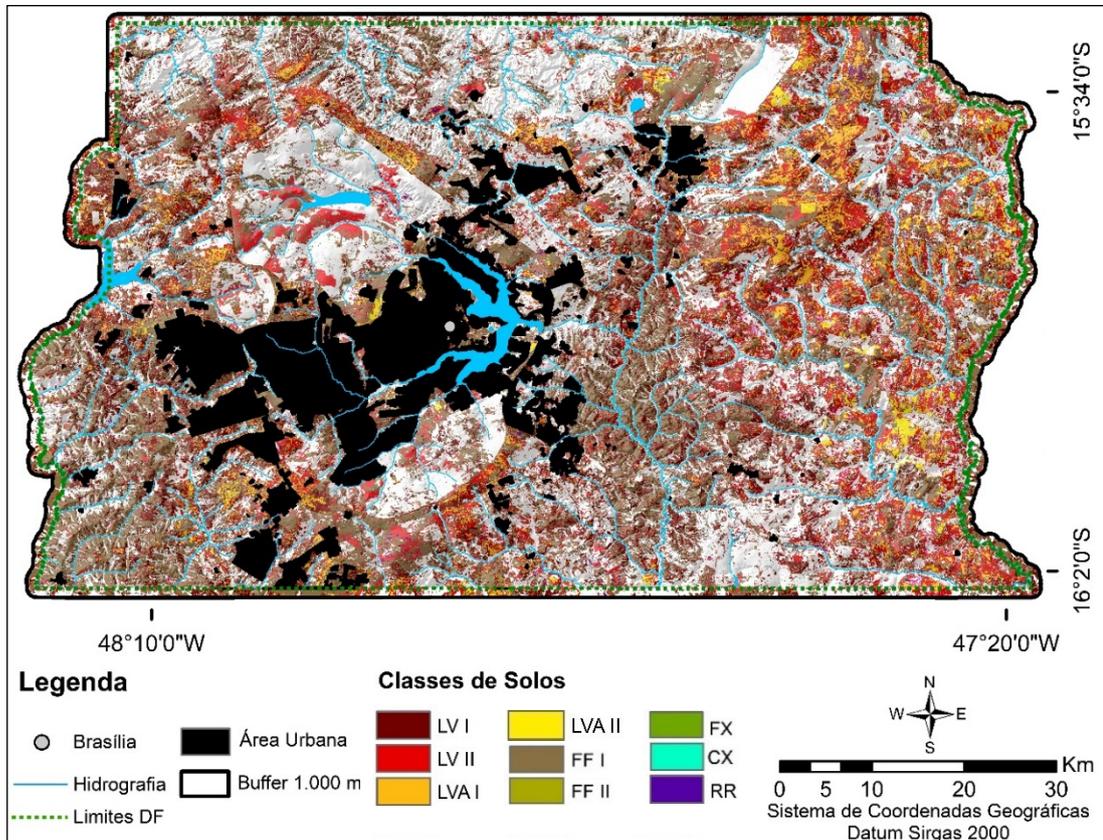


Figura 4.13. Mapa digital de solos expostos do Distrito Federal. LV-I = LATOSSOLO VERMELHO Distrófico típico argiloso; LV-II = LATOSSOLO VERMELHO Distrófico típico muito argiloso; LVA-I = LATOSSOLO VERMELHO-AMARELO Distrófico típico argiloso; LVA-II = LATOSSOLO VERMELHO-AMARELO Distrófico típico muito argiloso; FF-I = PLINTOSSOLO PÉTRICO Concrecionário típico argiloso; FF-II = PLINTOSSOLO PÉTRICO Concrecionário típico muito argiloso; FX = PLINTOSSOLO HÁPLICO Distrófico típico muito argiloso; CX = CAMBISSOLO HÁPLICO tb Distrófico típico argiloso; RR = NEOSSOLO REGOLÍTICO Distrófico típico argiloso.

À medida em que a declividade aumenta, formam-se as classes LVA, CX, FF e RR – não necessariamente nesta ordem. A classe LVA de maior granulometria ocorre nas bordas das chapadas, que corrobora com o material parental de matriz quartzítica (FREITAS-SILVA e CAMPOS, 1998). Nessa dinâmica, as classes RR e FF estão

associadas aos morrotes remanescentes da superfície geomorfológica Sul-Americana descritas por King (1956).

Ainda sobre os FF, Martins et al. (2004) acrescentaram que são de ocorrência comum em relevo convexo. Sua estrutura, de matriz latossólica e petroplíntica protege os morrotes residuais e bordas das chapadas da dissecação promovida pela dinâmica geomorfológica. Nesses locais, RR são recorrentes e surgem associados a afloramentos. Já os RQ surgem sobre o quartzito e os RR comuns em relevo plano a suave-ondulado (NOVAIS e LACERDA, 2021).

De maneira geral, o desempenho da modelagem MESMA na SG-III foi regular, pois houve a predominância de FF, porém a pedodiversidade é mais complexa, que passa pela ocorrência de associações entre diversas classes pedológicas. Assim os FF modelados nesta região representam associações RR + FF + CX + LVA + PV + PVA + NV. Dentre as causas possíveis das inconsistências encontradas nesta SG, pode-se mencionar a influência residual da vegetação natural e das queimadas que alteraram o espectro na SySI (DEMATTE et al., 2018). Além disso, o relevo movimentado nesta região pode afetar a resposta espectral. Ademais, os espectros do FF são análogos ao LVA, pois são derivados de uma matriz latossólica, a qual se diferenciam dos LVA pela maior quantidade Gt em relação à Ht e a presença mais destacada de feições de Ct (NOVAIS et al., 2021).

Embora apresentem pouca representatividade espacial, os PV, PVA e NV ocorrem em associações com outros solos, em transições interclasses. No MDS, foram registrados ao longo da porção oeste do DF. Frequentemente, essas classes têm sua gênese relacionada às rochas pelito-carbonatadas e tem ocorrência em relevo movimentado, como na SG-III (LIMA et al., 2014). As classes RQ, PV, PVA e NV foram suprimidas do MDS devido à ação conjunta de três fatores: pequena

representatividade espacial; fragmentação da imagem nas áreas de ocorrência dessas classes; e processo de filtragem. Estes fatores inviabilizaram a visualização dos polígonos no MDS, porém, foram computadas na tabela das áreas correspondentes a cada classe, porém, suprimida nos arquivos digitais gerados.

4.3.6.4. Validação dos modelos de mistura espectral

A avaliação do MDS, realizada mediante a análise da matriz de erros, com 417 pontos de validação, apresentou um índice Kappa de 0,69 (Tabela 4.6), considerada muito boa de acordo com a classificação proposta por Congalton e Green (2010). Genú et al. (2013) em São Paulo, e Novais (2017), Poppiel et al. (2019a) e Novais et al. (2021) no DF, modelaram os solos pelo método MESMA. Estes autores mapearam os solos expostos por meio da técnica de modelagem multiespectral e alcançaram a acurácia acima de 50%.

As classes LVA-I, com 75%, e RR, com 86%, alcançaram os maiores percentuais de acurácia do produtor. A peculiaridade do espectro dos RR pode ter contribuído para um maior índice de acerto. Em contrapartida, a acurácia do usuário apresentou os menores percentuais de acertos (20% e 59%) para as classes CX e FX respectivamente. Esse comportamento revela a necessidade de estudos orientados a estas classes, como destacaram Genú et al. (2013).

Quanto aos erros de omissão, os percentuais variaram de 19%, para o LV-I, a 80%, para o CX. Já os valores referentes aos erros de comissão foram de 14%, para o RR, e 75% para o CX. Os espectros variam segundo a associação interclasse, a qual o CX está relacionado. Além disso, houve baixo número de pontos de validação. Tem-se que a classe FF pode ser confundida com LVA, pois as informações espectrais do FF são geralmente extraídas da fração TFSA, uma matriz latossólica.

Tabela 4.6. Matriz do mapeamento digital de solos expostos do DF.

| Classe de solo | Verdade de campo | | | | | | | | | TOTAL | AU % | EO | |
|-----------------------|------------------|------------------|-----------|-----------|-----------|-----------|--------------|-----------|----------|------------|------|----|----|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | | | | |
| Mapa digital de solos | 1 | 81 | 9 | 5 | 1 | 1 | 0 | 2 | 1 | 0 | 100 | 81 | 19 |
| | 2 | 12 | 62 | 2 | 1 | 3 | 0 | 0 | 0 | 0 | 80 | 78 | 23 |
| | 3 | 8 | 5 | 52 | 6 | 4 | 0 | 1 | 0 | 1 | 77 | 68 | 32 |
| | 4 | 5 | 2 | 7 | 25 | 2 | 1 | 1 | 1 | 2 | 46 | 54 | 46 |
| | 5 | 2 | 6 | 2 | 7 | 26 | 3 | 0 | 0 | 0 | 46 | 57 | 43 |
| | 6 | 1 | 1 | 0 | 0 | 1 | 14 | 2 | 0 | 0 | 19 | 74 | 26 |
| | 7 | 3 | 3 | 0 | 1 | 0 | 2 | 9 | 1 | 0 | 19 | 47 | 53 |
| | 8 | 3 | 2 | 1 | 0 | 0 | 0 | 0 | 19 | 0 | 25 | 76 | 24 |
| | 9 | 1 | 1 | 0 | 1 | 0 | 1 | 0 | 0 | 1 | 5 | 20 | 80 |
| TOTAL | 116 | 91 | 69 | 42 | 37 | 21 | 15 | 22 | 4 | 417 | | | |
| AP | % | 70 | 68 | 75 | 60 | 70 | 67 | 60 | 86 | 25 | | | |
| EC | | 30 | 32 | 25 | 40 | 30 | 33 | 40 | 14 | 75 | | | |
| Acertos | 289 | Erros 128 | | | | | kappa | | | 69% | | | |

Classes de solos: 1: LV-I; 2: LV-II; 3: LVA-I; 4: LVA-II; 5: FF-I; 6: FF-II; 7: FX; 8: RR; 9: CX; AU: Acurácia do usuário; EO: Erro de omissão; AP: Acurácia do produtor; EC: Erro de comissão.

A análise da matriz de confusão do mapeamento, por meio da observação dos erros de comissão e omissão, possibilitou incluir algumas associações de classes de solos, sobretudo, na SG-III, onde houve menor correspondência com a verdade de campo. A classe majoritariamente modelada para essa região foi a dos FF. As associações inferidas se referem à: a) FF + RR; b) FF + LV + LVA; c) FF + FX + CX; e d) FF + RR + CX + LVA, que refletem a realidade observada em campo e compõem o mapa digital de solos gerado.

4.4. CONCLUSÕES

A classificação espectral baseada no emprego do algoritmo MESMA alcançou 69% de índice Kappa para o mapa digital de solos em escala de 1:100.000, assim a metodologia aplicada alcançou o objetivo de discriminar simultaneamente os padrões espectrais das classes de solos nas três regiões estudadas. Os Latossolos predominaram nas três superfícies geomorfológicas e representou 75% das classes modeladas. Os Plintossolos pétricos apresentaram os maiores erros de comissão e

omissão devido às semelhanças espectrais entre os endmembers selecionados, associado às condições ambientais dos locais de ocorrência dessa classe.

Houve alta capacidade em identificar a classe de solo mais adequada para cada pixel na imagem sintética de solos, que alcançou uma fração média de 71%, ou seja, 3 a cada 4 *endmembers* foram modelados. O erro médio foi de 2%, que explica a acurácia muito boa para o mapa digital de solos gerado. Não obstante, uma modelagem localizada, com condições pedomorfológicas mais homogêneas, pode diminuir os erros no mapeamento.

O percentual de solos expostos aumentará com o passar do tempo mediante a expansão do legado de imagens Landsat e de outros sensores orbitais. Dessa forma, uma série temporal mais robusta pode fornecer dados que permitam melhorar a modelagem espectral. Além disso, um mapeamento híbrido pode suprir as áreas não mapeadas por meio da utilização de técnicas geoestatísticas aplicadas à pedometria, ou ainda, pode-se incluir as informações espectrais para implementar modelos preditivos mais robustos ou aprimorar os já existentes a fim de reduzir os erros.

CAPÍTULO 5

ESTIMATIVA DE UMIDADE DE SOLOS POR MEIO DE APRENDIZADO DE MÁQUINA AUXILIADO POR DADOS SAR (SENTINEL-1), ÓPTICOS (SENTINEL-2) E ATRIBUTOS PEDOMORFOLÓGICOS

5.1. INTRODUÇÃO

A umidade de solos é uma variável fundamental para o monitoramento de vários fenômenos ambientais como os meteorológicos e hidrológicos (DOBSON e ULABY, 1986). Além disso, é possível utilizá-la como um indicador de desastres naturais como inundações e secas e de mudanças ambientais como tempestades de poeira e erosões (MOHANTY et al., 2016). Em 2015, o Distrito Federal (DF) enfrentou uma seca sem precedentes que gerou fortes impactos socioeconômicos (CUNHA et al., 2018). Assim, o monitoramento desse parâmetro é indispensável para o direcionamento de políticas públicas preventivas ou mitigantes dos efeitos causados por eventos climáticos extremos como secas.

Vale ressaltar que a umidade de solos é dinâmica e apresenta, além das variações intrínsecas às condições climáticas, alternâncias causadas pelos atributos pedológicos (PALOSCIA et al., 2013). Seus estudos são de grande relevância para o manejo e conservação dos solos. Os métodos clássicos de aferição *in situ* exigem alta demanda de tempo e recursos financeiros, além de requerer medições repetitivas para determinar mudanças temporais (ULABY et al., 1996).

Os sensores remotos ativos que operam na faixa espectral das micro-ondas têm sido empregados na estimativa da umidade de solos devido à capacidade de penetração do sinal de radar na superfície de solos (SANO et al., 2020). Vários estudos têm sido propostos para estimá-la por sensores ativos nas bandas X

(BAGHDADI et al., 2012; EL HAJJ et al., 2016; GARCIA et al., 2016; SETIYONO et al., 2017), C (JACOME et al., 2013; BAUER-MARSCHALLINGER et al., 2019, BENNINGA et al., 2020) e L (PALOSCIA, 2013; ALEXAKIS et al., 2017; GAO et al., 2017; ZRIBI et al., 2019; DATTA et al., 2020; SEKERTEKIN et al., 2020).

Essas pesquisas demonstraram uma relação linear entre umidade de solos medida em campo e coeficientes de retroespalhamento (σ^0) derivados de imagens de radar, conforme reportado por Ulaby et al. (1986) e Dubois et al. (1995). Contudo, o retroespalhamento é ainda intensamente afetado pela rugosidade do terreno e pela vegetação densa (SANO et al., 1998). Com efeito, abordagens mistas que considerem outros fatores em modelos preditivos são mais robustas para melhorar as estimativas de umidade de solos baseadas em imagens de radar (BENNINGA et al., 2020).

Os dados de radar de abertura sintética (SAR) dos sensores orbitais Sentinel-1 operam na banda C, isto é, com comprimento de onda em torno de 5 cm e resolução espacial de 10 m (ESA, 2021). O primeiro satélite dessa constelação, denominado de Sentinel-1A, foi lançado em 2014, seguido pelo Sentinel-1B, em órbita desde 2016. A combinação dos dois satélites proporciona uma resolução temporal de 6 dias (ESA, 2012a; TORRES et al., 2012). A Agência Espacial Europeia (ESA) lançou ainda outra constelação de dois satélites ópticos denominados de Sentinel-2A e Sentinel-2B em 2015 e 2017, respectivamente. Esses satélites possuem 12 bandas espectrais no visível, infravermelho próximo e infravermelho de ondas curtas, operam com resolução espacial de 10 m e periodicidade de 5 dias.

Os dados Sentinel estão disponíveis nas plataformas Copernicus (scihub.copernicus.eu/dhus/#/home) (ESA, 2012a; 2012b) e *Google Earth Engine* (GEE) (<https://earthengine.google.com/>). O GEE corresponde a um ambiente virtual de processamento de dados geoespaciais que realiza de processamentos em nuvem

por meio de linguagem de programação em Javascript (GOOGLE INC., 2021). Entretanto, alguns estudos exigem maior controle de processamento e requerem o desenvolvimento de algoritmos dedicados ao objetivo, como Poppiel et al. (2019b) que elaboraram um roteiro para modelagem de atributos dos solos no DF.

Nesse sentido, modelos de aprendizado de máquina como Regressão Linear Múltipla (RLM), por exemplo, necessita de dados altamente correlacionáveis para modelagens mais eficientes (MILLER, 2017). O *Random Forest* (RF), por outro lado, são versáteis e produzem, mesmo sem ajuste de hiperparâmetros, alta correlação com os dados empíricos (HENGL et al., 2018). O RF é um dos algoritmos mais utilizados devido da sua versatilidade em modelar dados complexos (MILLER, 2017). Diante do exposto, o objetivo deste estudo foi estimar umidade dos solos por meio da combinação de dados do Sentinel-1A e Sentinel-2A e variáveis pedomorfológicas via modelagem via RLM e RF ao longo de um ciclo pluviométrico.

5.2. MATERIAL E MÉTODOS

5.2.1. Fluxo de trabalho

Com base no estabelecimento das relações pedomorfogeológicas e condições de uso e ocupação das terras no DF, foram escolhidos 40 pontos de amostragem dentre as 173 posições utilizadas no Capítulo 4, para determinação da umidade gravimétrica. Para este fim, foram realizadas 10 saídas a campo para coleta de amostras indeformadas de solos designadas às estimativas de umidade de solos em 4 regiões distintas do DF. As amostragens ocorreram nas datas de passagem do satélite Sentinel-1 sobre a área de estudo, ao longo de um ciclo pluviométrico.

Os dados de sensoriamento remoto, nomeadamente, imagens SAR Sentinel-1 e ópticas do Sentinel-2A, convertidas em índice de vegetação por diferença

normalizada (NDVI) (ROUSE et al., 1974), foram pré-processadas na plataforma GEE (DATTA et al., 2020). Esses dados foram importados para o programa *Sentinel Application Platform* (SNAP) (ESA, 2021) para remoção de feições de áreas urbanas e corpos hídricos e aquisição dos dados referentes às covariáveis utilizadas na modelagem da umidade do solo na série temporal. Além disso gerou-se variáveis explicativas por meio de atributos do terreno, geradas mediante o MDT, e atributos físico-químicos dos solos, ambos oriundos dos processamentos e análises realizadas no Capítulo 4. A Figura 5.1 resume os procedimentos adotados nesta pesquisa.

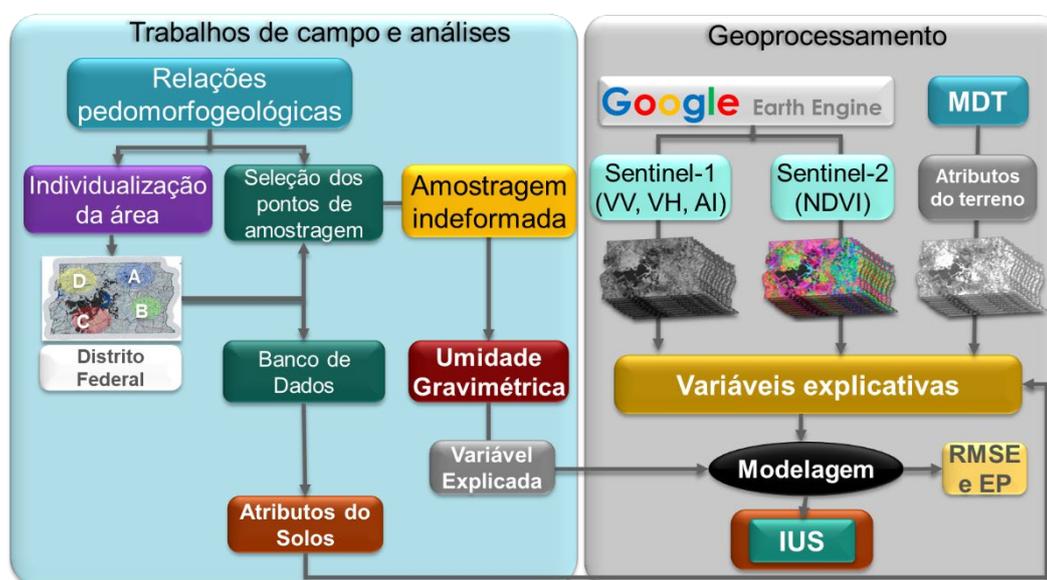


Figura 5.1. Fluxograma da metodologia de trabalho. MDT: Modelo Digital do Terreno; RMSE: Raiz quadrada do erro médio; EP: Erro-padrão; IUS: Índice de Umidade do Solo.

Para a modelagem, foram seguidas as etapas propostas por Hengl et al. (2018) relacionadas ao uso dos algoritmos de Regressão Linear Múltipla (RLM) RF no programa estatístico R (R CORE TEAM, 2019). Nesse programa, os dados de retroespalhamento, ângulo de incidência, índice de vegetação e atributos do terreno e dos solos foram submetidos à correlação de Pearson (r) e análise de componentes

principais (PCA) para redução de dimensionalidade das covariáveis mais relevantes. As variáveis preditoras significativas foram inseridas nos modelos RLM e RF para estimar a distribuição da umidade de solos do DF. A qualidade da modelagem foi avaliada por meio da raiz quadrada do erro médio (RMSE) e pelo erro-padrão. Os dados resultantes foram editados, classificados e avaliados segundo as características pedológicas correspondentes.

5.2.2. Individualização da área

A área de estudo foi dividida em quatro setores que representam parte da diversidade de condições pedomorfogeológicas do DF descritas por Lacerda e Barbosa (2012) e foram definidas em locais estratégicos para compreender as várias características de uso e ocupação das terras de cada setor, os quais:

- Setor A: Localizado a nordeste do DF, na Região Administrativa (RA) Planaltina, na área de influência da microbacia hidrográfica do rio São Bartolomeu, especificamente, nas dependências da unidade experimental da Embrapa Cerrados.
- Setor B: Programa de Assentamento Dirigido do Distrito Federal (PAD-DF), região localizada no sudeste da área de estudo, RA Paranoá, sob abrangência da microbacia do Rio Preto.
- Setor C: Fazenda Água Limpa da Universidade de Brasília (FAL/UnB), a sudoeste do DF, na RA Lago Sul, na área de influência do Ribeirão do Gama, afluente do Rio Paranoá. Esta área de estudo compreende as dependências da unidade experimental da UnB.
- Setor D: Parque Nacional de Brasília, região noroeste do DF, na RA Brasília.

5.2.3. Amostragem e análise dos solos

5.2.3.1. Localização e amostragem período de amostragem de solos

As posições dos 40 pontos de amostragem foram direcionadas em função de locais específicos de ocorrência de determinadas classes pedológicas, com vistas a obter representatividade dos solos da região e, dessa forma, avaliar a eficiência dos modelos de distribuição da umidade de solos em relação à pedodiversidade local. A maioria dos pontos foram alocados nas superfícies geomorfológicas SG-I e SG-II para minimizar a influência do relevo movimentado, como é o caso da paisagem da SG-III que afeta os dados SAR e o desempenho da modelagem (SANO et al., 2020).

Dessa forma, as amostras indeformadas de solos foram coletadas por quatro equipes em 10 saídas a campo, entre outubro de 2019 e setembro de 2020, programadas de acordo com as datas e horários de passagem do satélite Sentinel-1A sobre a área em estudo. A Figura 5.2 ilustra as datas das amostragens indeformadas de solos sobrepostas às oscilações médias mensais da precipitação ao longo do ano nos setores determinados (INMET, 2020).

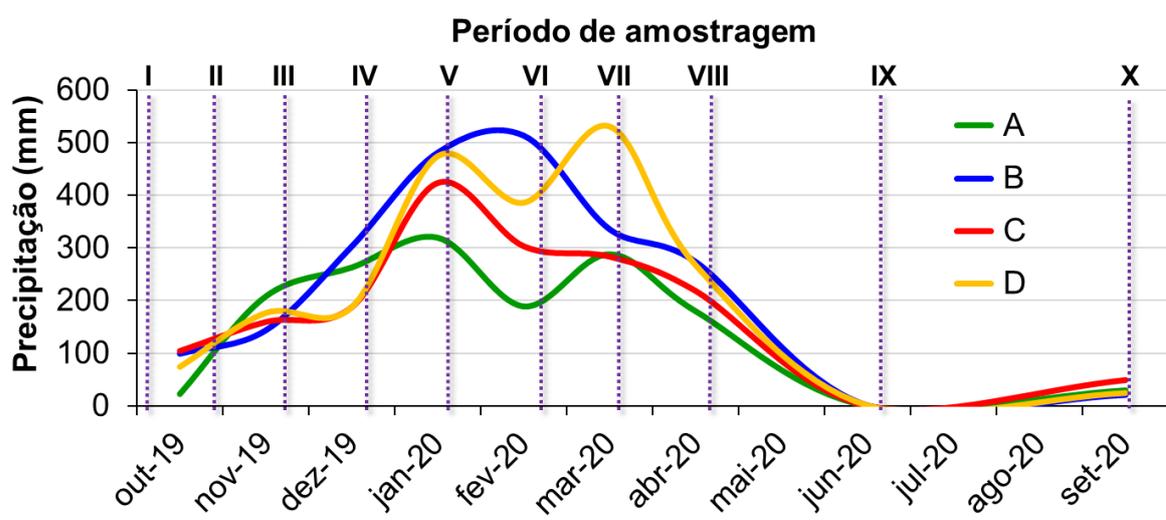


Figura 5.2. Distribuição da normal pluviométrica nos setores A, B, C e D no período 2019-2020. Fonte: Elaborado pelo autor com dados de INMET (2020).

Os conjuntos de instrumentos e materiais necessários à amostragem indeformada (Figura 5.3a) continham 30 anéis volumétricos de metal inoxidável (anéis de Uhland) (Figura 5.3b), os quais formaram um total de 120 peças, numeradas em ordem crescente. As dimensões médias aproximadas dos anéis foram: 5,0 cm de altura, 4,5 cm de diâmetro ($79,52 \text{ cm}^3$) e peso médio de 75 g. Os kits contaram com material para a amostragem de solos: extratores de amostras indeformadas de solo do tipo “castelinho” (Figura 5.3b), fita adesiva de papel, barbantes, pás, espátulas, marretas e um par de tampas vedantes em cores diferentes para especificar a orientação dos anéis (Figura 5.3c). As coletas em triplicata de cada ponto obedeceram a um espaçamento de aproximadamente 10 m entre si.

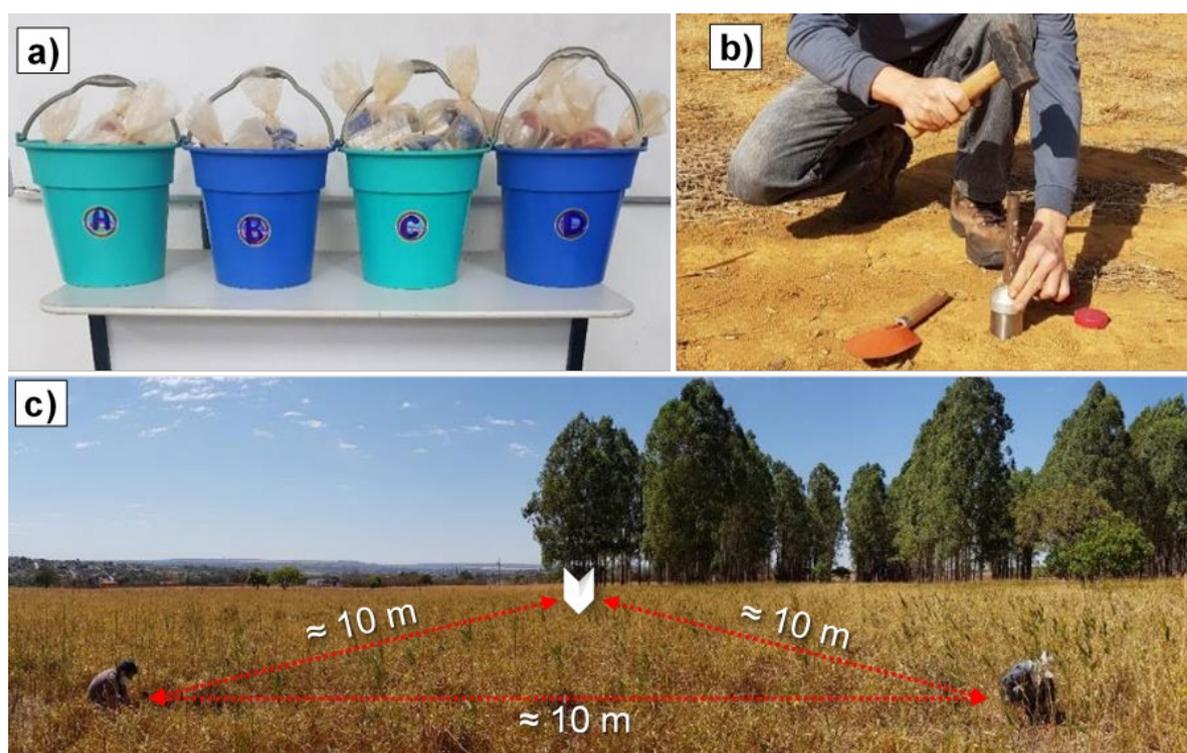


Figura 5.3. Material utilizado para amostragem indeformada de solos: a) kit de amostragem; b) anel volumétrico e c) espaçamento de amostragem.

Para conferir eficiência ao processo de amostragem indeformada do solo, foram elaboradas fichas identificadoras para as amostragens, baseada no modelo

disposto em Santos et al. (2015), as quais continham informações como data de amostragem, região de amostragem e número do ponto. Além da identificação dos anéis utilizados, as fichas incluíram campos para registro das massas dos cilindros (total, seco e vazio), conforme consta em Teixeira et al. (2017). Cada grupo contou, em média, com três membros munidos de dois conjuntos de instrumentos necessários para a amostragem indeformada de solo. Os horários de coleta ocorreram em por volta das 9 horas da manhã, horário de Brasília, que corresponde à janela de passagem do satélite Sentinel-1 sobre a área de estudo (ESA, 2021).

5.2.3.2. Análises de campo e laboratório

Os métodos de análises laboratoriais de solos estão descritos na seção 4.2.5 do Capítulo 4 deste trabalho, os quais determinaram os atributos químicos e físicos dos horizontes A, B, C ou F que, com as características morfológicas dos solos, possibilitaram a classificação pedológica de acordo com Santos et al. (2018).

Quanto às amostragens indeformadas de solos, ao fim de cada saída a campo, as equipes encaminharam as amostras para aferição da massa de solo úmido nos anéis nas respectivas fichas de amostragem (Figura 5.4a). Posteriormente, estas, foram conduzidas à secagem em estufa (Figura 5.4b) a 105 °C por um período de 24h, de acordo com Teixeira et al. (2017). Em seguida, as amostras foram retiradas da estufa e tiveram suas respectivas massas de solo seco registradas. Ao final, os anéis foram esvaziados, limpos, secos e encaminhados à pesagem para abatimento da massa de cada anel (Figura 5.4c).



Figura 5.4. Amostras indeformadas de solo para estimativa de umidade: (a) solo úmido; (b) amostras secas na estufa e (c) anéis limpos prontos para reutilização.

A umidade de solos foi obtida segundo os procedimentos dispostos em Schoeneberger et al. (2012) e Teixeira et al. (2017). A umidade gravimétrica do solo corresponde ao percentual de água livre em uma determinada massa do solo, o cálculo para obtenção desse percentual é expresso pela Eq. 5.1.

$$U_g = \frac{m_u - m_s}{m_s} \cdot 100 \quad (5.1)$$

Em que U_g corresponde à umidade gravimétrica do solo; m_u é a massa úmida do solo; e m_s é a massa seca do solo.

5.2.4. Aquisição, processamento e seleção das covariáveis

Para representar alguns dos fatores que influenciam nas estimativas da umidade de solos, recorreu-se às covariáveis estatisticamente significativas, dentro de um intervalo de confiança de 90%, as quais foram divididas em dois grupos:

- 1) covariáveis dinâmicas: valores de retroespalhamento nas polarizações VH e VV; índice de vegetação por diferença normalizada (NDVI); e
- 2) covariáveis estáveis: ângulo de incidência local (AI); índice de rugosidade do terreno (TRI), índice de posição topográfica (TPI); índice topográfico de umidade (TWI); e os seguintes atributos de solos: textura, pH em água, capacidade de troca de cátions (CTC), saturação por bases (V%), saturação por alumínio (m%) e matéria orgânica (MO).

5.2.4.1. Dados SAR

O satélite Sentinel-1 obtém dados na faixa espectral das micro-ondas, especificamente, na banda C e nas polarizações VV e VH. Neste trabalho, foram considerados os dados obtidos nessas duas polarizações e o ângulo de incidência local, conforme utilizado também por Sekertekin et al. (2020). As micro-ondas polarizadas verticalmente são afetadas pela vegetação, enquanto as polarizadas horizontalmente são menos sensíveis à vegetação, o que dificulta a chegada do sinal SAR no solo. Vale ressaltar que o AI considera um elipsoide de referência determinado para cálculo da inclinação da visada do sensor, também apresenta certa correlação com o retroespalhamento e, conseqüentemente, com a umidade do solo.

5.2.4.2. Pré-processamento e aquisição dos dados SAR

Neste estudo, foram considerados os produtos *Ground Range Detected* (GRD) no modo de aquisição Interferométrico de Faixa Larga (*Interferometric Wide Swath - IW*), disponível na plataforma GEE em nível de processamento L1 que consiste em dados projetados para o elipsoide de referência (datum) WGS-84 (ESA, 2021). A largura da faixa de imageamento é de 250 km. As etapas de pré-processamento no

GEE seguem os padrões predefinidos para conversão de valores digitais para coeficientes de retroespalhamento (σ^0), como consta na caixa de aplicações dedicada para os dados do Sentinel-1 no programa *Sentinel Application Platform* (SNAP) (ESA, 2021). O Quadro 5.1 resume as características dos dados do satélite Sentinel-1.

Quadro 5.1. Especificações dos dados do Sentinel-1 utilizado no estudo.

| Especificação | Característica |
|------------------------|--|
| Período de aquisição | outubro de 2019 a setembro de 2020 |
| Órbita | Descendente |
| Modo de imageamento | <i>Interferometric Wide (IW)</i> |
| Banda * | C ($\nu = 5,4$ GHz, $\lambda = 3,8-7,5$ cm) |
| Polarização | VH e VV |
| Ângulo de Incidência | 30° |
| Nível de processamento | L1** |
| Tipo de produto | GDR |
| Período de revisita | 12 (6) dias *** |
| Resolução espacial | 10 m |

* ν = frequência, λ = comprimento de onda; ** Dados brutos em *single look complex*; *** Seis dias de resolução temporal, se considerarmos os dois satélites. Fonte: Torres et al. (2012).

Em relação aos recursos técnicos, na plataforma GEE (GOOGLE INC., 2021) os produtos Sentinel-1 em nível de processamento L1 contém dados de coeficiente de retroespalhamento (σ^0) convertido em decibéis (dB), que mede o espalhamento da radiação de micro-ondas incidente no terreno, conforme descrito em (TORRES et al., 2012). O retroespalhamento é influenciado pelos atributos do terreno, como a geometria e comportamento eletromagnético. As etapas de pré-processamento na plataforma GEE seguem os procedimentos padrão para conversão de valores digitais para σ^0 por operação ($10 * \log_{10}\sigma^0$) a saber:

1. Arquivo de órbita: Atualização de metadados com um arquivo de órbita corrigido;
2. Remoção de ruído de borda: Correção do ruído de baixa intensidade e dados inválidos nas bordas da cena;

3. Remoção de ruído térmico: Eliminação de ruído aditivo em subfaixas para diminuir as lacunas entre as subfaixas para cenas em modos de aquisição de várias faixas;
4. Calibração radiométrica: Cálculo da intensidade do retroespalhamento por meio de parâmetros de calibração para metadados GRD;
5. Correção do terreno: transformação dos dados com base na geometria do terreno em σ° por meio do MDE 30 m da *Shuttle Radar Topography Mission*.

Com a execução do roteiro no GEE, os dados matriciais foram encaminhados para um repositório em nuvem para *download* em formato TIFF, o código consta no Apêndice C1. Essa operação foi repetida 10 vezes ao longo da série temporal em estudo para aquisição dos dados.

As imagens com as duas polarizações e o ângulo de incidência foram indexadas, juntamente com os demais conjuntos, em um banco de dados exclusivo para realização dos processamentos do presente trabalho. O Quadro 5.2 exibe a ordem da série temporal analisada e a descrição dos dados Sentinel-1. Essas foram identificadas segundo as datas de amostragem indeformada de solos da série temporal em análise.

Quadro 5.2. Descrição das imagens Sentinel-1 selecionadas para este estudo.

| ID ¹ | Data | Código do arquivo ¹ |
|-----------------|------------|---|
| I | 05/10/2019 | S1A_IW_GRDH_1SDV_20191005T084512_20191005T084537_029321_035529_AEAF |
| II | 29/10/2019 | S1A_IW_GRDH_1SDV_20191029T084512_20191029T084537_029671_036146_C60B |
| III | 22/11/2019 | S1A_IW_GRDH_1SDV_20191122T084512_20191122T084537_030021_036D76_B020 |
| IV | 16/12/2019 | S1A_IW_GRDH_1SDV_20191216T084511_20191216T084536_030371_037993_AA5C |
| V | 21/01/2020 | S1A_IW_GRDH_1SDV_20200121T084510_20200121T084535_030896_038BCE_5774 |
| VI | 14/02/2020 | S1A_IW_GRDH_1SDV_20200214T084509_20200214T084534_031246_0397FA_2913 |
| VII | 09/03/2020 | S1A_IW_GRDH_1SDV_20200309T084509_20200309T084534_031596_03A414_51C9 |
| VIII | 14/04/2020 | S1A_IW_GRDH_1SDV_20200414T084510_20200414T084535_032121_03B689_8C87 |
| IX | 25/06/2020 | S1A_IW_GRDH_1SDV_20200625T084514_20200625T084539_033171_03D7BF_6777 |
| X | 17/09/2020 | S1A_IW_GRDH_1SDV_20200917T084518_20200917T084543_034396_040010_4A30 |

¹ Identificação dos componentes da série temporal.

Cada coleção de dados foi empilhada em um único arquivo com 10 bandas por meio da função *Layer stacking* do Envi 5.3 (HARRIS GEOSPATIAL SOLUTIONS, INC., 2020). Após a observação do comportamento dos dados, as imagens obtidas na polarização VH visualmente discrepantes em relação ao uso e ocupação na série temporal, foram submetidas a uma composição colorida RGB para verificação da dinâmica do uso das terras na área de interesse.

De acordo com Gomes et al. (2019), a dinâmica da cobertura vegetal no Cerrado é marcada pela sazonalidade e pelas ações antrópicas. As séries temporais de imagens de sensoriamento remoto permitem uma análise quanto à detecção de mudanças no uso do solo, bem como as variações em que a cobertura vegetal passa nesse intervalo (SANO e BORGES, 2019). Nesse sentido, os dados Sentinel-1, na polarização VH, foram submetidas à composição colorida RGB, referentes às datas de maior, menor e média pluviosidade no DF, para detectar alterações na reflectância sobre as áreas, e assim, relacioná-las com a umidade do solo medida e predita.

5.2.4.3. Índice de vegetação por diferença normalizada (NDVI)

Como uma das variáveis explicativas dos modelos preditivos de umidade de solos, recorreu-se ao NDVI (ROUSE et al., 1974) que identifica áreas mais ou menos vegetadas que, de certa forma, afetam o desempenho de modelos de predição baseados em dados SAR (WU et al., 2019). O pigmento das folhas das plantas, a clorofila, absorve fortemente a luz visível (de 0,4 μm a 0,7 μm) para uso na fotossíntese. A estrutura celular das folhas, por outro lado, reflete intensamente a radiação na faixa espectral do infravermelho próximo (de 0,7 μm a 1,1 μm). Quanto mais folhas uma planta tem, mais esses comprimentos de onda de luz são afetados. O NDVI é calculado pela Eq. 5.2:

$$NDVI = \frac{\rho_{NIR} - \rho_{red}}{\rho_{NIR} + \rho_{red}} \quad (5.2)$$

Em que *red* e *NIR* representam os comprimentos de onda da reflectância espectral adquiridas nas regiões do vermelho (visível) e infravermelho próximo, respectivamente. Os valores de NDVI variam entre -1,0, para áreas sem vegetação e +1,0, para áreas densamente vegetadas. As imagens de NDVI foram calculadas com base na mediana de 30 dias em torno de cada data da série temporal a fim de cobrir toda a área com menor incidência de nuvens. O Apêndice C2 contém o código utilizado para geração das imagens de NDVI, repetido para as 10 datas especificadas.

5.2.4.4. Atributos do terreno

A rugosidade da superfície exerce forte influência no retroespalhamento (e.g. SANO et al., 1998). Desse modo, superfícies com rugosidades mais acentuadas estão propensas a retroespalhar mais o sinal em várias direções, quando comparado a superfícies lisas. Além disso, superfícies menos rugosas desviam o sinal retroespalhado que não retornam à antena (MOHANTY et al., 2016).

Em vista disso, foi elaborado um MDE para gerar as covariáveis geomorfológicas pela aplicação *topo to raster* que realiza a interpolação de dados topográficos e outras feições da paisagem. Os dados para geração do MDE foram os seguintes arquivos vetoriais: hidrografia (linha), curva de nível (linha), limites do DF (polígono) e nuvem de pontos de elevação (ponto), que resultaram em um dado matricial com 10 m de resolução espacial. Esse dado gerou as três covariáveis morfométricas anteriormente reportadas (TPI, TRI e TWI). O TPI (Eq. 5.3) compara a elevação de cada célula em um MDE para a elevação média de uma vizinhança

especificada em torno dessa célula de forma a padronizar as altitudes, o que permite análises do relevo (WEISS, 2001).

$$TPI = z_0 - z \quad (5.3)$$

Em que o *TPI* equivale à diferença entre a elevação no ponto central (z_0) e a elevação média (z) em torno dele dentro de um raio predeterminado (R). De acordo com Weiss (2001), os valores positivos de *TPI* indicam que o ponto central está localizado acima da média dos arredores, enquanto os valores negativos indicam uma posição inferior à média. Com efeito, o intervalo de *TPI* depende não apenas das diferenças de elevação, mas também de R . Os valores elevados de R revelam as unidades principais da paisagem, enquanto os valores menores destacam características menores, como vales e cumes pequenos, que têm relação com a umidade do solo (GUTIÉRREZ et al., 2015).

O *TRI* é uma técnica morfométrica desenvolvida por Riley et al. (1999) para expressar a diferença nos valores de elevação de uma célula central e das oito células imediatamente ao seu redor. Para o cálculo do *TRI*, eleva-se ao quadrado cada um dos oito valores de diferença de elevação para torná-los todos positivos e toma-se a média dos quadrados. Esse índice é, então, derivado pela raiz quadrada dessa média, como disposto na Eq. 5.4.

$$TRI = \sqrt{\sum(z_c - z_i)^2} \quad (5.4)$$

Em que z_c é a elevação de uma célula central; e z_i é a elevação de uma das oito células vizinhas ($i = 1, 2, \dots, 8$).

Não obstante, o *TWI* foi obtido pela Eq. 5.5. Esse índice considera os valores de elevação do *raster* de um MDE e a declividade, comumente utilizados em estudos

hidrológicos (BEVEN e KIRKBY, 1979). O TWI também é conhecido como índice topográfico TOPMODEL.

$$TWI = \ln \left(\frac{\alpha}{\tan\beta} \right) \quad (5.5)$$

Em que α (área de captação específica) representa a área da pendente que contribui para o fluxo hídrico ao longo do contorno. O TWI indica a quantidade de água que pode fluir em meio à superfície em direção à drenagem. Para dados de grade, o comprimento do contorno é equivalente ao espaçamento da grade, e $\tan\beta$ é a descendente local (BEVEN e KIRKBY, 1979). Alternativamente, esse índice pode ser calculado pela Eq. 5.6.

$$TWI = \log \left(\frac{\alpha}{T \cdot \tan\beta} \right) \quad (5.6)$$

Em que α corresponde à área de drenagem por unidade de comprimento de contorno; e T é a transmissividade lateral do solo, por esta razão, ele é também conhecido como índice topográfico do solo (BEVEN e KIRKBY, 1979).

5.2.4.5. Extração dos dados para implementação dos modelos

O processamento dos dados SAR procedeu-se no programa computacional SNAP, que consiste em um SIG dedicado aos produtos Sentinel (ESA, 2021). As imagens Sentinel-1 foram submetidas a uma nova correção geométrica do terreno com base no MDT de 10 m para redução dos ruídos na imagem.

Os dados de sensoriamento remoto (Sentinel-1 e Sentinel-2) foram submetidos ao georreferenciamento e a reamostragem dos pixels para 30 m para compatibilização com os dados gerados no Capítulo 4. Ao final, corpos hídricos e áreas antropizadas não agrícolas como edificações e pavimentos maiores que 5 há foram suprimidas.

Após o tratamento dos dados matriciais e vetoriais, foi executada a função de visualização de plotagem correlativa do SNAP. Essa funcionalidade coleta o valor mediano dos pixels dentro de um polígono, nesse caso 5 pixels x 5 pixels, sobre os pontos amostrados para as etapas de treino e teste dos modelos de umidade de solos. Com estes dados, recorreu-se à correlação de Pearson para verificação do comportamento das variáveis preditoras com relação aos pontos medidos em campo e a filtragem de possíveis *outliers*.

5.2.5. Implementação dos modelos de aprendizado de máquina

5.2.5.1. Regressão linear múltipla

Com os valores das covariáveis filtradas pelas análises de Correlação de Pearson e Análise de Componentes Principais, utilizadas para reduzir o número de covariáveis autocorrelacionáveis, procedeu-se à modelagem (MILLER, 2017). Os dados foram divididos em dois conjuntos para a etapa de treinamento (70%) e de teste (30%). Então, foram implementados, primeiramente, os modelos de regressão linear múltipla (RLM) para estimativas da umidade de solos no DF em cada data estipulada. A Eq. 5.7 exibe a base de cálculo da regressão para estimativas da umidade de solos, por meio das covariáveis estatisticamente significativas selecionadas para cada conjunto de dados.

$$y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_n X_{in} + \varepsilon \quad (5.7)$$

Em que y_i corresponde à variável dependente (umidade de solos a ser predita); $X_{i1, 2, 3}$ são as variáveis explicativas ou covariáveis; β_0 é o intercepto da inclinação da reta 1:1 em y (termo constante); $\beta_{1, 2, \dots, n}$ são os coeficientes de inclinação para cada variável explicativa; e ε correspondente ao termo de erro do modelo.

5.2.5.2. Modelagem *Random Forest*

Posteriormente, as covariáveis significativas foram submetidas a modelagem pelo método RF (BREIMAN, 2001) via linguagem de programação em ambiente R, de acordo com os procedimentos constantes em Hengl e MacMillan (2019). O pacote “randomForest” do R realiza o melhor ajuste dos modelos por meio das covariáveis de treinamento e retorna os dados preditos (R CORE TEAM, 2019). As estimativas da umidade do solo por aprendizado de máquina também se orientaram por trabalhos realizados por Zhang et al. (2018) e Datta et al. (2020), para a modelagem da umidade do solo em séries temporais.

Em ambiente R, foram inseridos hiperparâmetros de acordo com Hengl et al. (2018), a saber: limite de árvores de decisão na floresta (1000); número mínimo de amostras necessárias para dividir cada nó para evitar o sobreajuste; número mínimo de amostras necessárias para cada folha; determinação do número de covariáveis a serem reamostradas; quanto maior esse valor, melhor desempenho do modelo, pois as árvores dispõem de uma maior fonte de recursos para selecionar a melhor divisão, por outro lado, podem induzir ao sobreajustes nas árvores menos diversificadas; e, por último, o número máximo de níveis em cada árvore de decisão (100) com amostragem sem reposição (MILLER et al., 2017).

A modelagem RF apresenta maior acurácia quando comparada a modelos de regressão por não depender, necessariamente, de linearidade ou alta correlação entre as variáveis preditas e preditoras (HENGL e MACMILLAN, 2019). Por esse motivo, recorreu-se ao algoritmo RF para geração dos mapas de umidade de solos estimada em cada data da série analisada. Os *rasters* foram associados a uma paleta de cores contrastantes e intuitivas para destacar áreas com valores de umidade máxima, média

e mínima. A umidade do solo foi representada por seis classes agrupadas segundo os quantis dos dados de cada imagem.

5.2.5.3. Avaliação dos modelos

As amostras de dados de treinamento (70%) foram usadas para identificar as inter-relações, enquanto os restantes (30%) para validar a acurácia da estimativa. As amostras de treino e de teste foram escolhidas proporcionalmente segundo a quantidade de tipos de solo dentro dos setores determinados. Os modelos empíricos foram validados por meio da análise de correlação entre os valores preditos e os dados de umidade de solos de referência. Além disso, observaram-se o erro-padrão e o RMSE, como recomendado por Miller (2017).

Ainda de acordo com Miller (2017), esta técnica é um recurso estatístico baseado no desvio-padrão dos resíduos (erros de predição), uma vez que os resíduos são uma medida de dispersão dos pontos da linha de regressão. Portanto, o RMSE (Eq. 5.8) consistiu em uma medida de quão espalhados esses resíduos se apresentaram na modelagem.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (S_i - O_i)^2} \quad (5.8)$$

Em que O_i são as observações; S_i , os valores previstos de uma variável; e n é o número de observações disponíveis para análise. Em outras palavras, RMSE demonstra a concentração dos dados em torno da linha de melhor ajuste e é considerado uma medida de precisão adequada, mas apenas para comparar erros de previsão de diferentes modelos ou configurações de modelo para uma determinada variável, não entre variáveis, pois depende da escala (MILLER, 2017; HENGL e MACMILLAN, 2019). Ao final, uma imagem com a média dos valores de RMSE da

série temporal foi gerada por meio da aplicação da lei de propagação de incerteza para avaliação quantitativa dos erros.

5.3. RESULTADOS E DISCUSSÃO

Os quantitativos relacionados aos atributos químicos e físicos, bem como a classificação dos solos analisados estão dispostos nos Apêndices C3 a C7. Ademais, as características como: padrões geomorfológicos, litologias, usos e ocupações das terras e a localização destes pontos se encontram resumidos na tabela disposta no Apêndice C8. Desse modo, estas informações, associadas ao clima e ao tempo de exposição, configuram os fatores pedogenéticos (MCBRATNEY et al., 2003).

As ações antrópicas influenciam diretamente em algumas propriedades dos solos e afetam a qualidade desse recurso (GOMES et al., 2019; NOVAIS e LACERDA, 2021). A capacidade de infiltração da água pode ser reduzida em caso de compactação superficial ou subsuperficial em áreas agrícolas, por exemplo. A supressão da vegetação natural é, ainda, um dos fatores que leva à perda de solo em declividades acentuadas por processos de erosão, o que acarreta assoreamento de corpos hídricos (HUNKE et al., 2014). Consta nos Apêndices D1 ao D4, o relatório fotográfico dos pontos de amostragem selecionados para este Capítulo, nos quais se observam os diferentes usos e cobertura vegetal dos setores.

5.3.1. Avaliação do uso e ocupação das terras

A Figura 5.5 exibe uma composição colorida (RGB) das imagens Sentinel-1 do DF obtidas em outubro de 2019 (*Red*), fevereiro de 2020 (*Green*) e junho de 2020 (*Blue*) na polarização VH. Houve uma menor variação de retroespalhamento em áreas de vegetação natural, na parte oeste do DF, onde sobressaíram os valores referentes

à estação seca (tons em magenta). De maneira oposta, na porção leste do DF, o efeito da antropização realçou os valores das bandas verde e azul, referentes aos meses chuvosos, no qual há o replantio das lavouras sob SPD (GOMES et al., 2019).

Houve, ainda, regiões com alternância de atividades, notadamente na região centro-sul do DF. As feições com tons variados em magenta representam alta reflectância durante os meses mais secos, representada pela imagem obtida em 29 de outubro de 2019. Por outro lado, as áreas mais claras, com valores elevados de retroespalhamento nas três imagens, caracterizam coberturas densamente vegetadas, como é o caso das matas de galeria.

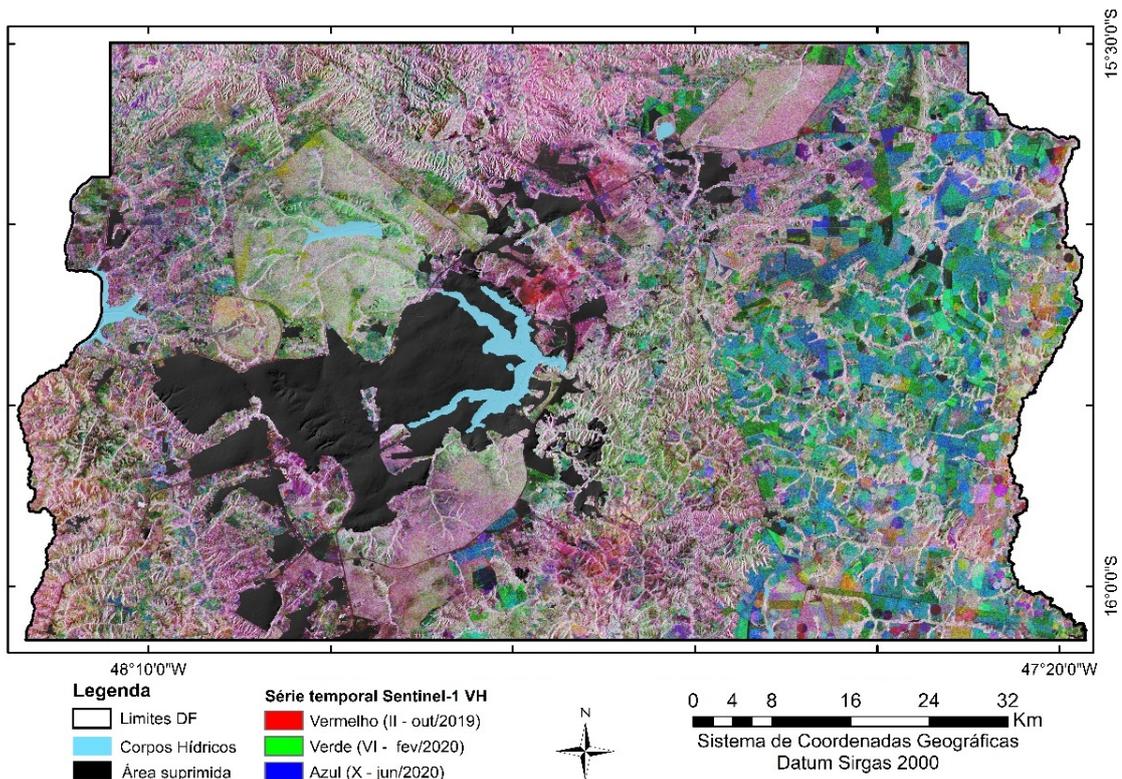


Figura 5.5. Composição colorida RGB das imagens Sentinel-1 do DF obtidas em outubro de 2019, fevereiro de 2020 e junho de 2020 na polarização VH.

De maneira geral, a variação nos valores de retroespalhamento na polarização VH é influenciada por diversos fatores como os relacionados às propriedades e atributos dos solos. Entretanto, atividades antrópicas como irrigação e drenagem

podem mudar tais características, o que interfere na detecção remota da umidade de solos (DATTA et al., 2020). A imagem de mudança do uso das terras demonstra maiores percentuais nas áreas a leste do DF, pois predomina a cor azul, referente à data de fevereiro de 2020, época de maior incidência de precipitação na área de estudo, maior vegetação (SILVA et al., 2014).

5.3.2. Relações pedomorfogeológicas

Os 10 primeiros pontos foram alocados no Setor A, cuja geomorfologia local abrange as superfícies SG-I e SG-II com usos diversificados com áreas de agricultura sob SPD, silvicultura e pastagem. A pedodiversidade remete predominantemente aos Latossolos vermelhos e vermelhos-amarelos.

No setor B, representado pelo intervalo de pontos 11 a 20, região leste do DF, foi observado a forte ação antrópica, caracterizada pela agricultura intensiva sob SPD, vegetação de campo com gramíneas cultivadas e silvicultura, porém, com presença de Cerrado e matas de galeria (NOVAIS e LACERDA, 2021).

O padrão geomorfológico varia desde as paisagens planas da SG-I com cotas acima dos 1.100 m, para os pontos 1 a 4, à montante da microbacia do Rio Jardim. Os demais pontos foram alocados na SG-II, onde as altitudes diminuem até 900 m, a jusante da microbacia do Rio Jardim, quando esse encontra o Rio Preto (NOVAES PINTO, 1987). Nessa região há a predominância do relevo suave-ondulado e altitudes inferiores a 1.000 m remete à SG-II (área de dissecação intermediária) com forte ação antrópica voltada à agricultura e urbanização (NEVES et al., 2018).

No setor C houve a predominância de vegetação nativa de Cerrado, com presença de pastagem e agricultura em menor proporção. Essa área comporta as duas primeiras SGs com altitudes que variam de 1.070 m a 1.200 m e declividade

plana a ondulada. A litologia é formada por rochas do grupo Paranoá, com a preponderância de ardósias, associadas a quartzitos nas bordas da SG-I (FREITAS-SILVA e CAMPOS, 1998).

Por último, a Região D apresentou cobertura do solo predominante constituída por vegetação natural, com algumas áreas de gramíneas (*Poaceae*) nativas ou cultivadas. A maioria dos pontos foram alocados sobre a SG-I, com cotas acima de 1.200 m, onde predominam os Latossolos (LACERDA e BARBOSA, 2012). Entretanto, na SG-III, caracterizada pelas maiores declividades, sobre a qual ocorreram os Neossolos Regolíticos e Plintossolos Pétricos (REATTO et al., 2004).

5.3.3. Caracterização dos solos

A diversidade de solos é controlada pelas condições pedomorfogeológicas em que as classes estão inseridas, associado ao tempo de exposição ao clima local (SANTOS et al., 2018). A Figura 5.6 exhibe o triângulo textural adotado em Soil Survey Staff (2017) com a distribuição dos pontos, nos horizontes superficiais (Figura 5.6a) e subsuperficiais (Figura 5.6b), que revela a predominância de solos muito argilosos.

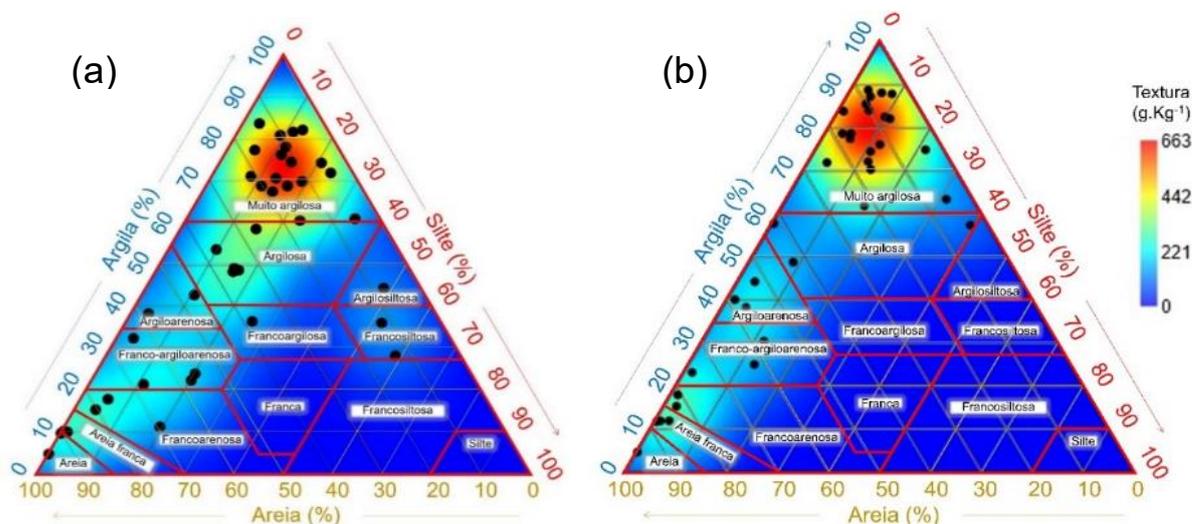


Figura 5.6. Triângulo textural dos horizontes superficiais (a) e subsuperficiais (b) dos 40 pontos amostrados para as estimativas de umidade dos solos.

A Figura 5.7 resume os resultados das análises físicas e químicas dos solos estudados. Dentre os atributos físicos dos solos, a textura influencia na capacidade de retenção ou disponibilização de água nos solos, pois a ela estão associados os demais parâmetros como densidade, porosidade e estrutura, por exemplo (TEIXEIRA et al., 2017). Nesse sentido, os dados também demonstram a predominância de solos muito argilosos até texturas arenosas, como verificado por Poppiel et al. (2019c).

O pH médio caracteriza solos ácidos (entre 5,4 e 5,6 para os horizontes superficiais e subsuperficiais, respectivamente). Os elevados teores de fósforo assimilável se justificam pelas práticas de adubação fosfatada em áreas de agricultura sob SPD, conforme observado por Fink et al. (2014) em estudos sobre solos tropicais sob SPD no Brasil. Da mesma forma, os valores médios de alumínio estiveram abaixo dos valores para solos tropicais de Cerrado, devido às práticas de correção da acidez com calcário ou gesso mais elevado nas camadas superiores do que nas inferiores, como relatou Hunke et al. (2014).

A concentração de pontos ocorreu nas classes de textura muito argilosa. Essa característica é reflexo do material de origem, isto é, rochas pelíticas dos Grupos Paranoá e Bambuí (FREITAS-SILVA e CAMPOS, 1998). Solos muito argilosos a argilosos são formados, geralmente, em áreas planas a suave-onduladas das SG-I e SG-II sob material parental do Grupo Paranoá ou Grupo Bambuí. Já nos vales dissecados, há a predominância de solos com menor grau de evolução provenientes de rochas pelíticas dos Grupos Araxá e Canastra. Os solos arenosos ocorrem, normalmente, nas bordas das chapadas elevadas do DF, transições das SG sobre matrizes quartzíticas, como relatado por Lacerda et al. (2016).

Os diversos usos das terras, pelos quais as amostras foram coletadas, geraram valores variados de bases trocáveis. Os teores de SB apresentaram valores dentro da

expectativa para os solos do Cerrado cuja fertilidade natural é baixa, como os baixos valores de CTC encontrados. De acordo com Gomes et al. (2019), essas características também contribuem para os valores de saturação por alumínio (m%) e os percentuais de saturação por bases (V%) em torno de 35%, que caracterizam solos distróficos, em contraste com os teores de matéria orgânica que foram considerados altos. Carvalho et al. (2014) relataram os altos teores de carbono em solos sob SPD.

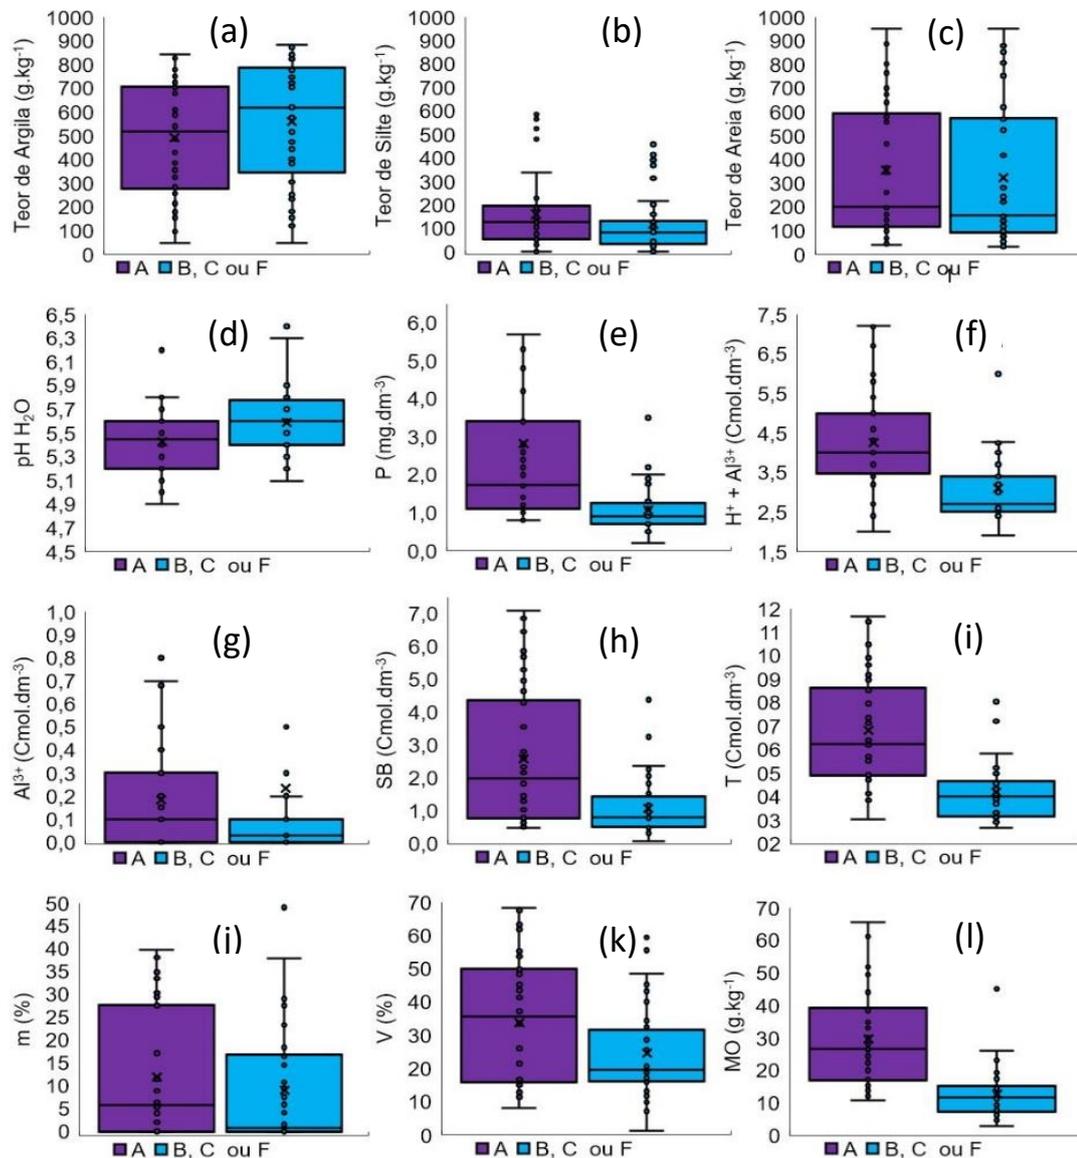


Figura 5.7. Gráfico de caixa dos valores dos atributos dos solos: (a) argila, (b) silte, (c) areia, (d) pH em H₂O, (e) Fósforo assimilável, (f) Hidrogênio + Alumínio, (g) Alumínio trocável, (h) soma das bases trocáveis, (i) Capacidade de Troca de Cátions potencial, (j) saturação de alumínio, (k) saturação por bases e (l) matéria orgânica.

5.3.4. Caracterização e classificação dos solos nas áreas de estudo

As classes pedológicas, utilizadas neste Capítulo, estão descritas no Apêndice C8 de acordo com Santos et al. (2018). Na primeira região nos Latossolos Vermelhos Distróficos típicos (LVd) (pontos 2, 9 e 10), Latossolos Vermelhos-Amarelos Distróficos petroplínticos (LVAc) (pontos 1, 3 e 5), Plintossolos Háplicos Distróficos típicos (FXd) (pontos 4 e 8), todos com texturas variaram entre muito argilosa e argilosa. Já nos pontos 6 e 7 foram encontrados solos de texturas arenosas, os quais foram classificados como Plintossolo Pétrico Concrecionário êndico, FFc, e Neossolo Quartzarênico Órtico típico (RQo), respectivamente.

A região B comporta uma extensa área cuja paisagem é classificada como SG-II (NOVAES-PINTO, 1987). De maneira similar, o setor A é marcado pela pressão exercida pela exploração dos solos, onde predominam atividades antrópicas diversificadas, especialmente, agricultura intensiva sob o SPD. Entretanto, há remanescentes de vegetação natural em áreas de preservação. De acordo com Novais et al. (2021), as classes encontradas nesse setor representam a pedodiversidade da porção leste do DF.

As classes LVd (13, 16 e 19), LVAc (11) e Latossolos Vermelho-Amarelo Distrófico típico (LVAd-14) ocorreram em declividades planas a suave-onduladas, cobrem a maior parte desse setor, como observado por Lacerda e Barbosa (2012), seguido pela ocorrência das classes FFc (15 e 18) e Neossolo Regolítico Distrófico típico (RRd - 17 e RRd - 20), em declividades suave-ondulado a ondulado. O material de origem local, rochas pelíticas do Grupo Bambuí, é responsável por solos muito argilosos. Contudo, nas bordas da SG-I, há a ocorrência de matrizes quartzíticas que geram solos arenosos como o RQo-12.

A região C é caracterizada pelas variações da declividade e cobertura do solo, onde predomina a vegetação natural do Cerrado. As classes de solos também são diversificadas, porém, há a predominância de Latossolos (LVd – 22, 24, 27 e 29; LVAc – 26 e LVAd – 23), seguido por Plintossolos com seus subtipos determinados por fatores hídricos e geomorfológicos (FXd – 25 e 30 FFc – 21). A classe RRd, nesse setor, contou com apenas um registro (ponto 28). Nessa região, a textura dos solos foi, predominantemente, muito argilosa para os Latossolos, entretanto, ocorrem texturas médias nas bordas da SG-I.

As diferentes classes distribuídas no setor D demonstraram características típicas de solos que ocorrem sobre matrizes quartzíticas, que, naturalmente, possuem textura arenosa com diferentes profundidades a exemplo do ponto 32-FFc, mais raso, e em declividade suave-ondulada, e 35-RQo, com profundidades superiores a 120 cm e com ocorrência em relevo plano, como descritos por Santos et al. (2018). Nessas condições, há um acréscimo nos teores de carbono deixado pela palhada em SPD que mantém a umidade do solo por mais tempo (CARVALHO et al., 2014).

Além disso, alguns pontos em áreas com vegetação natural mais adensadas contribuíram para os altos valores de matéria orgânica. Os Latossolos, muito argilosos e ricos em sesquióxidos de ferro e alumínio, variaram pouco quando comparado aos demais perfis desse setor (LVd - 31, 36, 37 e 39). Já os pontos 32-FFc e 34-FFc foram caracterizados pela baixa profundidade, menor 50 cm, e a textura. Lacerda e Barbosa et al. (2012) identificaram esse comportamento nos solos ao estudarem as relações pedomorfogeológicas nas chapadas elevadas do DF.

Vale ressaltar ainda os solos 38-FX e 40-FX, que, de modo distinto, demonstraram altas médias de umidade. Assim como o 38-FX do setor A, esta classe, em específico, é conhecida como Campos de murundus, formados em feições

geomorfológicas côncavas, em vertentes e nas cabeceiras de drenagens que permanecem saturadas durante algum período (SILVA et al., 2014). O microrrelevo é caracterizado pela formação de morrotes (murundus) pelo processo pedogenético biopedoturbação (BAPTISTA et al., 2013).

5.3.5. Avaliação das variáveis preditoras da umidade do solo

O gráfico de correlação de Pearson (Figura 5.8a) demonstra alta correspondência entre as covariáveis passíveis de composição dos modelos preditivos, classificados segundo Miller (2017) que estabelece os seguintes níveis de correlação: bem fraca: 0,00 a 0,19; fraca: 0,20 a 0,39; moderada: 0,40 a 0,69; forte: 0,70 a 0,89; e muito forte: 0,90 a 1,00. Nessa representação, observa-se a forte correlação positiva entre a umidade de solos e os valores de retroespalhamento derivados do S1 em todas as séries de dados. Datta et al. (2020) e Sekertekin et al. (2020) encontraram valores de coeficientes de correlação altos e positivos para a variável explicativa NDVI, o que revela a dependência desses dados com relação à umidade de solo medida em campo.

A importância das covariáveis, baseada no método Gini, exibida na Figura 5.8b, destacou os componentes SAR como mais relevantes para a modelagem pelo algoritmo RF. De acordo com Hengl et al. (2018), a importância de Gini ou a diminuição média na impureza (MDI) calcula a importância de cada recurso como a soma sobre o número de divisões (em todas as árvores) que incluem o recurso, proporcionalmente ao número de amostras que ele divide. A escala é irrelevante: apenas os valores relativos importam.

Com base na PCA (Figura 5.8c), é possível observar a forte relação da umidade do solo com as covariáveis SAR, bem como o NDVI e os índices derivados do terreno

TRI e TWI. Quanto mais próximos dos eixos os valores se organizarem, maior a correlação (MILLER, 2017). Em contrapartida, os atributos dos solos, especialmente a textura, apresentaram menor relação com a umidade para o conjunto de dados analisados, à exceção dos teores de matéria orgânica. O procedimento de transformação dos dados pode ser uma das causas desse comportamento. Além disso, como os dados de umidade do solo são uma média da série temporal, as variações desse atributo ocasionaram uma baixa correlação com a textura, que na prática, influencia a quantidade de água no perfil de solo (KÄMPF e CURI, 2012).

A Figura 5.8d reforça a relevância das cinco primeiras variáveis explicativas, que podem representar 95% dos conjuntos de dados, de acordo com a linha de tendência da matriz variância-covariância (HENGL e MACMILLAN, 2019). Portanto, juntamente com o diagrama de Gini (Figura 5.8b), a PCA possibilitou a redução das covariáveis que compuseram os modelos de regressão linear múltipla e RF da série temporal por eliminação daqueles conjuntos de dados que apresentaram colinearidade ou alta correlação, como recomendado por Lourenço et al. (2020).

Desse modo, as covariáveis pré-selecionadas foram: polarização VH; limiar de NDVI; índice de rugosidade do terreno; índice topográfico de umidade; e o atributo do solo matéria orgânica. Hengl et al. (2018) relataram que a PCA pode suprimir covariáveis importantes para predição de determinada variável dependente, como ocorreu neste trabalho ao excluir a textura do solo, que segundo Kämpf e Curi (2012), é determinante na retenção ou na disponibilização de água para o lençol freático.

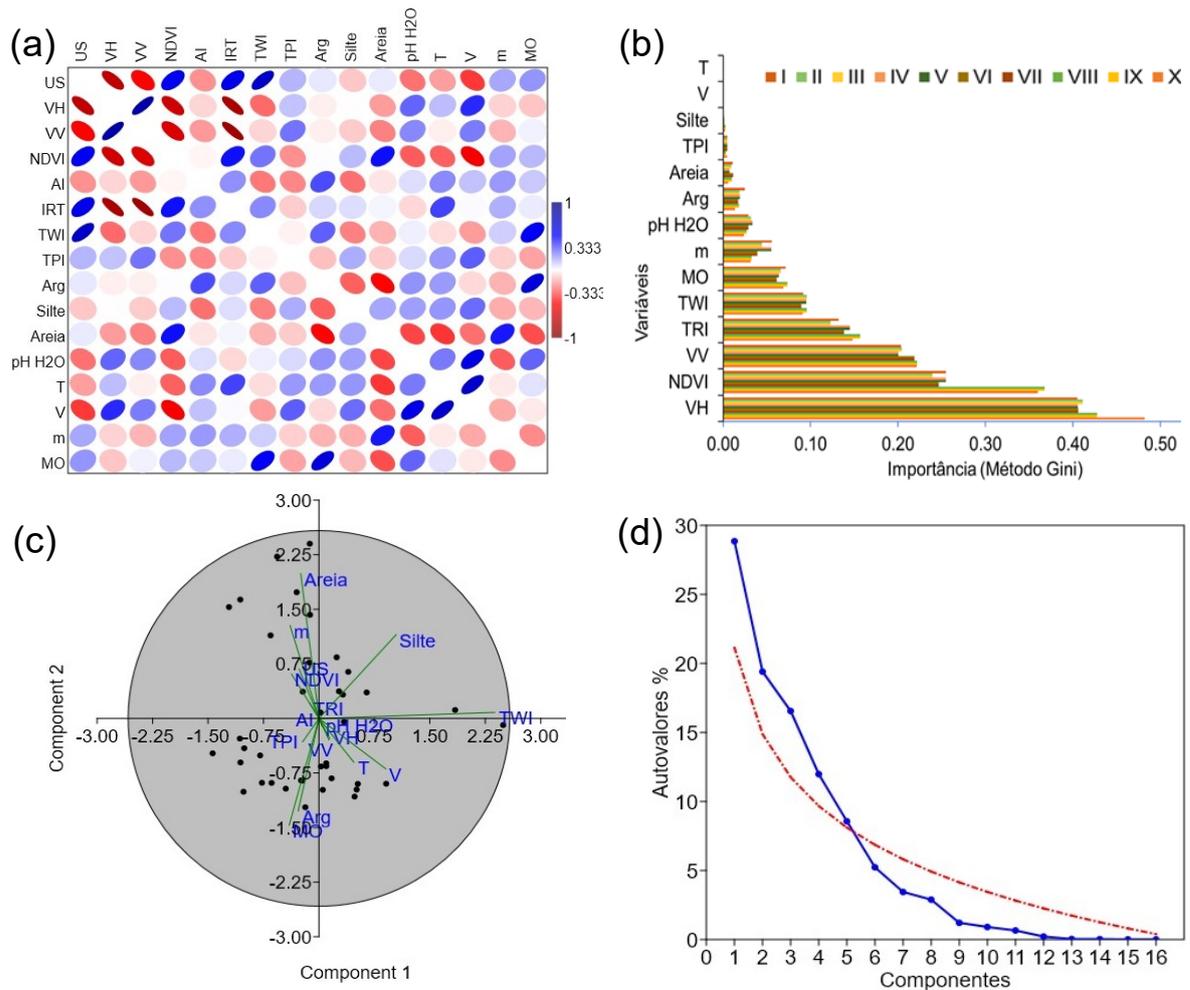


Figura 5.8. Correlograma (a), importância de Gini (b), análise de componentes principais (a) dispersão dos pontos e (d) importância dos autovalores.

5.3.5.1. Covariáveis SAR

A observação individualizada das variáveis SAR demonstrou alta correlação com os dados de umidade de solos medida em campo (Figura 5.9). A polarização cruzada VH exibiu maior coeficiente de determinação com a umidade do solo medida (média de 0,73), seguido pela polarização VV que apresentou 0,59 de correspondência com a umidade do solo (Figura 5.9a). Já a Figura 5.9b exibe o resultado para o AI, que acompanhou a tendência das polarizações VH e VV, porém,

com coeficiente de determinação menor ($R^2 = 0,32$) que as demais covariáveis originárias dos dados SAR.

Mohanty et al. (2020) afirmaram que a polarização VV detecta as diferenças dentro da estrutura vertical da vegetação em vários estágios de crescimento, o que interfere no sinal SAR para obtenção de informações da água no solo. Dessa forma a polarização cruzada VH é mais precisa do que a polarização HH ou VV para áreas com alguma vegetação, conforme mencionado por Saradjian e Hosseini (2011).

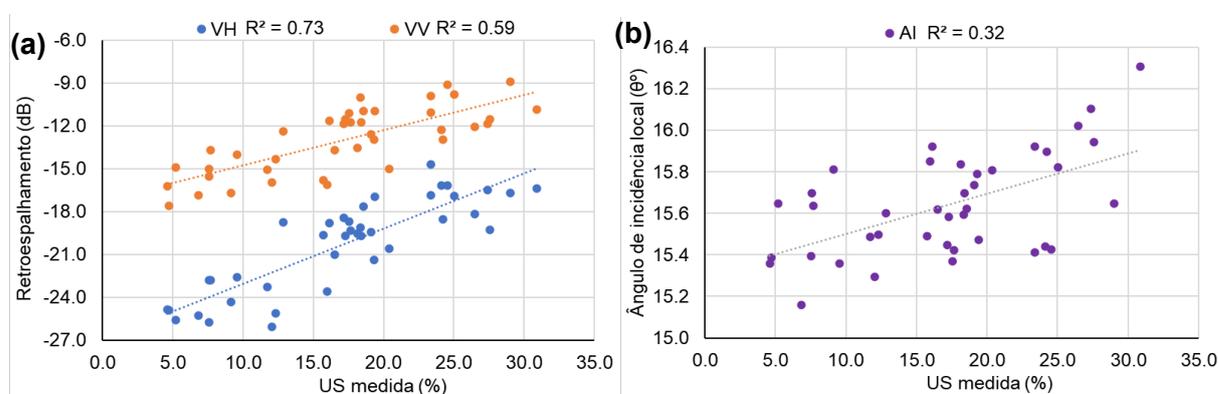


Figura 5.9. Gráfico de dispersão com as médias de umidade de solos coletadas em campo: (a) retroespalhamento das polarizações VH e VV; e (b) ângulo de incidência local do S1 ao longo da série temporal analisada.

Sekertekin et al. (2018; 2020) observaram uma baixa correlação do VH, VV e AI com os dados de umidade de solos quando analisaram a sensibilidade de dados de radar dos satélites ALOS-2 e Sentinel-1 para estimativas da umidade do solo em campos agrícolas, com e sem vegetação. Esses autores inseriram o NDVI junto às covariáveis SAR em um modelo que utiliza redes neurais para prever a umidade de solos. Entretanto, a polarização VV e o AI não participaram da análise devido a forte correlação com os valores de VH, como representado na Figura 5.9a deste Capítulo, o que os torna desnecessários segundo recomendações de Miller (2017).

5.3.5.2. Avaliação do NDVI

O comportamento do NDVI durante a série em estudo evidenciou uma forte relação com o ciclo de chuvas no DF. O comportamento dos dados também é confirmado na Figura 5.10a, que exibe os histogramas de NDVI ao longo da série temporal. Nessa representação, há dois grupos principais, o primeiro com valores de NDVI menores referentes aos meses de estiagem e outro grupo com limiares intermediários de NDVI e distribuídos nas séries associados aos meses mais chuvosos. A Figura 5.10b mostra que os valores mínimos de NDVI se concentraram nas épocas de menor incidência de chuvas (I, II e X) e os máximos, no período de maior pluviosidade (IV, V, VI e VII).

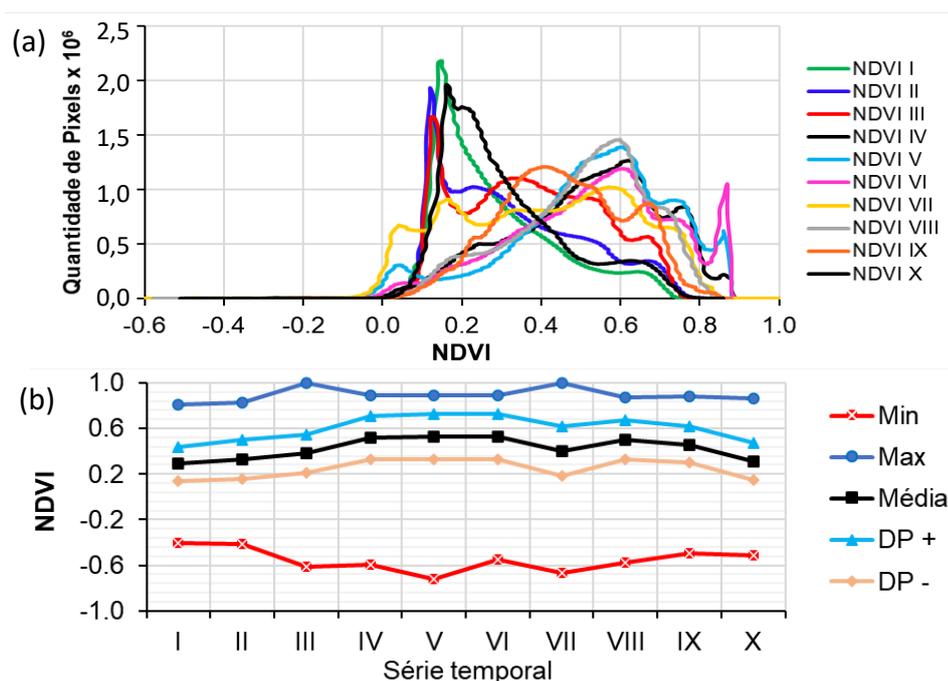


Figura 5.10. Histogramas dos valores de NDVI (a) e resumo dos dados de NDVI (b).

Gao et al. (2017) utilizaram dados dos satélites Sentinel-1 e Sentinel-2 para estimar a umidade de solos a uma resolução de 100 m e relataram forte correlação entre NDVI e umidade de solos medida em campo. Mohanty et al. (2017) reforçaram essa tese e atribuíram ao microclima criado sobre os dosséis em vários estratos. Datta

et al. (2020) também relataram esses fatores e identificaram a influência de áreas irrigadas sobre os resultados de NDVI e a umidade do solo. A Figura 5.11a exemplifica a forte correlação entre a umidade dos solos medida em campo e a polarização VH do Sentinel-1 da série I comparada com a correlação entre a umidade do solo e os limiares de NDVI referentes à primeira série de dados analisados (Figura 5.11b).

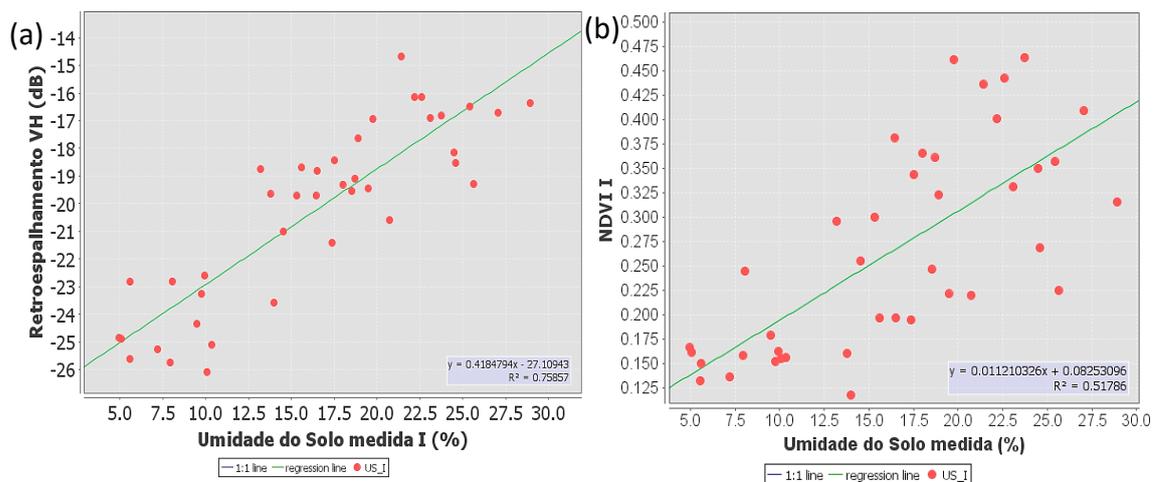


Figura 5.11. Plotagem correlativa do SNAP sobre dados médios de umidade do solo medida em campo e (a) retroespalhamento e (b) NDVI da primeira série de dados.

5.3.5.3. Análise das covariáveis pedomorfológicas

Acerca dos atributos relacionados ao terreno, derivados do MDE de 10 m, observou-se diferentes níveis de correlação com a umidade do solo medida em campo. A Figura 4.12 exibe os mapas gerados que demonstram a forte relação com a rugosidade do terreno, que considera os parâmetros morfométricos para o estabelecimento dos índices como o TPI, TRI e TWI (Figuras 5.12a, 5.12b e 5.12c, respectivamente). Contudo, a forte autocorrelação apresentada pelas covariáveis, observadas na Figura 4.12d, influenciou a decisão de excluir os dados de TPI das análises por meio de filtragem do método PCA e a análise de relevância de Gini.

Assim, as covariáveis TWI e TRI se mostraram mais importantes dentre os atributos do terreno para predição da umidade do solo pelas modelagens RLM e RF.

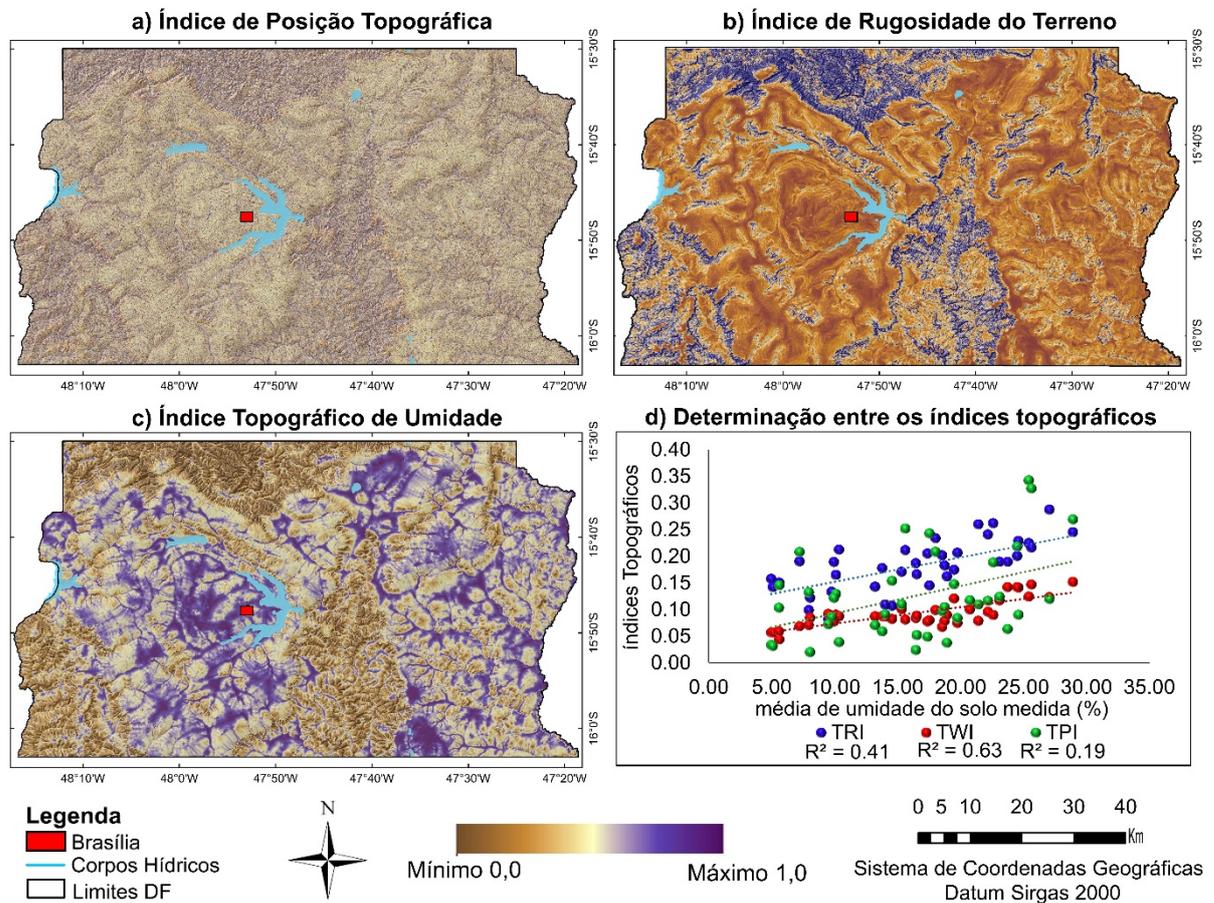


Figura 5.12. Covariáveis morfométricas: a) Índice de Posição Topográfica; b) Índice de Rugosidade do Terreno; c) Índice Topográfico de Umidade e d) Correlação.

Com relação às covariáveis de atributos químicos e físicos dos solos, houve relação não significativa a 90% e foram filtradas pela PCA e pela análise de relevância no método de Gini. Os valores de matéria orgânica, por exemplo, apresentaram correlação moderada com a umidade de solos, enquanto os demais atributos dos solos demonstraram correlação fraca. Esse comportamento dos dados diverge da série I, que exibiu valores de correlação forte e negativa para V% e correlação positiva para a umidade de solos, como observado por Poppiel et al. (2019) em solos do Centro-Oeste do Brasil.

Ao desconsiderar as variáveis explicativas colineares nos atributos dos solos, justifica-se uma correlação negativa entre o pH em H₂O e V% e os valores de umidade de solos. Como alguns pontos foram coletados sobre áreas com agricultura consolidada, os valores desses atributos acompanharam no sentido inverso da umidade de solos. Na prática, não há relação entre essas covariáveis, exceto o fato de alguns pontos de amostragem estarem sob um SPD em que estes atributos são corrigidos com adubação e calagem (FINK et al., 2014).

5.3.6. Desempenho da modelagem

Tanto a regressão linear múltipla quanto o modelo RF foram capazes de prever a umidade de solos por meio das covariáveis significativas. Os valores mínimos de coeficiente de determinação (R^2) foram de 66%, para a regressão múltipla e 82% para RF, ambos na etapa de treinamento dos dados (Tabela 5.1). Os dados na etapa de validação, teste, foram superiores para os dois modelos e alcançaram R^2 de 92% a 95% para regressão múltipla e RF, respectivamente. Esses percentuais revelam a superioridade do algoritmo RF em modelar os dados de umidade do solo, como observado por Datta et al. (2020). Nesse sentido, os valores de RMSE coincidiram com os períodos de chuvas no DF, época em que houve maior influência da vegetação. Apesar disso, foi observada a forte correlação do NDVI com a umidade do solo e as demais covariáveis.

Os coeficientes de determinação entre os valores de umidade de solos medidos e preditos pelos modelos de regressão e RF são exibidos no Apêndice C9. Houve uma forte correlação entre os dados (MILLER, 2017). Os dados referentes à estação seca obtiveram os melhores desempenhos comparados àqueles valores de umidade de solos extraídos no período chuvoso em ambos os modelos. Esse fato pode ser

explicado pela vegetação mais adensada nesta época e devido à ocorrência de chuvas irregularmente distribuídas.

Ainda na Tabela 5.1, nota-se que o comportamento dos valores de coeficientes de determinação influenciou nos percentuais de erro-padrão e RMSE. Dessa forma, modelos de regressão obtiveram valor mínimo de 1,04% na série X e máximo de 2,85% na série II para as variáveis teste, e corresponderam com um intervalo de RMSE que oscilou de 1,12%, para a série IV a 2,66% em II. Já o modelo RF apresentou variação de erro-padrão de 1,08% em IX a 2,59% em VI na etapa de treinamento e de 1,07% a 2,48% durante o processo de teste dos modelos. Os RMSE da modelagem RF variaram de 1,38% a 2,82% para a modelagem treino e 0,94% a 2,30% nas respectivas séries X e III.

Tabela 5.1. Resultados dos modelos de Regressão Linear Múltipla e *Random Forest*.

| Modelos Var Série | Regressão Linear Múltipla | | | | | | Random Forest | | | | | |
|-------------------------|---------------------------|------|------|----------------|------|------|----------------|------|------|----------------|------|------|
| | Treino | | | Teste | | | Treino | | | Teste | | |
| | R ² | EP | RMSE | R ² | EP | RMSE | R ² | EP | RMSE | R ² | EP | RMSE |
| I | 86,76 | 2,41 | 2,14 | 92,18 | 1,94 | 1,37 | 94,71 | 2,58 | 2,82 | 95,39 | 1,52 | 1,90 |
| II | 65,87 | 3,64 | 3,23 | 88,77 | 2,77 | 1,96 | 84,37 | 2,26 | 1,34 | 88,19 | 2,46 | 2,00 |
| III | 73,09 | 2,60 | 2,31 | 70,04 | 2,85 | 2,02 | 86,34 | 1,70 | 1,51 | 84,43 | 1,86 | 2,30 |
| IV | 81,60 | 1,93 | 1,71 | 72,28 | 1,59 | 1,12 | 81,67 | 2,32 | 1,43 | 89,94 | 1,93 | 1,34 |
| V | 78,76 | 2,96 | 2,62 | 73,73 | 2,25 | 1,59 | 87,67 | 2,44 | 1,61 | 92,86 | 2,25 | 1,06 |
| VI | 85,88 | 2,56 | 2,27 | 73,16 | 2,63 | 2,06 | 86,76 | 2,58 | 1,58 | 82,33 | 2,48 | 1,38 |
| VII | 88,44 | 1,77 | 1,57 | 81,21 | 2,38 | 1,68 | 89,03 | 1,66 | 1,45 | 83,95 | 1,72 | 2,15 |
| VIII | 77,20 | 1,31 | 1,16 | 76,03 | 1,27 | 0,90 | 82,85 | 1,20 | 1,77 | 88,58 | 1,14 | 1,22 |
| IX | 85,24 | 1,09 | 0,96 | 80,90 | 1,05 | 0,74 | 85,84 | 1,08 | 1,60 | 87,71 | 1,07 | 1,16 |
| X | 89,51 | 1,49 | 1,32 | 88,48 | 1,04 | 0,73 | 89,67 | 1,61 | 1,38 | 91,83 | 1,48 | 0,94 |

Var. variáveis; R² = Coeficiente de determinação; EP = Erro-padrão; RMSE = Raiz quadrada do erro médio.

Os coeficientes das covariáveis utilizados nas equações de regressão, referentes a cada conjunto de dados utilizados para construção dos modelos, estão dispostos na Tabela 5.2. A polarização VH serviu a todos os modelos, o que sugere que os dados dessa covariável são mais sensíveis à umidade que as demais. Em segundo lugar, os dados correspondentes à polarização VV não alcançaram significância estatística ($p > 0,1$) nos modelos I e X. Já os dados relativos ao AI

apresentaram baixa correlação e participaram apenas das equações I, II e X. Do mesmo modo, os NDVI não demonstraram correlação significativa em V, VI e VII, período chuvoso.

Tabela 5.2. Coeficientes da Regressão Linear Múltipla.

| CM\Série | I | II | III | IV | V | VI | VII | VIII | IX | X |
|---------------------|---------|--------|---------|---------|--------|--------|---------|--------|---------|---------|
| β_0 | -186,93 | 133,31 | -363,93 | -399,31 | 704,35 | 923,43 | -101,23 | 415,64 | -133,96 | -523,28 |
| VH-I | 0,87 | -0,20 | 1,64 | 1,28 | 4,42 | 3,47 | 2,67 | 1,96 | -0,10 | 0,66 |
| VV-I | * | * | 2,16 | * | 1,08 | 1,61 | 1,24 | 0,80 | 0,47 | 0,57 |
| NDVI I | 0,02 | 7,56 | 5,25 | 11,44 | * | * | 9,23 | 5,41 | 14,68 | 16,57 |
| AI | * | * | * | * | * | * | * | -1,97 | * | -0,62 |
| TPI | 4,85 | 6,62 | * | * | * | * | -1,69 | -1,23 | * | * |
| TRI | 49,29 | 45,23 | 12,54 | * | 40,10 | 21,92 | 2,05 | -0,20 | 12,45 | * |
| TWI | 1,43 | 0,74 | * | * | * | * | 0,21 | -0,15 | * | 0,21 |
| Arg | * | * | * | * | * | * | * | * | * | * |
| Silte | * | * | * | * | * | * | * | * | * | * |
| Areia | * | * | * | * | * | * | * | * | * | * |
| pH H ₂ O | * | * | * | * | * | * | * | * | * | 2,74 |
| T | * | * | * | * | * | * | * | * | * | * |
| V | * | -0,15 | * | * | * | * | * | -0,05 | * | * |
| m | -0,09 | * | * | * | * | * | * | * | * | * |
| MO | -0,12 | * | * | -0,15 | -0,20 | * | * | * | -0,04 | -0,20 |

CM = Componente do modelo; β = Coeficiente; EP = Erro-Padrão; t = teste de Student; P = valor de probabilidade; Inf. = Valores inferiores a 90% de probabilidade; Sup. = Valores superiores a 90% de probabilidade; β_0 = interseção; * Valor não-significativo a 90% de probabilidade.

Notadamente, os valores de inclinação da reta 1:1, em conjunto com os fatores de cada variável, serviram aos cálculos da umidade de solos nas equações de regressão. Assim, os valores médios dos pixels das variáveis preditoras sobre proximidades dos pontos de amostragem auxiliaram na elaboração das equações de cada modelo de regressão. De maneira semelhante, Sekertekin et al. (2018) modelaram eficientemente a distribuição da umidade de solos por meio de regressão linear múltipla, ao utilizarem um conjunto de covariáveis do Sentinel-1 na Turquia.

Não obstante, o desempenho geral dos modelos reforça a superioridade do método RF. Ao observar a distribuição dos erros na série, nota-se a capacidade de minimizar os ruídos durante o período chuvoso quando comparado ao modelo de regressão. Apesar dos menores valores de erro na época seca, observaram-se

limitações do método de regressão em prever a umidade do solo durante a estação de maiores índices de precipitação na área de estudo. Além dos fatores já conhecidos que contribuem para o desempenho da modelagem de dados SAR, procedimentos inadequados na coleta e análise dos dados, até o processamento podem influenciar negativamente a previsão da umidade do solo (ALEXAKIS et al., 2017).

5.3.6.1. Avaliação conjunta dos algoritmos

Tanto a umidade de solos predita pelo método regressão quanto pela RF acompanharam os acumulados diários de precipitação no DF. Como ilustra a Figura 5.13, os modelos empíricos demonstraram forte correlação com o período de coleta dos dados, de maneira que as séries acompanharam a curva média de referência de umidade do solo do DF.

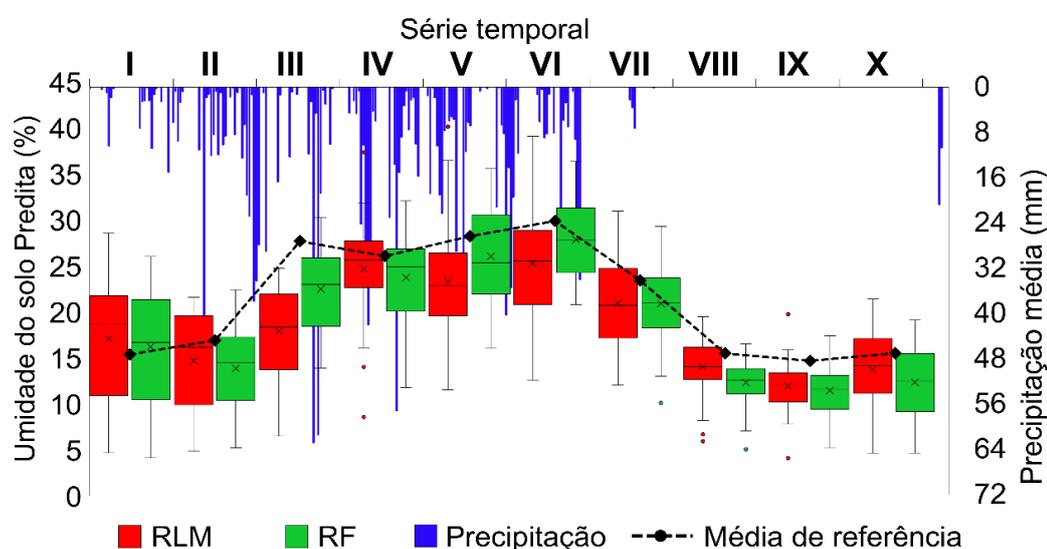


Figura 5.13. Variação da umidade dos solos predita pelos modelos de regressão linear múltipla (RLM) (em vermelho) e *Random Forest* (RF) (em verde); acumulados de precipitação diária e média de umidade do solo medida (linha pontilhada).

No início da série temporal, no período de estiagem (séries I e II), houve maior variação da umidade de solos atribuído à incidência de chuvas irregulares ao longo

da região de estudo. Os índices de umidade aumentam com o começo da estação chuvosa (séries III a VII) ocorreu alta amplitude de umidade do solo. Os meses mais secos da série temporal (VIII e IX) apresentaram as menores variações e índices de umidade do solo quando considerados os demais períodos selecionados neste trabalho. Zhang et al. (2018) relataram que as características diferenciais dos solos influenciam na oscilação dos dados de umidade ao longo de uma série temporal.

A Figura 5.14 exibe as amplitudes de cada conjunto de dados preditos. Os dados mais dispersos nos histogramas derivados das matrizes de umidade de solo preditas pelo modelo RF são aqueles coletados no final da época de estiagem como em I, II e X, na qual os valores médios de umidade do solo foram menores, como demonstram as linhas VII e VIII. Por outro lado, os pixels referentes aos períodos chuvosos concentraram-se em uma distribuição normal com altos valores médios de umidade de solos nas curvas III, IV e V.

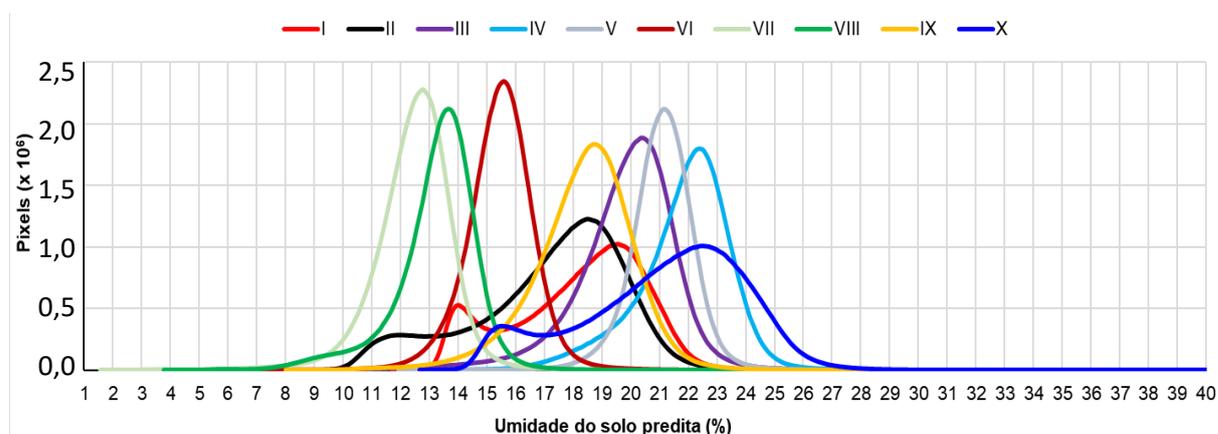


Figura 5.14. Histogramas da série temporal de umidade do solo modelada por *Random Forest*.

De maneira geral, a distribuição da umidade de solos predita se comportou semelhante à medida em campo, como observado por El Hajj et al. (2016) em áreas irrigadas. Os pontos caracterizaram a alta variabilidade de umidade, sobretudo naqueles perfis com textura muito argilosa e em relevo plano a suave ondulado. Esse

comportamento pode ser atribuído ao ambiente em que esses solos se desenvolvem, além disso, a superfície esteve sob vegetação natural adensada, no período de maior pluviosidade, o que implica em erros na predição da umidade, como também acrescentou Zhang et al. (2018).

De maneira geral, as mudanças espaço-temporais no teor de umidade do solo e informações sobre o tipo de solo corroboram a variabilidade na capacidade de retenção de água e taxa de evaporação da camada superficial do solo. Além disso, o estudo identificou as mudanças na umidade da camada superficial do solo devido a eventos de precipitação e atividades de irrigação durante o período de estiagem. Verificaram-se ainda altos percentuais de umidade do solo, mesmo na estação seca, que revela a alta capacidade de retenção de água nas classes atribuída à presença de horizonte subsuperficial concrecionário ou petroplíntico que dificulta a percolação da água no perfil (LACERDA e BARBOSA, 2012).

Embora os dados de precipitação e temperatura durante o período de estudo não tenham sido incluídos nas modelagens devido a irregularidades na ocorrência de eventos de precipitação pluviométrica, estas informações serviram para avaliar a modelagem com os dados de estações meteorológicas do Inmet (2020) situadas em cada setor de observação dentro da área de estudo. Os dados indicaram temperaturas médias e precipitação total de 30 °C e 70,8 mm em dezembro de 2019, enquanto no intervalo entre maio e setembro de 2020, estes números foram de 25 °C e apenas 10,5 mm. O número de eventos de precipitação nesse período explica os valores de umidade do solo inferiores, tanto no conjunto de dados medidos, quanto preditos.

Nesse sentido, a Figura 5.15a exibe a alternância de umidade de solos tomada como referência ao longo do período analisado, enquanto a Figura 5.15b demonstra a variação percentual do conteúdo de água modelada pelo método de regressão. A

Figura 5.15c ilustra os percentuais de umidade dos solos preditos pelo RF referentes aos mesmos pontos de validação. A modelagem RF conseguiu registrar maiores percentuais de umidade nas classes 1-LVAc, 11-LVAc e 15-FFc nos dados de referência, causada, principalmente, pela textura argilosa que aumenta a capacidade de retenção de água pelas camadas dos solos, (LACERDA e BARBOSA, 2012).

Ainda na Figura 5.15, houve maior variação de umidade nos solos arenosos, quando comparado aos dados de referência, porém, ambos os métodos exibiram os menores percentuais médios de umidade superficial, como exibido no ponto 35-RQo. A estrutura das partículas de quartzo soltas nesses solos promove a rápida infiltração da água no perfil condicionado, em menor expressão, pela declividade local já que ocorrem normalmente em relevo plano a suave-ondulado (SANTOS et al., 2018).

Já os Latossolos demonstraram comportamento intermediário para os dois modelos. Contudo, o perfil 9-LVd destaca a baixa variação da umidade superficial. Esse perfil encontra-se sob uso de pastagem e o pisoteio dos animais acaba por compactar a camada superficial do solo, o que dificulta a infiltração de água. Enquanto o perfil 37-LVd, que está sob vegetação natural preservada, aumenta a capacidade do solo em reter ou disponibilizar água (KÄMPF e CURTI, 2012).

A variação espaço-temporal da umidade do solo na camada superficial ocorre principalmente em função da taxa de evaporação que é influenciada pelo tipo de solo, eventos de precipitação, nebulosidade, umidade relativa, velocidade do vento e temperatura do ar (SILVA et al., 2013). Como relatado por Kämpf e Curi (2012), a maior ou menor variação na umidade de solos entre as classes se deve às características diferenciais intrínsecas a cada tipo de solo, além do tipo de uso e ocupação o qual o ponto está submetido. De acordo com Zhang et al. (2018), a

distância entre os pontos também afeta a variação, pois chuvas localizadas influenciam a aferição instantânea da umidade.

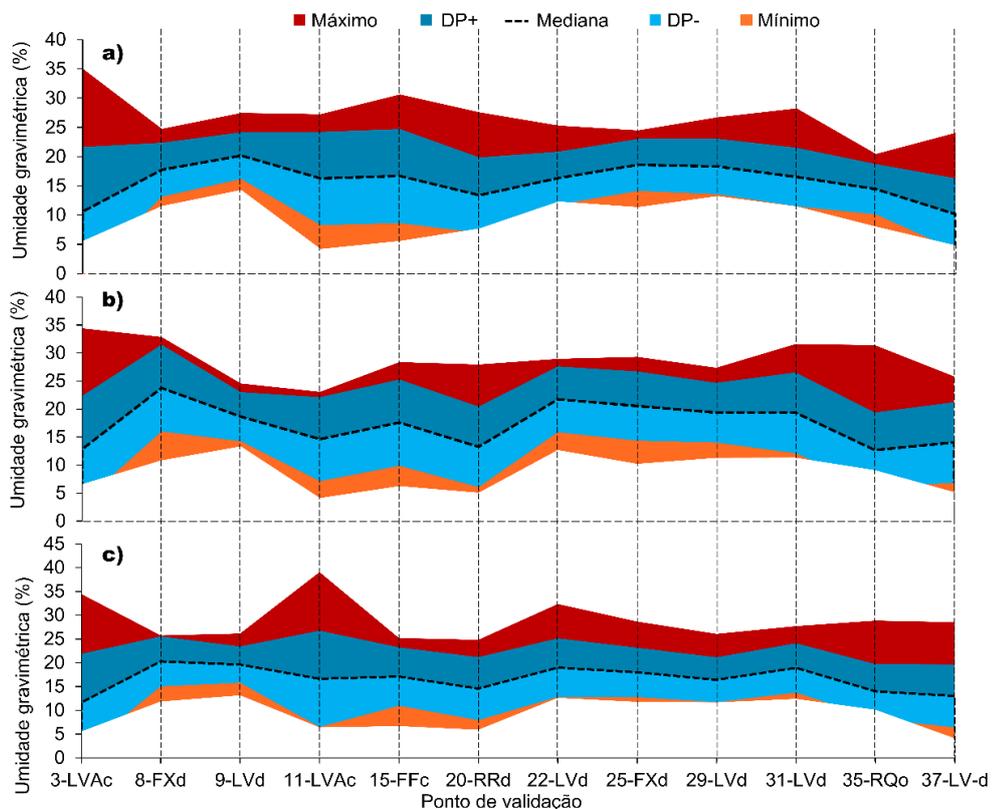


Figura 5.15. Validação da modelagem da umidade do solo: (a) referência em campo; (b) método de regressão linear múltipla e (c) método *Random Forest*.

5.3.6.2. Avaliação dos índices de umidade de solos do DF

A análise estatística dos mapas de umidade de solos preditos pelos modelos possibilitou o cálculo dos valores mínimos e máximos entre os dados do período (Tabela 5.3). A avaliação conjunta dos resultados demonstra que ocorreram áreas com umidade de solos mínima de 2,30% para o modelo de regressão e 4,09% no modelo RF, relativa a outubro de 2019 e setembro de 2020, respectivamente (estação seca). Em um estudo semelhante na China, Zhang et al. (2018) estimaram o índice de umidade do solo por meio de imagens multitemporais do satélite Sentinel-1 e concluíram que os melhores resultados ocorreram nos períodos de estiagem.

Vale ressaltar que os menores percentuais de umidade do solo preditos ocorreram em função do tipo de exploração a qual a área está submetida, nesse caso, agricultura em SPD, que expõe a superfície do solo em fase de pré-plantio (HUNKE et al., 2014). Embora haja, na área analisada, solos com baixa capacidade de armazenamento de água devido a diversos fatores, foram identificados percentuais acima de 2% durante as amostragens. Contudo, esses valores são aceitáveis ao considerar áreas antropizadas como pavimentos de estradas e construções que não foram mascarados neste trabalho, ou ainda afloramentos rochosos, por exemplo.

Por outro lado, as maiores estimativas de umidade alcançaram 46% na mesma série. Estes valores são possíveis na área e, inclusive, foram registrados valores próximos em classes como os Plintossolos Háplicos dos quatro setores, inclusive em épocas de estiagem. Apesar disso, podem representar *outliers*. Alexakis et al. (2017) identificaram altos teores de umidade em áreas alagadas na ilha de Creta, na Grécia, mediante a modelagem por redes neurais de dados Sentinel-1 e NDVI.

A variação de umidade das demais séries alcançaram valores intermediários condizentes com aqueles medidos em campo, com destaque para série II, que apresentou variação de umidade entre 4,85% a 21,58% para os modelos RF, percentuais diferentes daqueles dos observados pelo modelo de regressão (8,29% a 36,91%). Os erros nos modelos da distribuição da umidade de solos no período estudado foram minimizados pelas características nas SG mais aplainadas do DF. Entretanto, a distribuição mais espaçada dos pontos de amostragem prejudicou a correlação com os dados SAR como observado por Alexakis et al. (2017) e Zhang et al. (2018) que modelaram a umidade do solo nos domínios espacial e temporal.

Como disposto na Tabela 5.3, a última série (X), em áreas planas, a leste do DF, predominou a baixa umidade dos solos como na primeira (I) e na última imagem

(X) no modelo RF. Apesar do período de estiagem, os altos percentuais de umidade constatados no modelo RLM, na série X, representam solos com maior capacidade de retenção de água ou *outliers* (GAO et al., 2017). A influência do relevo no resultado da modelagem também foi evidenciada nos mapas de umidade de solos.

Tabela 5.3. Índices de umidade do solo da série temporal analisada pelos modelos Regressão Linear Múltipla e *Random Forest*.

| Série | Regressão Linear Múltipla | | | | | <i>Random Forest</i> | | | | |
|-------|---------------------------|-------------------------|------------------------|-------------------------|------------------|----------------------|-------------------------|------------------------|-------------------------|------------------|
| | ¹ Mín | ² σ^- | ³ \bar{X} | ⁴ σ^+ | ⁵ Máx | ¹ Mín | ² σ^- | ³ \bar{X} | ⁴ σ^+ | ⁵ Máx |
| I | 2,30 | 15,14 | 16,20 | 20,48 | 34,45 | 4,66 | 10,62 | 17,09 | 23,55 | 28,55 |
| II | 8,29 | 14,57 | 17,20 | 19,83 | 36,91 | 4,85 | 9,40 | 14,68 | 19,96 | 21,58 |
| III | 8,36 | 18,08 | 19,88 | 21,68 | 37,82 | 6,50 | 13,00 | 17,89 | 22,78 | 24,73 |
| IV | 12,75 | 20,25 | 21,89 | 23,53 | 38,95 | 8,56 | 19,46 | 24,70 | 29,94 | 37,35 |
| V | 11,94 | 20,05 | 21,15 | 22,25 | 34,54 | 11,51 | 17,27 | 23,25 | 29,23 | 48,12 |
| VI | 5,18 | 14,29 | 15,50 | 16,71 | 31,81 | 12,60 | 19,68 | 25,27 | 30,85 | 39,07 |
| VII | 5,70 | 11,17 | 12,52 | 13,87 | 29,60 | 12,03 | 16,18 | 20,93 | 25,68 | 30,95 |
| VIII | 3,77 | 11,83 | 13,28 | 14,73 | 28,65 | 5,93 | 11,14 | 14,04 | 16,94 | 29,50 |
| IX | 8,00 | 16,64 | 18,40 | 20,16 | 38,68 | 4,09 | 9,24 | 11,92 | 14,59 | 39,74 |
| X | 3,16 | 18,32 | 21,16 | 24,12 | 46,51 | 4,65 | 9,41 | 13,70 | 17,99 | 28,39 |

¹ Valor mínimo ² Desvio-padrão inferior; ³ Média aritmética; ⁴ Desvio-padrão superior; e ⁵ Valor máximo.

Assim, a modelagem RF se mostrou superior, quanto a qualidade dos resultados, pois, além de minimizar os erros de predição, suavizou as feições destacadas por atividades antrópicas, como observado por Poppiel et al. (2019c) ao predizerem atributos pedológicos no centro-oeste por meio do algoritmo RF.

Ao realizar estimativas de umidade do solo, Datta et al. (2020) consideraram a técnica de aprendizado de máquina por RF superior ao algoritmo RLM e outros modelos. Esses autores alcançaram 93% de correlação com o modelo RF. Por esta razão, os mapas de umidade do solo foram gerados com base no algoritmo RF.

5.3.7. Distribuição da umidade dos solos predita pelo método *Random Forest*

Além da topografia e da vegetação, a extensão da área de interesse, aumenta a variabilidade de feições, associada à quantidade limitada de pontos de calibração,

também são características altamente influenciadoras do desempenho em modelos dessa natureza (SANO et al., 2020). Cada imagem de umidade de solos expôs as variações espaciais para cada data estudada, cujo desempenho de cada predição ocorreu em função dos fatores pedológicos e ambientais, anteriormente comentados, que afetam a qualidade dos dados de sensoriamento remoto (ZHANG et al., 2018).

Nesse sentido, a umidade de solos recuperada nas duas primeiras imagens relativas a outubro de 2019 (Figura 5.16a e 5.16b) expressa uma maior variação espacial quando comparada com as demais imagens da série temporal. Contudo, notaram-se diferenças nos extremos oeste, leste e norte, caracterizadas por maiores percentuais de umidade. Vale destacar que os maiores percentuais ocorreram em áreas de várzeas e grotas típicas em ambiente de Cerrado que apresentam maiores índices de umidade do solo ao longo do ano (HUNKE et al., 2014).

Na terceira e quarta imagem da série analisada (Figura 5.16c e 5.16d), novembro e dezembro de 2019, respectivamente, houve maior variação espacial da umidade do solo, pois as datas em análise apresentam maior pluviosidade comparado com as demais regiões estabelecidas. Zhang et al. (2018) relataram que a distância entre pontos proporciona valores diferentes à modelagem. Isso foi observado mesmo entre classes de solos iguais, com propriedades e atributos semelhantes. Ainda assim, os percentuais de umidade de solos estiveram dentro da normalidade ao considerar as características da pedodiversidade local, descrita por Reatto et al. (2004), Poppiel et al. (2019b) e Novais et al. (2021).

As modelagens 5 e 6 (Figura 5.16e e 5.16f) demonstraram menor variabilidade na distribuição espacial da umidade comparado aos demais meses do ano, bem como os maiores percentuais de umidade do solo ocorreram nos meses de janeiro e fevereiro de 2020 nas áreas principalmente em regiões de várzeas. Diferentemente

das séries anteriores, esta apresentou áreas de solo mais seco a oeste do DF. Supõe-se que: a) houve uma menor incidência de chuvas no período de amostragem; b) houve uma distribuição irregular da precipitação nesta região à época ou c) há uma maior capacidade de drenagem nos perfis de solos sob análise.

A umidade de solos recuperada nas séries 7 e 8 apresentou variação entre 6% a 38% (Figura 5.16g de março e 5.16h de abril de 2020). A vegetação e padrões geomorfológicos também afetaram o desempenho da modelagem. Apesar da maior distância entre os pontos de amostragem, a metodologia conseguiu distribuir a umidade de solos de maneira eficiente. Nessas condições, houve diferenças na ocorrência de chuvas entre os pontos da região. Os erros na modelagem expressaram, de forma generalizada, a distribuição da umidade, como em Sekertekin et al. (2020). No setor em análise, as diferenças se concentraram em áreas vegetadas, tanto naturais, quanto em áreas consolidadas de agricultura e pastagem.

As imagens referentes às séries IX e X (Figura 5.16i e 5.16j), de junho e setembro de 2020, exibiram distribuição da umidade de solos diferentes, especificamente nas áreas com predominância de Cerrado ralo, Campo Cerrado e Campo úmido (SANO et al., 2019). Tais características mencionadas podem causar erros na modelagem em áreas agrícolas e de vegetação nativa, como observado por Zhang et al. (2018). Contudo, em locais com vegetação mais adensada, a modelagem da umidade de solos alcançou baixo desempenho, o que pode ser atribuído à menor capacidade de penetração da banda C sobre a vegetação densa (WU et al., 2019).

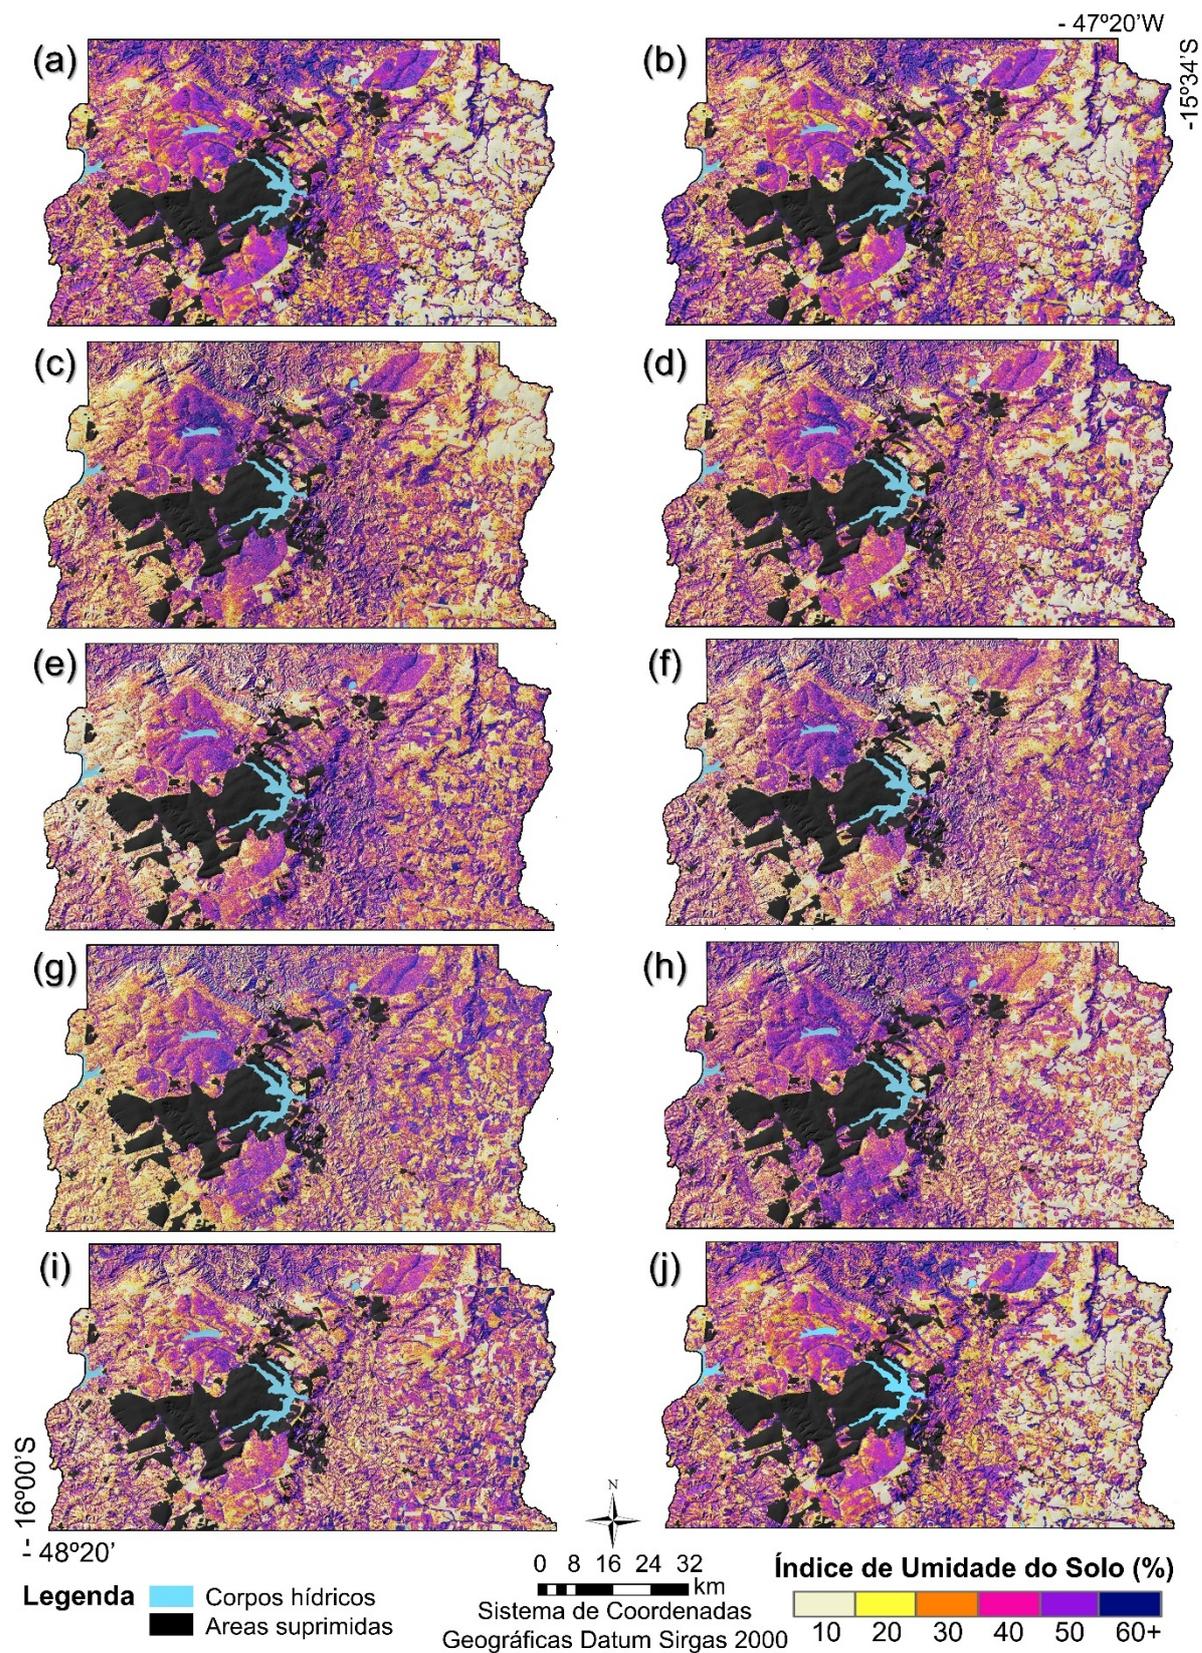


Figura 5.16. Mapas de umidade do solo da série temporal estudada. I – outubro (a), II – outubro (b), III – novembro (c), IV – dezembro (d), V – janeiro (e), VI – fevereiro (f), VII – março (g), VIII – abril (h), IX – junho (i) e X – setembro (j).

As características dos solos, associadas à posição no relevo, proporcionaram comportamentos diferenciados da umidade dos solos ao longo da série temporal. Entre os meses de março a setembro, período de estiagem no DF, ocorreu um decréscimo na umidade. De maneira oposta, nos meses de novembro a fevereiro houve um aumento, o que reforça a validade dos modelos empíricos, como também observado por Datta et al. (2020).

Vale observar que os altos percentuais de umidade do solo predita nas áreas de pousio durante a época de justificam-se pela presença de áreas irrigadas nos campos para o cultivo na entressafra. Por outro lado, áreas de cultivo em pousio são localizadas em áreas comparativamente mais altas e dominadas por solos lateríticos (alto escoamento superficial) ou solo com textura arenosa (alta taxa de infiltração), segundo Lacerda e Barbosa (2012).

Um número maior de observações de campo e a extensão da série auxilia no desempenho geral dos algoritmos, bem como na implementação de diferentes modelos para as várias classes de solo e rugosidades distintas. As informações de vegetação derivadas de dados ópticos podem ser integradas por meio de modelo de conteúdo de água e índices de água como o índice de água por diferença normalizada (NDWI) para minimizar os erros de modelagem da umidade do solo em áreas vegetadas (BAGDHADI et al., 2012; EL HAJJ et al. 2017; GAO et al. 2017; SEKERTKIN et al., 2018; 2020; DATTA et al., 2020).

5.3.8. Propagação dos erros da modelagem via *Random Forest*

A modelagem da umidade de solos via RF apresentou valores altos de RMSE (2,63%) durante a espacialização, sobretudo em áreas vegetadas e de relevo movimentado. Os menores valores de erro ocorreram em áreas de relevo plano a

suave-ondulado, geralmente com geomorfologia côncava, em vertentes. A predominância de áreas agrícolas sob SPD, irrigadas ou não, contribuíram para o melhor desempenho dos modelos. Como há menor influência do relevo e da vegetação nessas áreas, os erros relacionados às covariáveis SAR são minimizados, de acordo com relatos constantes em Sano et al. (2020).

A Tabela 5.4 apresenta cinco classes de RMSE médio alcançadas pela modelagem durante a série temporal. Os valores médios nas imagens de erros atingiram 1,24%, considerado relativamente baixo (MILLER, 2017). Ademais, cerca de 20% da área (aproximadamente 1.124 km²) obtiveram valores de erros entre 1,5% e 4,5%. Essas áreas coincidem com regiões de relevo montanhoso e de vegetação densa como as matas de galeria. Em contrapartida, quase 40% dos dados modelados apresentaram baixo ruído, sobretudo em áreas planas e sob exploração agrícola na porção leste do DF.

Tabela 5.4. Distribuição dos RMSE médios de umidade do solo predita ao longo da série temporal.

| Classe | Designação | Mínimo | Média | Máximo | Amplitude | Área | |
|--------|-------------|--------|-------|--------|-----------|--------|-----------------|
| | | % | | | | | km ² |
| 1 | 0,00 - 1,01 | 0,00 | 0,51 | 1,01 | 1,01 | 19,04 | 1096,96 |
| 2 | 1,01 - 1,15 | 1,01 | 1,08 | 1,15 | 0,14 | 19,81 | 1141,14 |
| 3 | 1,15 - 1,29 | 1,15 | 1,22 | 1,29 | 0,14 | 22,37 | 1288,42 |
| 4 | 1,29 - 1,45 | 1,29 | 1,37 | 1,45 | 0,16 | 19,28 | 1110,71 |
| 5 | 1,45 - 4,46 | 1,45 | 2,95 | 4,46 | 3,01 | 19,50 | 1123,56 |
| Total | | | | | | 100,00 | 5760,78 |

Fonte: Elaborado pelo autor.

A imagem de RMSE médio (Figura 5.17) ilustra a concentração dos erros em áreas de relevo movimentado, em detrimento aos menores percentuais de ruído em áreas aplainadas. Em áreas de vegetação densa, os erros foram minimizados, o que demonstra a relevância do NDVI nos modelos de umidade do solo. Paloscia et al. (2013) ao mapear a umidade do solo por redes neurais em uma região a nordeste da

Itália também identificaram tais características na modelagem da umidade do solo baseada em dados SAR.

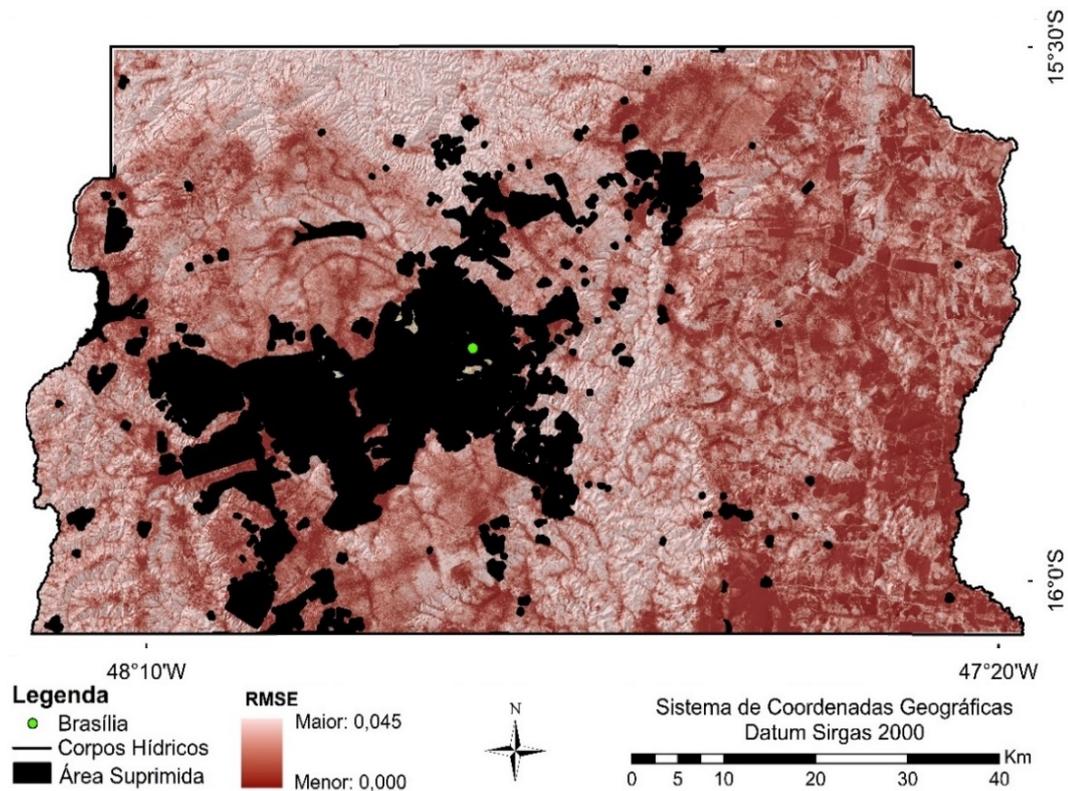


Figura 5.18. Imagem de raiz quadrada do erro médio da umidade da série temporal analisada.

5.4. CONCLUSÕES

As imagens de radar do satélite Sentinel-1, NDVI do Sentinel-2 e variáveis pedomorfológicas permitiram mapear a umidade dos solos do DF por meio de modelagem via algoritmo *Random Forest*. Os dados estimados alcançaram uma correlação máxima de 95,39% de correlação, 1,52% de erro-padrão e 1,90% de raiz quadrada do erro médio, para a etapa de teste da série I pelo modelo *Random Forest*, época de estiagem, especialmente para solos com pouca ou nenhuma cobertura. Por outro lado, esses valores alcançaram apenas 73%, 2,60% e 2,31%, respectivamente, de correlação, erro-padrão e raiz quadrada do erro médio, para a etapa de treino da

regressão linear múltipla referente à série III, mês de maior incidência de chuvas no DF. O que reforça a influência de fatores ambientais na modelagem de umidade do solo baseada em dados de radar.

Dessa forma, concluiu-se que a análise da variação da umidade do solo no domínio do espaço e do tempo em diferentes regiões do DF comprovaram as características dos atributos e propriedades dos solos, ao considerar o objetivo de estimar índices de umidade por meio de covariáveis originadas dos dados de sensoriamento remoto ativo e passivo e dados pedomorfológicos.

Como relatado por diferentes autores, modelar a umidade do solo por meio de dados SAR representa um desafio a ser superado. Essa tarefa necessita, principalmente, de dados multitemporais e muitas medições em campo. E ainda que isso seja disponibilizado, os fatores como microrrugosidade e cobertura vegetal desempenham um papel adicional que deve ser considerado em trabalhos futuros. A análise de propriedades como a capacidade de infiltração, densidade e porosidade pode auxiliar na modelagem, uma vez que possuem relação prática direta com a umidade do solo no perfil.

CAPÍTULO 6

RELAÇÃO ENTRE ÍNDICE DE UMIDADE DO SOLO DE SÉRIES TEMPORAIS E CLASSES PEDOLÓGICAS

6.1. INTRODUÇÃO

A capacidade de retenção ou disponibilização de água pelos diversos tipos de solos está diretamente associada às suas propriedades e à posição na paisagem (LACERDA e BARBOSA, 2012). Nesse sentido, estudos das relações pedomorfogeológicas e hidrológicas podem auxiliar na tomada de decisão quanto à conservação ou exploração sustentável desses recursos naturais não renováveis (HUNKE et al., 2014). Contudo, o levantamento de solos, bem como suas propriedades e atributos envolve uma alta demanda de tempo, pessoal especializado e recursos financeiros (DEMATTE et al., 2018).

Dessa forma, o mapeamento digital de solos (MDS) (classes ou atributos) por meio de modelagem multiespectral da faixa óptica surge como uma alternativa viável de aquisição e processamento dos dados pedológicos (NOVAIS et al., 2021). De acordo com Jensen (2009), o processamento de dados oriundos de sensoriamento remoto passivo ou ativo, em nível orbital, aéreo ou terrestre, possibilita as predições desses recursos e de muitos outros em larga escala.

O sensoriamento remoto torna os levantamentos de solos e propriedades mais eficientes e menos onerosos, tanto na faixa óptica do espectro eletromagnético (LACERDA et al., 2016; BAPTISTA e TEOBALDO, 2017; DEMATTE et al., 2018; POPPIEL et al., 2019; LIU et al., 2020; NOVAIS et al., 2021), quanto na de micro-ondas (ULABY et al., 1996; SANO et al., 1998; BAGDHADI et al., 2012; PALOSCIA et al., 2013; GARCIA et al., 2016; DATTA et al., 2020; SEKERTEKIN et al., 2018; 2020).

O sensoriamento remoto na faixa das micro-ondas emite e capta o sinal retroespalhado de um determinado ponto, que é linearmente correlacionável com a umidade do solo, quando desconsiderados os fatores que afetam a recepção do sinal transmitido pelos sensores (SANO e BORGES, 2019). Para Zhang et al. (2018), esses dados modelados representam as variações espaço-temporais da quantidade de água nas camadas superficiais dos solos por meio do índice relativo de umidade dos solos (IRUS). Contudo, há limitações técnicas quanto a interferência de fatores como topografia e vegetação, o que exige a inclusão de mais variáveis nos modelos preditivos de umidade do solo (DATTA et al., 2020). Há, ainda, a necessidade de validação dos dados obtidos a partir de pontos de verificação em campo diferentes daqueles utilizados em processos preditivos (MCBRATNEY et al., 2003).

Além disso, o coeficiente de variação de Pearson (CV) pode ser utilizado como referência da dinâmica dos IRUS em séries temporais, uma vez que, o CV consiste em um recurso estatístico que mede a dispersão de um determinado conjunto de dados (ZHANG et al., 2018). Assim, quanto maior o CV, mais heterogêneo é o conjunto de dados estudado, e, por outro lado, quanto menor o CV, mais homogêneo o grupo (MILLER, 2017). Uma sobreposição de dados matriciais IRUS e o CV proporciona uma forte correlação. O IRUS, por sua vez, pode ser validado mediante à sobreposição do MDS local.

Diante do exposto, este Capítulo objetiva avaliar o IRUS, recuperado por modelagem de dados de radar de abertura sintética (SAR) do sensor Sentinel-1, auxiliado por dados de índice de vegetação por diferença normalizada (NDVI), derivado do Sentinel-2, ambos em uma série temporal, em relação às várias classes pedológicas adquiridas por MDS modelado sobre série temporal multiespectral Landsat no Distrito Federal (DF).

6.2. MATERIAL E MÉTODOS

6.2.1. Fluxo de trabalho

O presente Capítulo dessa pesquisa foi realizado no DF entre os anos de 2019 a 2020 e envolveu a avaliação quantitativa e qualitativa do mapa digitais de solos (MDS) e do Índice Relativo de Umidade do Solo (IRUS). As observações pedomorfogeológicas, bem como as caracterizações climática e biótica da área de estudo estão descritas nos Capítulos 3 desta tese. As metodologias para obtenção dos subprodutos cartográficos acima citados estão apresentadas nos Capítulos 4 e 5.

Os trabalhos iniciaram com a compilação MDS que utilizou modelagem multiespectral para a predição das classes pedológicas com o auxílio de série temporal Landsat. Em seguida, recorreu-se ao cálculo do IRUS, obtido pela sobreposição de mapas de umidade do solo, que por sua vez, foram adquiridos por modelagem de dados Sentinel-1, Sentinel-2 e variáveis ambientais. Esses dois produtos foram cruzados para a avaliação qualitativa e quantitativa das classes de solos com a variabilidade da umidade superficial dos solos (Figura 6.1).

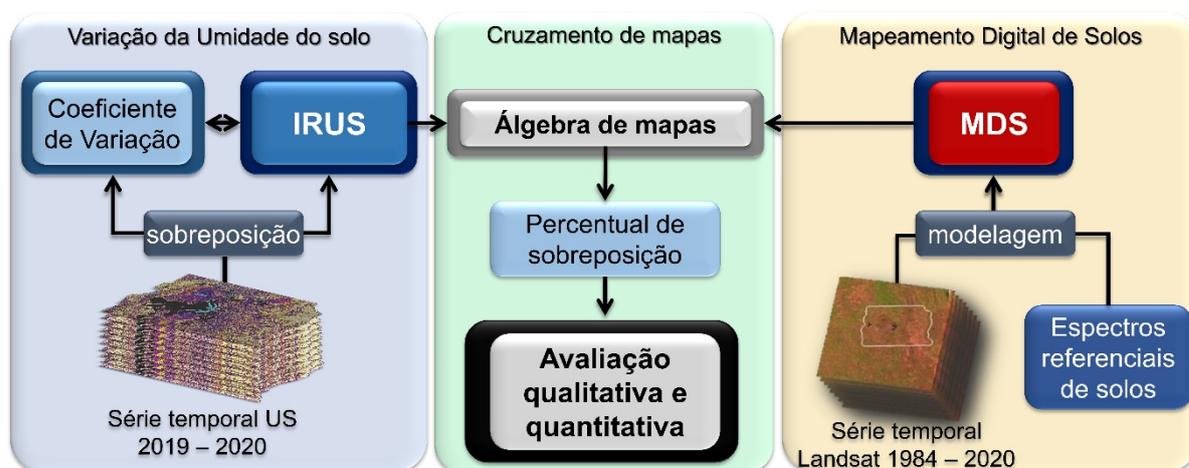


Figura 6.1. Fluxograma de trabalho para avaliação da umidade do solo em diferentes classes pedológicas. IRUS = Índice de umidade do solo, MDS = Mapa digital de solos.

6.2.2. Obtenção do mapa digital de solos

Com a aquisição e processamento de dados hiperespectrais de solos, representativos da pedodiversidade da área de estudo, foram obtidos membros de referências que serviram para modelagem de classes de solos sobre uma série temporal de solos expostos Landsat, obtida em via Google Earth Engine (GEE). Os modelos de mistura espectral representaram a distribuição das classes de solos, os quais foram comparados com dados de campo para a validação do MDS.

Dessa forma, o MDS com os polígonos referentes às classes de solos pré-determinadas no Capítulo 4 serviu de verdade de campo para validação deste trabalho. As informações contidas nele também compõem o banco de dados do Laboratório de Geoprocessamento e Pedomorfogeologia (Geoped) da Faculdade de Agronomia e Medicina Veterinária da Universidade de Brasília (FAV/UnB).

6.2.3. Estimativas dos índices de umidade do solo

A série temporal em análise contou com 10 imagens com os índices de umidade do solo ao longo de um ciclo pluviométrico registrado entre outubro de 2019 e setembro de 2020. A variação da umidade do solo foi recuperada por meio de dados SAR do satélite Sentinel-1A (ESA, 2012a; TORRES et al., 2012) e dados multiespectrais do satélite Sentinel-2 (ESA, 2012b), associados a covariáveis morfológicas extraídas do modelo digital do terreno (MDT). Sobre essas variáveis, foram executadas modelagens por meio do algoritmo de aprendizado de máquina *Random Forest* (RF), desenvolvido por Breiman (2001) no *software* estatístico R, que usa linguagem de programação (R CORE TEAM, 2019).

Os pontos de calibração (40 pontos de amostragem da umidade gravimétrica do solo medidos em campo) foram distribuídos da seguinte forma: 70% foram utilizados na etapa de treinamento e os 30% restantes, no procedimento de teste. Os pontos amostrados foram coletados sincronicamente com a passagem do satélite Sentinel-1, em quatro setores distintos do DF para a estimativas da umidade do solo na série temporal em um ciclo pluviométrico.

Para a modelagem por RF, foram consideradas, como variáveis preditoras, os dados obtidos pelo Sentinel-1 nas polarizações VH e VV, além do ângulo de incidência local (AI). Utilizou-se, ainda, os valores medianos de NDVI derivados do satélite Sentinel-2 de até 30 dias em torno da data de amostragem. Essas variáveis foram obtidas por intermédio de linguagem de programação na plataforma para processamento de dados geoespaciais *Google Earth Engine* (GOOGLE CO., 2021).

As variáveis do terreno foram inseridas nas análises para minimizar a influência desse fator no desempenho de modelos preditivos baseados em dados SAR, conforme recomendado por Mohanty et al. (2020). Para tanto, foram gerados o índice de rugosidade do terreno (TRI), o índice topográfico de umidade (TWI) e o índice de posição topográfica (TPI), calculados do MDE de 10 m de resolução espacial. Além disso, foram incluídos alguns atributos dos solos medidos em laboratório. Compuseram os modelos as covariáveis de maior relevância para os modelos preditivos da umidade do solo segundo análise de componentes principais (PCA) para cada conjunto de dados da série temporal.

A Tabela 6.1 exhibe as datas de coleta de dados em campo e de aquisição dos dados de campo e das imagens Sentinel-1, bem como a variação da umidade do solo medida em campo, divididas por etapas de treinamento e de teste, essas, tomadas como referência para a validação dos mapas de umidade do solo.

Tabela 6.1. Descrição da série temporal de umidade do solo medida em campo.

| Série | Data | Umidade do solo medida em campo | | | | | |
|-------|------------|---------------------------------|-------|--------|--------|-------|--------|
| | | Treinamento | | | Teste | | |
| | | Mínimo | Médio | Máximo | Mínimo | Médio | Máximo |
| I | 05/10/2019 | 4,13 | 16,20 | 26,02 | 6,96 | 16,04 | 22,35 |
| II | 29/10/2019 | 5,23 | 14,46 | 22,40 | 10,05 | 15,61 | 21,83 |
| III | 22/11/2019 | 13,89 | 22,86 | 30,23 | 19,13 | 22,82 | 25,33 |
| IV | 16/12/2019 | 11,80 | 24,77 | 32,06 | 19,52 | 25,81 | 28,86 |
| V | 21/01/2020 | 16,03 | 25,50 | 35,56 | 23,12 | 25,33 | 27,88 |
| VI | 14/02/2020 | 20,80 | 27,85 | 36,34 | 28,42 | 29,95 | 32,92 |
| VII | 09/03/2020 | 10,10 | 20,89 | 29,29 | 17,89 | 19,67 | 23,77 |
| VIII | 14/04/2020 | 5,06 | 12,50 | 16,52 | 4,87 | 10,40 | 12,43 |
| IX | 25/06/2020 | 5,18 | 11,45 | 17,38 | 7,63 | 12,92 | 17,88 |
| X | 17/09/2020 | 4,64 | 12,35 | 19,11 | 6,78 | 13,32 | 18,91 |

Fonte: Elaborado pelo autor.

6.2.4. Coeficiente de variação da umidade do solo

No sistema de informação geográfica (SIG) Envi 5.4 (HARRIS GEOSPATIAL SOLUTIONS, INC., 2020), as imagens de umidade do solo preditas foram sobrepostas de modo a formar um único arquivo com 10 bandas referentes às datas da série temporal avaliada. Sobre esse arquivo matricial, foram calculados, com funcionalidade *band math*, os seguintes parâmetros, conforme descrito por Miller (2017): a) média aritmética, que corresponde à uma medida de tendência central dos dados; b) desvio-padrão amostral; e c) coeficiente de variação, que corresponde à uma medida de dispersão, os quais são alcançados por meio das Eq. 6.1, 6.2 e 6.3, respectivamente.

$$\underline{X} = \frac{x_1 + x_2 + x_3 + \dots + x_n}{n} \quad (6.1)$$

Em que \underline{X} representa a média aritmética simples; $x_1, x_2, x_3 \dots$ corresponde a cada componente do conjunto de dados; e n consiste na quantidade de dados.

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{X})^2}{n}} \quad (6.2)$$

Em que σ é o desvio-padrão amostral; Σ é o somatório dos termos, desde $i = 1$ que corresponde à primeira posição até o último termo da série; x_i corresponde ao

valor na posição i no conjunto de dados; \bar{X} é a média aritmética dos dados; n é a quantidade de dados na análise; C_v representa o coeficiente de variação, em porcentagem; σ é o desvio-padrão; e \bar{X} é a média aritmética do conjunto de dados.

$$C_v = \frac{\sigma}{\bar{X}} \cdot 100 \quad (6.3)$$

De acordo com Miller (2017), valores de CV menores referem-se a dados mais homogêneos, isto é, haverá uma menor dispersão em torno da média, ou vice-versa. Valores menores ou iguais a 15% representam baixa dispersão: dados homogêneos; valores de 15% a 30% correspondem a uma dispersão moderada e CV acima de 30% denotam alta dispersão dos dados, heterogeneidade. Assim, houve a perspectiva de que os dados do IRUS acompanhassem essas tendências.

6.2.5. Índice relativo de umidade do solo em séries temporais

A funcionalidade álgebra de bandas do ENVI 5.3 possibilitou a implementação do cálculo para obtenção do IRUS. Para tanto, utilizou-se a diferença normalizada entre os valores máximos e mínimos de umidade do solo extraídos da série temporal, referentes às 10 datas de aquisição das imagens. Em seguida, calculou-se a razão entre as bandas resultantes, de acordo com a Eq. 6.4 que também retorna valores percentuais de variação da umidade do solo ao longo da série temporal.

$$IRUS_t = \frac{US_{max} - US_{min}}{US_{max} + US_{min}} \quad (6.4)$$

Em que $IRUS_t$ é o índice relativo de umidade do solo de série temporal; e US_{max} e US_{min} correspondem, respectivamente, aos valores máximos e mínimos dos pixels das imagens. Estabeleceu-se classificações de variabilidade dos dados, nos quais: valores entre 0 e 10, correspondem a baixa variação; 10 a 20, moderada; 20 a 30

média; 30 a 40, alta variabilidade e valores acima de 40 representam uma dispersão muito alta dos dados (MILLER et al., 2017).

Ao final dessa etapa, os arquivos *raster* de CV e IRUS foram submetidos a uma filtragem pelo método da mediana com células de 5 pixels x 5 pixels e, posteriormente, reclassificados em seis categorias com um intervalo de 10% baseado nos quartis dos valores dos pixels da matriz de dados. Os arquivos *raster* referentes ao CV e IRUS foram reamostrados para 30 m de resolução espacial e convertidos para vetor, no formato *shapefile* (.shp), legendados com cores contrastantes entre as classes de variação da umidade do solo. Por fim, as tabelas de atributos foram editadas para cálculos das áreas correspondentes às classes de variação da umidade do solo.

6.2.6. Análise da variabilidade da umidade do solo na série temporal

Os dados de CV e IRUS foram analisados conjuntamente segundo a dispersão dos dados, de forma a verificar se há correspondência entre os dois cálculos de variação espacial e temporal da umidade do solo. De acordo com Zhang et al. (2018), o IRUS tende a apresentar maior dispersão dos dados quando comparado ao CV.

Dessa forma, o IRUS índice foi utilizado para verificação das correspondências e discrepâncias entre as classes de solos e a variação da umidade inerente a essas classes. Ao considerar os fatores que influenciam na capacidade de retenção e disponibilização de água pelas diferentes unidades pedológicas, a umidade deverá variar de acordo com as características de cada classe de solo na paisagem (WEIL e BRADY, 2019).

6.2.7. Cruzamento de mapas

Os mapas foram, então, submetidos ao algoritmo *raster calculator* da caixa de aplicações *Map Algebra* e *Spatial Analyst* do programa ArcGIS 10.7.1 para calcular as

áreas, em percentual, de cada classe IRUS dentro dos polígonos com as classes de solos, o que possibilita a avaliação quantitativa e qualitativa das sobreposições dos arquivos *raster* (NOVAIS e LACERDA, 2021).

O arquivo resultante gerou uma tabela estatística com os valores de sobreposição dos pixels originários dos dados de entrada. Essa tabela foi exportada do programa ArcGIS (ESRI, 2019) por meio da funcionalidade *Zonal Statistics as Table* que exporta informações do dado matricial para o formato .csv, compatível com a maioria dos gerenciadores de planilhas eletrônicas, no qual pode ser contabilizada as áreas com ou sem intersecções entre os polígonos dos vetores do MDS e IRUS.

6.3. RESULTADOS E DISCUSSÃO

6.3.1. Análise da variação da umidade dos solos do DF

6.3.1.1. Umidade do solo na série temporal

Os modelos de RF recuperaram eficientemente a umidade do solo em todos os conjuntos de dados da série temporal com altos valores de correlação de Pearson entre os dados medidos e preditos (entre 86% e 91%) e baixos valores de raiz quadrada do erro médio (RMSE) (0,02 a 0,04) (MILLER, 2017). Datta et al. (2020) compararam o desempenho da modelagem da umidade do solo por diferentes técnicas de aprendizado de máquina por meio de dados observados em campo e do Sentinel-1 e obtiveram alta correlação entre os dados medidos e preditos ($R^2 = 0,87$ a $0,93$) durante a modelagem e validação, respectivamente, com RMSE de 0,03.

Como ilustra a Figura 6.2, a variação da umidade do solo acompanhou a curva de pluviosidade média do DF e os registros de precipitação mensal das épocas de amostragem (INMET, 2020). Assim, a observação do comportamento geral dos dados mostrou os maiores percentuais e menores amplitudes da umidade do solo durante

os meses chuvosos. Em contrapartida, períodos de estiagem demonstraram os menores índices e maior dispersão dos dados de umidade do solo.

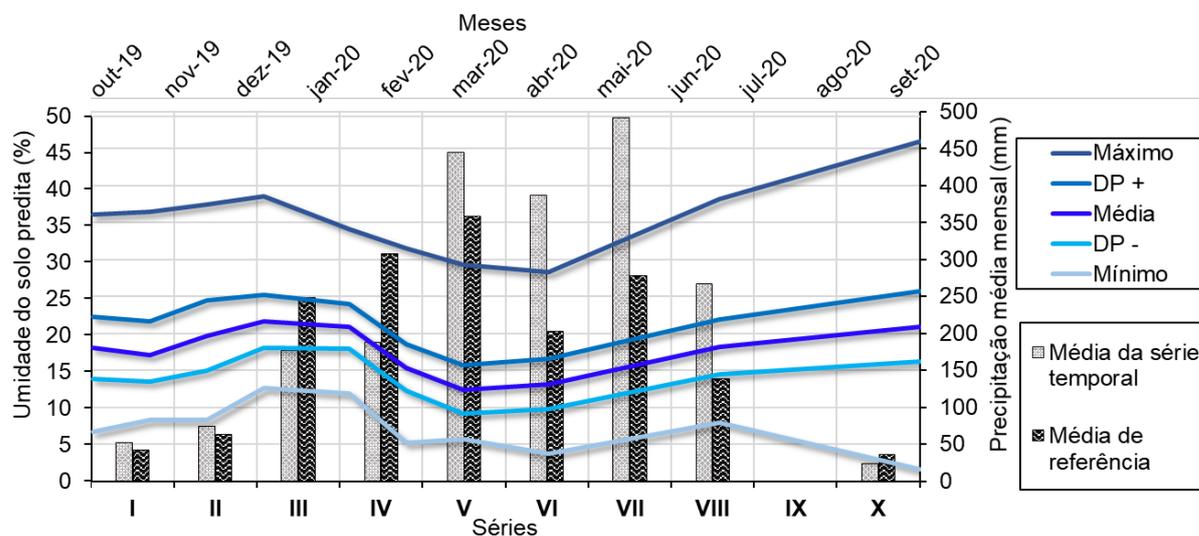


Figura 6.2. Umidade do solo predita e precipitação pluviométrica ao longo da série temporal. DP- e DP+ correspondem a desvio-padrão inferior e superior, respectivamente.

A Figura 6.3 também destaca que as maiores variações e amplitudes de umidade do solo em meses secos e, de modo inverso, em meses chuvosos, a variação e amplitude foram menores. Zhang et al. (2018) também observaram esse comportamento ao estimar a umidade do solo por meio de dados SAR e medições automáticas de umidade do solo com uma abordagem multitemporal na China. Para tanto, os autores utilizaram um modelo linear de efeitos mistos que retornaram resultados satisfatórios com baixos valores de RMSE (0,02) e correlação de 68% durante a validação cruzada.

6.3.1.2. Coeficiente de variação da umidade dos solos

O mapa com o CV da umidade do solo (Figura 6.3, ampliado no Apêndice E1) demonstrou uma distribuição irregular ao longo do DF. As feições de CV alcançaram

percentuais desde 7,6 até 46,6, o que reitera a heterogeneidade dos dados da série temporal estudada. A Figura 6.3a realça as áreas de preservação da vegetação natural do Cerrado do Parque Nacional de Brasília. Houve forte influência da vegetação na modelagem dessas áreas, o que proporcionou os maiores erros de predição, contudo, ocorreram feições de formas irregulares típicos de áreas com vegetação natural com baixos CV (entre 10 e 20%).

Por outro lado, como destacado na Figura 6.3b, as feições caracterizadas por padrões angulares evidenciaram a influência de atividades humanas na porção leste do DF, área ocupada por atividades antrópicas de exploração agropecuária, (NOVAIS e LACERDA et al., 2021). Notadamente, em locais com elevada antropização, houve alta variabilidade com predominância de CV acima de 30% devido às práticas agrícolas como o SPD e irrigação, que significa alta variabilidade dos dados de umidade do solo (MILLER, 2017). As áreas em azul nessa região representam formações de Cerrado ainda preservadas por força de leis florestais, como observado por Novais e Lacerda (2021) ao avaliar a adequabilidade do uso das terras no DF.

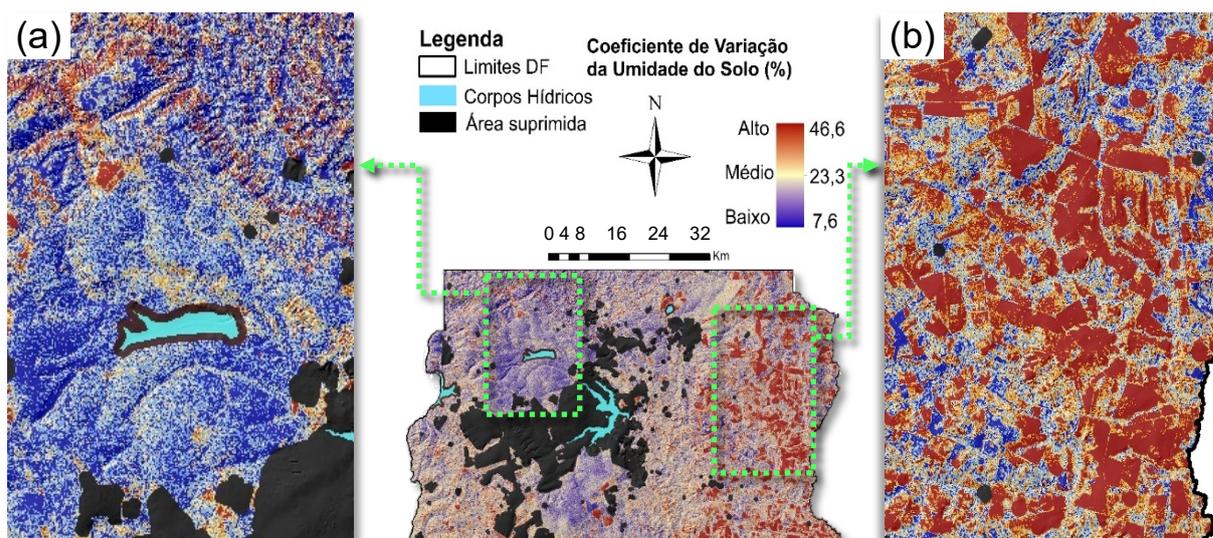


Figura 6.3. Mapa de coeficiente de variação da umidade do solo com destaque para áreas de baixa (a) e alta variabilidade (b).

6.3.1.3. Índice relativo de umidade do solo em séries temporais

Os percentuais de IRUS variaram entre 0% e 89%. Cerca de 60% da área apresentou variabilidade baixa à média e os 40% restantes, com variação alta a muito alta ao longo da série temporal (Tabela 6.2). O efeito negativo de áreas vegetadas e terrenos declivosos sobre a modelagem da umidade do solo foi também reportado por vários autores (ULABY et al., 1996; SANO et al., 1998; PALOSCIA et al., 2013; GARCIA et al., 2016; DATTA et al., 2020; SEKERTEKIN et al., 2018; 2020). Essas áreas tendem a manter a umidade do solo por mais tempo e, conseqüentemente, ocorre uma menor variação ao longo do ano.

Tabela 6.2. Contabilização das classes de índice relativo de umidade do solo.

| Classe | Designação | Mínimo | Máximo | Área | |
|--------|------------|---------------|--------|-----------------|-------|
| | | ----- % ----- | ----- | km ² | % |
| 1 | Baixa | 0,00 | 10,00 | 1102,36 | 19,14 |
| 2 | Moderada | 10,01 | 20,00 | 1251,97 | 21,73 |
| 3 | Média | 20,01 | 30,00 | 1198,82 | 20,81 |
| 4 | Alta | 30,01 | 40,00 | 1178,44 | 20,46 |
| 5 | Muito alta | 40,01 | 100,00 | 1029,18 | 17,87 |

Fonte: Elaborado pelo autor.

A análise visual do IRUS (Figura 6.4, ampliado no Apêndice E2) evidenciou comportamento de feições distinto àquele do mapa de CV da umidade do solo. Houve uma concentração de áreas com baixa variação de umidade do solo na parte central do DF, especialmente sob regiões de vegetação natural preservada (Figura 6.4a). Nos extremos, houve predominância de alta variabilidade, como mostrado na porção leste (Figura 6.4b). A parte oeste também revelou a alta variação da umidade do solo. Porém, diferentemente da porção leste, essa área é marcada pela paisagem dissecada, onde predomina a vegetação natural (NOVAES PINTO, 1987).

As porções norte e sul do DF apresentaram um comportamento intermediário com a mistura de áreas com alta variação da umidade do solo e outras com menores

percentuais de IRUS. Nessas áreas, a paisagem é marcada pela presença de relevo movimentado e faz parte da SG-III, região dissecada de vales, cuja vegetação predominante é de Cerrado ralo com ocorrência de algumas áreas com atividades agropecuárias em menores declividades (CODEPLAN, 2020a).

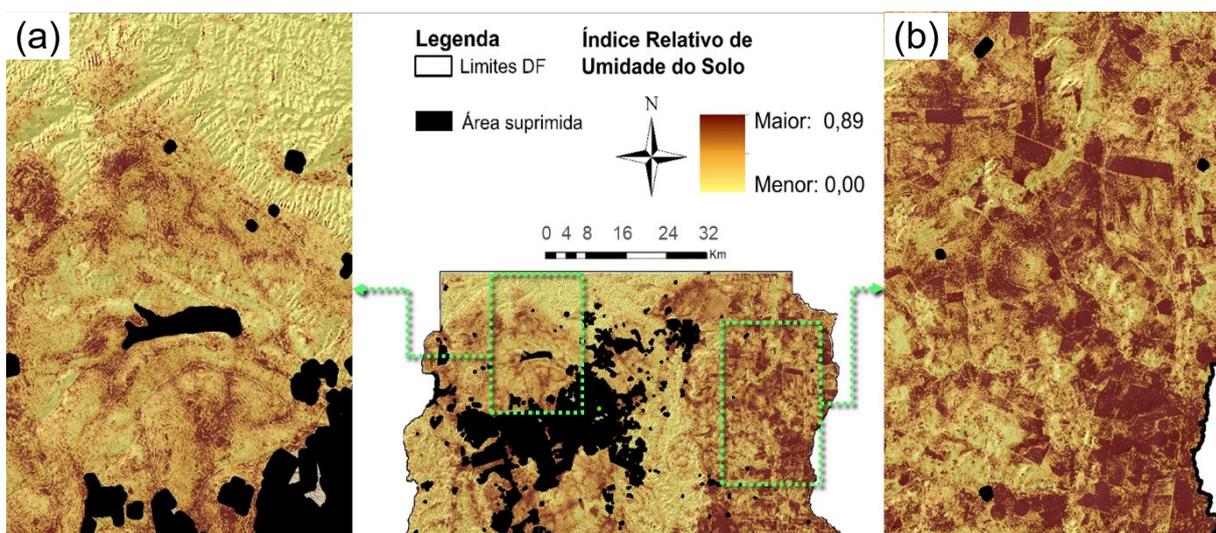


Figura 6.4. Mapa de índice relativo de umidade do solo com destaque para áreas de baixa (a) e alta variabilidade (b).

6.3.1.4. Avaliação da variabilidade da umidade do solo na série temporal

A variação conjunta dos dados medidos da umidade do solo (CV e IRUS) é ilustrada na Figura 6.5a, a qual demonstra a distribuição dos valores em histogramas de CV e IRUS preditos (Figura 6.5b). O comportamento das curvas nos gráficos sugere semelhanças entre os dois conjuntos de dados. De forma geral, a análise visual da imagem de IRUS já demonstrou certa correspondência à imagem de CV.

Ainda na Figura 6.5b verificou-se que os percentuais de variação foram mais altos em épocas de estiagem e menores em estações úmidas para os dois conjuntos de dados. Vale destacar que, apesar de ocorrer colinearidade entre os dados das matrizes, uma vez que foram derivados do mesmo conjunto, as diferentes operações

matemáticas permitiram comprovar quantitativamente esta correspondência, como observado por Zhang et al. (2018) quando avaliaram o comportamento da variação espaço-temporal da umidade do solo.

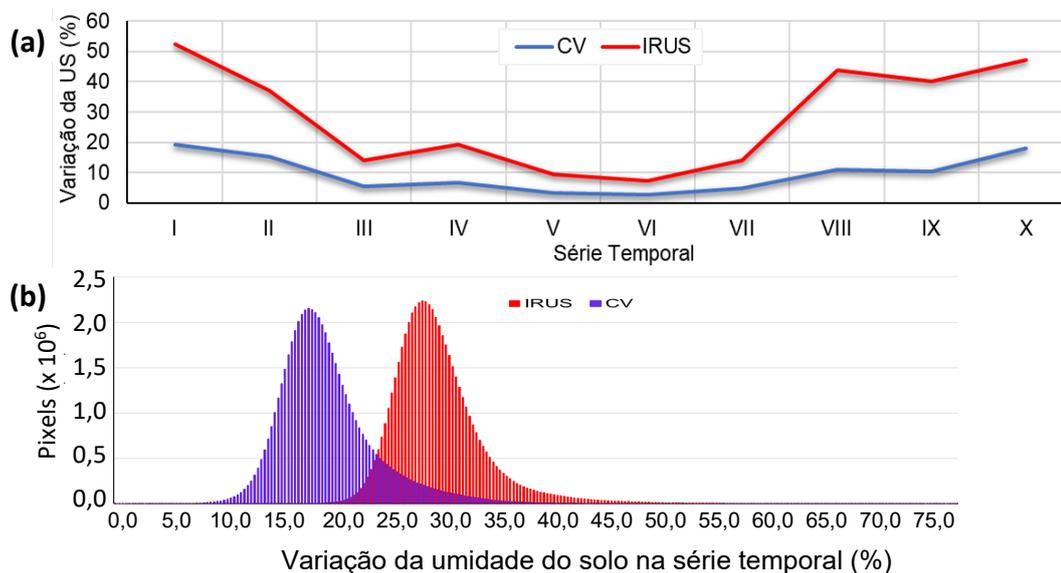


Figura 6.5. Gráficos de distribuição do coeficiente de variação de Pearson (CV) e do índice relativo de umidade de solos (IRUS). Variação conjunta (a) e histogramas (b).

Por meio da observação dos histogramas constatou-se a normalidade dos dados, o que foi comprovado nos principais testes de normalidade utilizados para validar a hipótese alternativa de que os dados estão normalizados. A Tabela 6.3 exibe os resultados de probabilidade de os dados apresentarem uma distribuição normal.

Tabela 6.3. Testes de normalidade dos dados de índice relativo de umidade de solos (IRUS) e coeficiente de variação de Pearson (CV).

| Conjunto de dados | IRUS | CV |
|--------------------|------------|------------|
| Shapiro-Wilk W | 0,97240 | 0,98220 |
| p (normal) | 0,00000 | 0,00000 |
| Anderson-Darling A | 342,30000 | 214,30000 |
| p (normal) | 0,00000 | 0,00000 |
| p (Monte Carlo) | 0,00010 | 0,00010 |
| Lilliefors L | 0,05469 | 0,05046 |
| p (normal) | 0,00010 | 0,00010 |
| p (Monte Carlo) | 0,00010 | 0,00010 |
| Jarque-Bera JB | 2127,00000 | 1571,00000 |
| p (normal) | 0,00000 | 0,00000 |
| p (Monte Carlo) | 0,00010 | 0,00010 |

* Significativo a 99% de probabilidade normal.

Basicamente, o CV medido obteve forte correlação positiva com o IRUS (Figura 6.6a). Os pixels localizados próximos da origem do gráfico sugerem uma maior variabilidade espacial da umidade dos solos em períodos de seca. Como existem grandes áreas antropizadas no DF, as diferenças espaciais mais pronunciadas de umidade do solo entre elas e áreas com vegetação natural de Cerrado também podem contribuir para o IRUS mais alto em condições mais secas.

A tendência do CV pode ser ajustada por uma função de potência decrescente, com um alto coeficiente de determinação ($R^2 = 0,88$) para os pontos de amostragem e 76% para os *rasters* gerados (Figura 6.6b). Semelhante tendência decrescente foi encontrada para o CV da umidade do solo por muitos estudos realizados em climas distintos, os quais os autores relacionaram parâmetros da característica de retenção de umidade do solo e sua variabilidade espacial (BROCCA et al., 2007; VEREECKEN et al., 2007; PRATOLA et al., 2014; ZHANG et al., 2018 e DATTA et al., 2020).

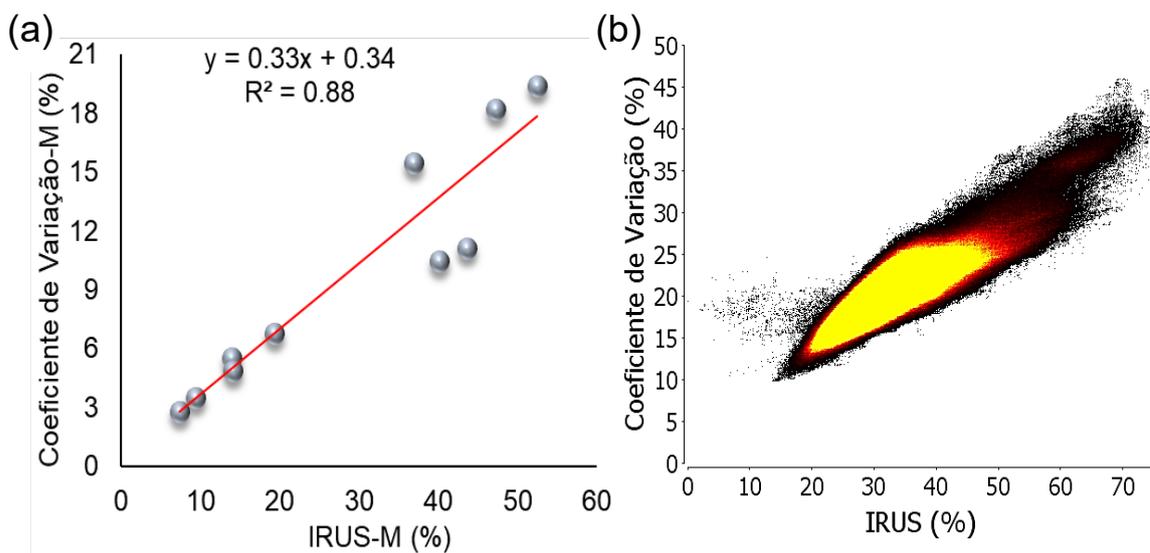


Figura 6.6. Gráficos de dispersão entre o índice relativo de umidade de solos (IRUS) e coeficiente de variação (a) medidos em campo e (b) das imagens previstas.

6.3.2. Variação da umidade dos solos com base nas classes pedológicas

As classes de solos identificadas pelo MDS foram definidas como Latossolos Vermelhos e Vermelhos-Amarelos, Plintossolos Pétricos e Háplicos, Cambissolos Distróficos, Neossolos Regolíticos e Quartzarênicos e Argissolos, com base em Santos et al. (2018). Vale ressaltar que houve textura variável entre as classes pedológicas, atributo majoritariamente responsável pelas variações na umidade no perfil (LACERDA et al., 2016).

Em estudos sobre as relações pedomorfogeológicas das chapadas elevadas do DF conduzidos por Lacerda e Barbosa (2012) afirmaram que algumas características dos solos como profundidade, textura, porosidade, entre outras, influenciam na variação da umidade do solo. Como exemplo, houve baixa variação da umidade do solo em áreas de ocorrência de Plintossolos Háplicos. Segundo Santos et al. (2018), essa classe possui um horizonte diagnóstico subsuperficial (horizonte C) que é formado por regolitos muito argilosos que mantêm a água no perfil durante mais tempo, quando comparado aos Latossolos, por exemplo.

O cruzamento dos mapas viabilizou a análise quantitativa da sobreposição de polígonos referentes às classes de solos e de IRUS por meio do cálculo dos percentuais de sobreposição dos polígonos avaliados neste estudo. Esses cálculos consideraram apenas a área mapeada no DF, que representou 63,66% de toda extensão do DF, referentes aos percentuais de solos expostos alcançados pela metodologia do Capítulo 4 (DEMATTE et al., 2018; POPPIEL et al., 2019; NOVAIS et al., 2021). A análise dos dados da Tabela 6.4 demonstrou o comportamento da umidade do solo nas várias classes pedológicas.

Apesar das limitações que o método de estimativas da umidade do solo encontrou, notamos que as propriedades e atributos intrínsecos às várias classes de

solos estão de acordo com a umidade do solo apresentada pelo modelo, o que valida qualitativamente a metodologia. Como exemplo, os solos com textura franco-arenosa do DF (Latosolos) que alcançaram menor variação de umidade no período.

Naquelas classes de solos reconhecidamente capazes de reter umidade por um maior período ocorreram os maiores índices de umidade do solo, como os Plintossolos Pétricos, Plintossolos Háplicos, Latossolos Vermelho-Amarelos argilosos com horizonte concrecionários, os quais apresentaram baixos percentuais de IRUS.

Por outro lado, solos com baixa capacidade de retenção de água no perfil, tais como os Neossolos Quartzarênicos, alcançaram pouca variação desse índice. Devido a sua textura arenosa, a água infiltra com mais rapidez no perfil do solo, que resulta em uma menor variação nos RQo (TEIXEIRA et al., 2017). Os atributos e propriedades pedológicas influenciam a variação da umidade do solo (LACERDA et al., 2016).

Tabela 6.4. Percentuais de sobreposição entre as classes solos e as classes de variação da umidade do solo ao longo da série temporal analisada.

| Classe de Solo | Text. | Classes de variação da umidade do solo (%) | | | | | | | | Subtotal MDS Área (%) | |
|-----------------------------------|--------|--|-------------------|----------------|---------------|---|-------------|-------------|-------------|--------------------------|---------------|
| | | Baixa < 10 | Moderada 10-20 | Média 20-30 | alta 30-40 | -----Muito alta----- 40-50 50-60 60-70 >70 | | | | | |
| Classes de solos | LV-I | arg. | 4,31 | 12,11 | 14,42 | 4,08 | 0,79 | 0,08 | 0,04 | 0,02 | 35,85 |
| | LV-II | m. arg. | 1,09 | 5,38 | 4,16 | 1,82 | 0,75 | 0,14 | 0,05 | 0,02 | 13,41 |
| | LVA-I | arg. | 0,71 | 3,60 | 2,51 | 0,69 | 0,24 | 0,06 | 0,03 | | 7,84 |
| | LVA-II | m. arg. | 0,18 | 5,08 | 3,79 | 0,46 | | 0,18 | 0,10 | | 9,79 |
| | FF-I | arg. | 0,64 | 6,15 | 2,34 | 0,45 | 0,13 | 0,03 | 0,02 | | 9,76 |
| | FF-II | m. arg. | 0,58 | 6,23 | 3,29 | 0,19 | | | | | 10,29 |
| | FX | m. arg. | 0,24 | 1,32 | 0,86 | 0,28 | | | | | 2,70 |
| | CX | arg. | 0,14 | 0,83 | 0,93 | 0,05 | | | | | 1,95 |
| | RR | m. arg. | 0,45 | 2,95 | 1,63 | 1,59 | 0,30 | | 0,02 | | 6,94 |
| | RQ | aren. | 0,02 | 0,07 | 0,04 | | | | | | 0,13 |
| | PV | m. arg. | 0,00 | 0,12 | 0,35 | 0,02 | 0,01 | | | | 0,50 |
| | PVA | m. arg. | 0,00 | 0,11 | 0,37 | 0,00 | | | | | 0,48 |
| | NV | m. arg. | 0,01 | 0,09 | 0,26 | 0,00 | | | | | 0,36 |
| Subtotal IRUS Área (%) | | | 8,37 | 44,04 | 34,95 | 9,63 | 2,22 | 0,49 | 0,26 | 0,04 | 100,00 |

Text. = Textura do solo; arg. = argilosa; m.arg. = muito argilosa; aren.= arenosa; LV = Latossolo Vermelho; LVA = Latossolo Vermelho-Amarelo; FF = Plintossolo Pétrico; FX = Plintossolo Háplico; CX = Cambissolo Háplico; RR = Neossolo Regolítico; RQ = Neossolo Quartzarênico; PV = Argissolo Vermelho; PVA = Argissolo Vermelho-Amarelo; e NV = Nitossolo Vermelho. MDS = Mapa Digital de Solos; IRUS = Índice Relativo de Umidade do Solo

6.4. CONCLUSÕES

A metodologia aplicada neste trabalho possibilitou a análise quantitativa e qualitativa dos mapas de variação da umidade superficial dos solos sobre o mapa de classes pedológicas, ambos obtidos por técnicas de geoprocessamento de dados provenientes de sensoriamento remoto e ambientais.

Quanto ao cruzamento dos dados, 35% dos Latossolos apresentaram variação moderada, contudo, 10% dessas classes de solos se sobrepuseram às categorias de variação alta a muito alta. Os padrões geométricos relacionados com as atividades antrópicas como agricultura irrigada a leste do DF foram destacados e indicaram alta variabilidade na umidade do solo ao longo da série temporal. Esse fato implica na necessidade de um estudo orientado ao objeto para áreas mais homogêneas quanto ao uso e ocupação e características ambientais.

A maioria das áreas onde a umidade apresentou menores variações coincidiram com as classes de solos reconhecidamente com maior capacidade de manutenção da umidade por maiores períodos, tais como Plintossolos Háplicos e Pétricos. Do mesmo modo, solos com textura arenosa exibiram baixos índices de variação da umidade, enquanto, em classes de solos com capacidade de retenção de água intermediária como os Latossolos, houve maior índice de variação.

Em relação aos resultados, constatou-se a dependência da umidade do solo sobre as características diferenciais de cada classe, que apoiam a validade da metodologia utilizada. Diante disso, a inserção de outras variáveis como microrrugosidade e uso de algoritmos baseados em aprendizado de máquina podem contribuir para a minimização dos erros de predição. Um monitoramento contínuo da umidade do solo auxilia na mitigação de crises hídricas, pois configura um indicativo de áreas de menor ou maior variação da umidade.

CAPÍTULO 7

CONSIDERAÇÕES FINAIS

A técnica de modelagem multiespectral de *endmembers* de solos sobre série temporal de sensores remotos orbitais computada em nuvem comprovou potencial para o mapeamento digital de solos, inclusive de outros alvos como vegetação e água. Cerca de 64% da área (3.667 km²) do Distrito Federal foram mapeados, dos quais aproximadamente 75% das áreas foram modeladas como Latossolos. Em regiões de relevo movimentado, ocorreram os maiores percentuais de raiz quadrada do erro médio e foram categorizadas majoritariamente como Plintossolos Pétricos. Porém os trabalhos de campo demonstraram que essa classe ocorre associadas a Neossolos Regolíticos, Cambissolos, Latossolos Vermelhos e Vermelhos-Amarelos, entre outras.

Atualmente, os maiores entraves do método consistem na ausência de informações espectrais em áreas com cobertura permanente como florestas densas. Áreas antropizadas com agricultura consolidada apresentam modificações na reflectância à medida em que práticas de movimentação dos solos são executadas. Em áreas irrigadas, os processos de uniformização das variações de umidade dos solos ainda são limitados e induzem a erros nos modelos.

Quanto às modelagens da umidade dos solos por meio de dados de radar de abertura sintética e covariáveis ambientais, as médias de umidade variaram entre 11,97%, em épocas de estiagem, e 25,27%, em períodos chuvosos. Os dados preditos com o método de aprendizado de máquina pelo algoritmo *Random Forest* alcançaram forte correlação (r^2 máximo = 95%) com os dados medidos em campo na série temporal sob análise.

A utilização das covariáveis que mais influenciam a umidade do solo, como o retroespalhamento nas polarizações disponíveis, o índice de vegetação e os

componentes topográficos e pedológicos melhoraram o desempenho dos modelos, principalmente nas estimativas realizadas via *Random Forest*. Contudo, a maioria dos atributos dos solos não foram estatisticamente correlacionáveis com a umidade do solo medida devido a transformação dos dados nas análises de correlação, o que impediu a utilização desse tipo de informação nos modelos. Além disso, a utilização de índices de vegetação, fator de reflectância, temperatura de superfície, entre outras, também podem contornar tais limitações.

No que se refere ao mapa de variação da umidade do solo gerado no Capítulo 6, houve correspondência com o mapa digital de solos elaborado no Capítulo 4. Os materiais cartográficos produzidos nesta tese alcançam uma escala máxima de 1:100.000. Os resultados e discussão levantados representam fontes de referência para atividades que visem a exploração sustentável dos solos e da água, a ser empregados em vários outros estudos no Distrito Federal, bem como, em outras partes do mundo, por meio da aplicação da metodologia em projetos de pesquisa e extensão dedicados ao direcionamento de ações de conservação ou exploração sustentável de solos e recursos hídricos, por exemplo.

As informações desta tese estão disponíveis para órgãos públicos e privados, bem como para a comunidade acadêmica e interessados por meio da publicação dos resultados em forma de artigos científicos em periódicos, repositórios online e no banco de dados Geoped da Faculdade de Agronomia e Veterinária da Universidade de Brasília. Dessa forma, dados espaço-temporais da umidade do solo e das classes pedológicas tem implicações em nível de política econômica, social e ambiental. Pois auxiliam nas tomadas de decisões, por exemplo, projetos relacionados à programação de irrigação, agricultura, monitoramento de seca e é altamente útil ao monitoramento ambiental por parte de pesquisadores, extensionistas e gestores de recursos naturais.

REFERÊNCIAS

- AGRAWAL, S.; GUPTA, R. D. Web GIS and its architecture: a review. **Arabian Journal of Geosciences**. 10, 518. 2017. <https://doi.org/10.1007/s12517-017-3296-2>
- ALEXAKIS, D. D.; MEXIS, F.D. K.; VOZINAKI, A. E. K.; DALIAKOPOULOS, I. N.; TSANIS, I. K. Soil moisture content estimation based on Sentinel-1 and auxiliary Earth observation products. A hydrological approach. **Sensors**. 2017, 17, 1455. <https://doi.org/10.3390/s17061455>
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. M.; SPAROVEK, G., Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, 711–728. 2013. <https://doi.org/10.1127/0941-2948/2013/0507>
- ALVES, M. R.; DEMATTÊ, J.A. M.; BARROS, P. P. S. Multiple geotechnological tools applied to digital mapping of tropical soils. **Revista Brasileira de Ciências do Solo**, 39:1261-1274, 2015. <https://doi.org/10.1590/01000683rbcscs20140410>.
- ANALYTICAL SPECTRAL DEVICE INC. **ASD Fieldspec® 4: The industry-leading portable device for field spectroscopy**. [on-line]. 2019. https://www.malvernpanalytical.com/en/assets/ASD%20FieldSpec%204%20Product%20Brochure_tcm50-61709.pdf.
- BAGHDADI, N.; AUBERT, M.; ZRIBI, M. Use of TerraSAR-X data to retrieve soil moisture over bare soil agricultural fields. **IEEE Geoscience and Remote Sensing Letters**, v. 9, n. 3, p. 512–516. 2012. doi:10.1109/lgrs.2011.2173155
- BAPTISTA, G. M. M.; MADEIRA NETO, J. S.; SOUZA, D. T. M. Reflectância dos solos. In: MENESES, P. R.; ALMEIDA, T.; BAPTISTA, G. M. M. **Reflectância dos materiais terrestres: análise e interpretação**. Oficinas de Textos. 2019. p. 163–188.
- BAPTISTA, G. M. M.; CORRÊA, R. S.; SANTOS, P. F. Campos de murundus da Fazenda Água Limpa da UnB: hipóteses de origem. **Revista do Ceam**, v. 2, p. 47-60, 2013. <https://periodicos.unb.br/index.php/revistadoceam/article/view/10076>
- BAPTISTA, G. M. M.; TEOBALDO, D. WorldView-2 sensor for the detection of hematite and goethite in tropical soils. **Pesquisa Agropecuária Brasileira**, v. 52, n. 12, p. 1192-1202. 2017. <https://doi.org/10.1590/s0100-204x2017001200008>
- BAUER-MARSCHALLINGER, B.; FREEMAN, V.; CAO, S.; PAULIK, C. ; SCHAUFLE, S.; STACHL, T.; MODANESI, S.; MASSARI, C.; CIABATTA, L.; BROCCA, L.; WAGNER, W. Toward global soil moisture monitoring with Sentinel-1: Harnessing assets and overcoming obstacles. **IEEE Transactions on Geoscience and Remote Sensing**. v. 1, n. 20. 2019. DOI 10.1109/TGRS.2018.2858004
- BENNINGA, HARM-JAN F.; VAN DER VELDE, R.; SU, Z. Sentinel-1 soil moisture content and its uncertainty over sparsely vegetated fields. **Journal of Hydrology**, v. X, n. 9, 2020, DOI: 10.1016/j.hydroa.2020.100066
- BEVEN; K. J.; KIRKBY; M. J. A physically based, variable contributing area model of basin hydrology / Un modèle à base physique de zone d'appel variable de l'hydrologie

du bassin versant, **Hydrological Sciences Journal**, 24:1, 43-69. 1979. DOI: 10.1080/02626667909491834

BOUYOUCOS, G. J. A recalibration of the hydrometer method for making mechanical analysis of soil. **American Society of Agriculture Journal**. 1951. 43: 434-438. <https://doi.org/10.2134/agronj1951.00021962004300090005x>

BRASIL. **Decreto Nº 9.414, de 19 de junho de 2018**. Institui o Programa Nacional de Levantamento e Interpretação de Solos do Brasil. Embrapa. 2018.

BRASIL. **Projeto RADAMBRASIL**. Ministério das Minas e Energia. Departamento Nacional de Produção Mineral. Rio de Janeiro, 764 p (Levantamento de Recursos Naturais, v.1-34), p. 1973-1986. Disponível em: <<http://www.cprm.gov.br/publique/Geologia/Sensoriamento-Remoto-e-Geofisica/RADAM-D-628.html>>

BRAUN, A. Retrieval of digital elevation models from Sentinel-1 radar data – open applications, techniques, and limitations. **Open Geosciences**, 13(1), 532-569. 2021. <https://doi.org/10.1515/geo-2020-0246>

BREIMAN, L. Random Forests. **Machine Learning**. 45, 5–32. 2001. <https://doi.org/10.1023/A:1010933404324>

BREVIK, E. C.; BURGESS, L. C. The influence of soils on human health. **Nature Education Knowledge**. 5(12):1. 2014. <https://doi.org/10.1023/A:1010933404324>

BROCCA, L.; MORBIDELLI, R.; MELONE, F.; MORAMARCO, T. Soil moisture spatial variability in experimental areas of central Italy. **Journal of Hydrology**. v. 333, p. 356–373. 2007.

CAMPOS, J. E. G.; GASPAR, M. T. P.; GONÇALVES T. D. **Gestão de Recursos Hídricos Subterrâneos no Distrito Federal: Diretrizes, Legislação, Critérios Técnicos, Sistema de Informação Geográfica e Operacionalização**. Relatório de Consultoria Técnica. BNWPP, IBRD, ADASA. 2007. 158 p.

CAMPOS, J. E. G. Meio Físico do Distrito Federal. In: Distrito Federal. **Zoneamento Ecológico-Econômico do Distrito Federal**. 2011. Disponível em: <<http://www.zee-df.com.br/produtos.html>>. Acesso em: jun. 2020.

CARVALHO JÚNIOR, W.; CHAGAS, C. S.; MUSELLI, A.; PINHEIRO, H. S. K.; PEREIRA, N. R.; BHERING, S. B. Conditioned latin hypercube method for soil sampling in the presence of environmental covariates for digital soil mapping. **Revista Brasileira de Ciências do Solo**. 2014, vol. 38, n. 2, pp. 386-396. <http://dx.doi.org/10.1590/S0100-06832014000200003>

CARVALHO, A. M.; MARCHÃO, R. L.; SOUZA, K. W.; BUSTAMANTE, M. M. C. Soil fertility status, carbon and nitrogen stocks under cover crops and tillage regimes. **Revista Ciência Agrônômica**, v. 45, n. 5, p. 914–921. 2014. doi:10.1590/s1806-66902014000500007

CHABRILLAT, S.; BEN-DOR, E., CIERNIEWSKI, J.; GOMEZ, C.; SCHMID, T.; VAN WESEMAEL, B. Imaging spectroscopy for soil mapping and monitoring. **Surveing and Geophysics**. v. 40, p. 361–399. 2019. <https://doi.org/10.1007/s10712-019-09524-0>

CLINE, M. G. Historical highlights in soil genesis, morphology, and classification. **Soil Science Society of America Journal**, 41(2), 250. 1977. <http://dx.doi.org/10.2136/sssaj1977.03615995004100020018>

CLINE, M. G.; BUOL, S. W. Soils of the central plateau of Brazil and extension of results of field research conducted near Planaltina, Federal District, to them. Ithaca1973. 43 p.

CLINE, M.G. The changing model of soil. **Soil Science Society American Proc.** 25:442–446. 1961. <http://dx.doi.org/10.2136/sssaj1961.03615995002500060009x>

COBLINSKI, J. A.; GIASSON, É.; DEMATTÊ, J. A. M.; DOTTO, A. C.; COSTA, J. J. F.; VAŠÁT, R., Prediction of soil texture classes through different wavelength regions of reflectance spectroscopy at various soil depths. **Catena**, 189, 104485. 2020. <https://doi.org/10.1016/j.catena.2020.104485>

CODEPLAN – Companhia de Planejamento do Distrito Federal. **Atlas do Distrito Federal**. Secretaria de Estado de Planejamento, Orçamento e Gestão do Distrito Federal – SEPLAG. Brasília. DF. Vol. 2. 2020a. <http://www.codeplan.df.gov.br/atlas-do-distrito-federal-2020/>

CODEPLAN – Companhia de Planejamento do Distrito Federal. **Cartas Planialtimétricas em Formato Vetorial, na escala 1:25.000 e 10.000, Sistema Cartográfico do Distrito Federal - SICAD, com informações sobre sistema viário, hidrografia, hipsometria e áreas urbanas – CD-ROM**. Brasília, DF: CODEPLAN, 1991.

CODEPLAN – Companhia de Planejamento do Distrito Federal. **Estudo: Um Panorama das Águas no Distrito Federal**. Secretaria de Estado de Economia do Distrito Federal. Brasília. DF. 2020b. <http://www.codeplan.df.gov.br/wp-content/uploads/2020/07/Estudo-Um-Panorama-das-%C3%81guas-no-Distrito-Federal.pdf>

CONGALTON, R. G.; GREEN, K. Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. **New York: Taylor & Francis Group**, v. 25, 2010. http://doi.wiley.com/10.1111/j.1477-9730.2010.00574_2.x

CONRAD, O.; BECHTEL, B.; BOCK, M.; DIETRICH, H.; FISCHER, E.; GERLITZ, L.; WEHBERG, J.; WICHMANN, V.; BÖHNER, J. System for Automated Geoscientific Analyses (SAGA) v. 2.1.4, **Geosciences Model Development**, 8, 1991–2007, <https://doi.org/10.5194/gmd-8-1991-2015>, 2015.

CRABBÉ, A. H.; JAKIMOW, B.; SOMERS, B.; ROBERTS, D. A.; HALLIGAN, K.; DENNISON, P.; DUDLEY, K. **Viper Tools Software (Version 3) [Software]**. 2019. Disponível em: <https://bitbucket.org/kul-reseco/viper>. Acesso em 22 de abril de 2020.

CUNHA, A. P. M. A.; BRITO, S. S. B.; RIBEIRO NETO, G. G.; ALVALÁ, R. C. S. As secas entre 1963 e 2017 no Distrito Federal, Brasil. **Anuário do Instituto de Geociências – UFRJ**. v. 41, n. 2. 2018. DOI: 10.11137/2018_2_487_498.

- DATTA, S.; TAGHVAEIAN, S.; OCHSNER, T.; MORIASI, D.; GOWDA, P.; STEINER, J. Performance assessment of five different soil moisture sensors under irrigated field conditions in Oklahoma. **Sensors**, v. 18, n. 11, p. 3786. 2018. doi:10.3390/s18113786
- DEMATTÊ, J. A. M.; ALVES, M. R.; TERRA, F. S.; BOSQUILIA, R. W. D.; FONGARO, C. T.; BARROS, P. P. S. Is it possible to classify topsoil texture using a sensor located 800 km away from the surface? **Revista Brasileira Ciência do Solo**, 40. 2016. <http://dx.doi.org/10.1590/18069657rbc20150335>.
- DEMATTÊ, J. A. M.; BELLINASSO, H.; ROMERO, D. J.; FONGARO, C. T. Morphological Interpretation of Reflectance Spectrum (MIRS) using libraries looking towards soil classification. **Scientia Agricola**, v. 71, n. 6, p. 509-520, 2014. <https://doi.org/10.1590/0103-9016-2013-0365>
- DEMATTÊ, J. A. M.; DOTTO, A. C.; PAIVA, A. F. S.; SATO, M. V.; DALMOLIN, R. S. D.; ARAÚJO, M. S. B. ... COUTO, H. T. Z. The Brazilian Soil Spectral Library (BSSL): A general view, application and challenges. **Geoderma**, v. 354, p. 113793, 2019.
- DEMATTÊ, J. A. M.; FONGARO, C. T.; RIZZO, R.; SAFANELLI, J. L. Geospatial Soil Sensing System (GEOS3): A powerful data mining procedure to retrieve soil spectral reflectance from satellite images. **Remote Sensing of Environment**. n. 212, p. 161–175. 2018. <https://doi.org/10.1016/j.rse.2018.04.047>
- DEMATTÊ, J. A. M.; RAMIREZ-LOPEZ, L.; RIZZO, R.; NANNI, M.; FIORIO, P.; FONGARO, C.; MEDEIROS NETO, L.; SAFANELLI, J.; BARROS, P. Remote sensing from ground to space platforms associated with terrain attributes as a hybrid strategy on the development of a pedological map. **Remote Sensing**, v. 8, n. 10, p. 826, 2016.
- DEMATTÊ, J. A. M.; SAFANELLI, J. L.; POPPIEL, R. R.; RIZZO, R.; SILVERO, N. E. Q.; MENDES, W. S.; ... LISBOA, C. J. S. Bare Earth's surface spectra as a proxy for soil resource monitoring. **Scientific Reports**, v. 10, n. 1. 2020. <https://doi.org/10.1038/s41598-020-61408->
- DIEK, S., SCHAEPMAN, M., DE JONG, R. Creating multi-temporal composites of airborne imaging spectroscopy data in support of digital soil mapping. **Remote Sensing**. v. 8, n. 906. 2016. <http://dx.doi.org/10.3390/rs8110906>.
- DOBSON, M. C.; ULABY, F. T. Active microwave soil moisture research, **IEEE Transactions on Geosciences and Remote Sensing**, vol. GE-24, no. 1, p. 23-35, 1986. DOI: 10.1109/TGRS.1986.289585
- DOKUCHAEV, V. V. Russian Chernozem – Volume I. In: **Selected Works of V. V. Dokuchaev** - Traduzido por N. Kaner. Jerusalem: Israel Program for Scientific Translations, 1967. 439 p.
- DOKUCHAEV, V. V. Short storical description and critical analysis of the more important soils classification. **Trav. Soc. Nat.** Saint Petersburg, 10: 64-67 1879.
- DOTTO, A. C.; DALMOLIN, R. S. D.; TEN CATEN, A.; GRUNWALD, S. A systematic study on the application of scatter-corrective and spectral-derivative preprocessing for multivariate prediction of soil organic carbon by Vis-NIR spectra. **Geoderma**, v. 314, p. 262–274, 2018.

DOUVILLE, H.; RAGHAVAN, K.; RENWICK, J.; ALLAN, R. P.; ARIAS, P. A.; BARLOW, M.; CERESO-MOTA, R.; CHERCHI, A.; GAN, T. Y.; GERGIS, J.; JIANG, D.; KHAN, A.; POKAM MBA, W.; ROSENFELD, D.; TIERNEY, J.; ZOLINA, O. Water Cycle Changes Supplementary Material.. *In: Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*, Cambridge University Press. 2021 3949 p. Disponível em: <https://www.ipcc.ch/report/ar6/wg1/> Acesso em 8 de setembro de 2021.

DUBOIS, P. C.; VAN ZYL, J.; ENGMAN, T. Measuring soil moisture with imaging radars. *IEEE Transactions on Geoscience and Remote Sensing*, v. 33, n. 4, 915–926 1995.

EL HAJJ, M.; BAGHDADI, N.; ZRIBI, M.; BELAUD, G.; CHEVIRON, B.; COURAULT, D.; CHARRON, F., Soil moisture retrieval over irrigated grassland using X3 band SAR data. *Remote Sensing of Environment*, v. 176, p. 202-218. 2016., doi:10.1016/j.rse.2016.01.027.

EMATER-DF – Empresa de Assistência Técnica e Extensão Rural do Distrito Federal. **Informações Agropecuárias do Distrito Federal - 2020**. Brasília. DF. 2020. Disponível em: www.emater.df.gov.br/informacoes-agropecuarias-do-distrito-federal. Acesso: 22 jan. 2021.

EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária. **Sistema de Informação de Solos Brasileiros**. Embrapa Solos, RJ. 2014. https://www.bdsolos.cnptia.embrapa.br/consulta_publica.html

ESA - European Spatial Agency. **SENTINEL Technical Guide**. 2021. Disponível em: <https://sentinel.esa.int/web/sentinel/sentinel-technical-guides>. Acesso maio de 2020.

ESA - European Spatial Agency. **Sentinel-1: ESA's Radar Observatory Mission for GMES Operational Services**. ESA SP-1322/1. 2012a. Disponível em: https://sentinel.esa.int/documents/247904/349449/S1_SP-1322_1.pdf. jul 2020.

ESA - European Spatial Agency. **Sentinel-2: ESA's Radar Observatory Mission for GMES Operational Services**. ESA SP-1322/2. 2012b. Disponível em: https://sentinels.copernicus.eu/documents/247904/349490/S2_SP-1322_2.pdf. Acesso em 21 de dezembro de 2020.

ESPINDOLA, C. R. Histórico das pesquisas sobre solos até meados do século XX, com ênfase no Brasil. *Revista do Instituto Geológico*, v. 39 n. 2, 2018. <https://doi.org/10.5935/0100-929X.20180007>

ESRI. **ArcGIS® Desktop 10.7: ArcMap™ Functionality Matrix**. 2019. <https://www.esri.com/content/dam/esrisites/en-us/media/pdf/product/desktop/arcgis-10.7-desktop-arcmap-functionality-matrix.pdf>

FINK, J. R.; INDA, A. V.; BAYER, C.; TORRENT, J.; BARRÓN, V. Mineralogy and phosphorus adsorption in soils of south and central-west Brazil under conventional and no-tillage systems. *Acta Scientiarum, Agronomy*. v. 36, n. 3, p. 379-387, 2014. <https://doi.org/10.4025/actasciagron.v36i3.17937>.

FONGARO, C. T.; DEMATTÊ, J. A. M.; RIZZO, R.; SAFANELLI, J. L.; MENDES, W. D. S.; DOTTO, A. C.; VICENTE, L. E.; FRANCESCHINI, M. H. D.; USTIN, S. L. Improvement of clay and sand quantification based on a novel approach with a focus on multispectral satellite images. **Remote Sensing**. 10, 1555. 2018. <https://doi.org/10.3390/rs10101555>

FREITAS, F. G.; GOMES, I. A.; FERREIRA, R. C.; ANTONELLO, L. L. **Levantamento de reconhecimento dos solos do Distrito Federal**, Embrapa - Serviço Nacional de Levantamento e Classificação de Solos, Rio de Janeiro. 1978. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/62764/1/CNPS-BOL.-TEC.-53-78.pdf> Acessado em: 30 de outubro de 2019.

FREITAS-SILVA, F. H.; CAMPOS, J. E. G. Geologia do Distrito Federal. In: SEMARH. **Inventário hidrogeológico e dos recursos hídricos superficiais do Distrito Federal**. Parte I. IEMASEMATEC/Universidade de Brasília. 1998. 86 p.

GALLO, B.; DEMATTÊ, J.; RIZZO, R.; SAFANELLI, J.; MENDES, W.; LEPSCH, I.; LACERDA, M. Multi-temporal satellite images on topsoil attribute quantification and the relationship with soil classes and geology. **Remote Sensing**, v. 10, n. 10, p. 1571. 2018. doi:10.3390/rs10101571

GAO, Q.; ZRIBI, M.; ESCORIHUELA, M.J.; BAGHDADI, N. Synergetic use of Sentinel-1 and Sentinel-2 data for soil moisture mapping at 100 m resolution. **Sensors**. v. 17, p. 1966, 2017. <https://doi.org/10.3390/s17091966>

GARCÍA, G.; BROGIONI, M.; VENTURINI, V.; RODRIGUEZ, L.; FONTANELLI, G.; WALKER, E.; GRACIANI, S.; MACELLONI, G. Determinación de la humedad de suelo mediante regresión lineal múltiple con datos TerraSAR-X. **Revista de Teledetección**. v. 46, p. 73-81. 2016. <https://doi.org/10.4995/raet.2016.4024>

GENÚ, A. M.; ROBERTS, D.; DEMATTÊ, J. A. M. The use of multiple endmember spectral mixture analysis (MESMA) for the mapping of soil attributes using ASTER imagery. **Acta Scientiarum - Agronomy**. 2013. <https://doi.org/10.4025/actasciagron.v35i3.16119>

GOMES, L.; SIMÕES, S. J. C.; DALLA NORA, E. L.; SOUSA-NETO, E. R.; FORTI, M. C.; OMETTO, J. P. H. B. Agricultural expansion in the Brazilian Cerrado: Increased soil and nutrient losses and decreased agricultural productivity. **Land**, v. 8, p. 12. 2019. <https://doi.org/10.3390/land8010012>

GOOGLE INC. Google Earth Engine: **A planetary-scale platform for Earth science data & analysis**. Limited liability company. United States. 2021. Disponível em: <https://earthengine.google.com/> Acesso em 20 de jan. de 2021.

GUTIÉRREZ, N. L.; SANABRIA, Y. R.; QUIÑONES, A. J. P. Evaluation of soil moisture using topographic (DEM), climate and soil parameters in a piedmont area of Villavicencio. **Revista EIA**, 61-75. 2015.

HACHANI, A.; OUESSAR, M.; PALOSCIA, S.; SANTI, E.; PETTINATO, S. Soil moisture retrieval from Sentinel-1 acquisitions in an arid environment in Tunisia: application of Artificial Neural Networks techniques. **International Journal of Remote Sensing**, 2019: DOI: 10.1080/01431161.2019.1629503

HARPER, D. Online Etymology Dictionary©. SOIL. 2001-2021 disponível em: <<https://www.etymonline.com/search?q=soil> > Acesso em: 22 de março de 2021.

HARRIS GEOSPATIAL SOLUTIONS, INC. **ENVI Tutorials**. L3HARRIS GEOSPATIAL. 2020. Disponível em: <https://www.l3harrisgeospatial.com/Support/Self-Help-Tools/Tutorials> Acesso em 22 de julho de 2021.

HENGL, T.; NUSSBAUM, M.; WRIGHT, M. N.; HEUVELINK, G. B. M.; GRÄLER, B. Random forest as a generic framework for predictive modeling of spatial and spatio-temporal variables. **Peer Journal**. V. 6:e5518. 2018. <https://doi.org/10.7717/peerj.5518>

HENGL, T.; MACMILLAN, R. A. **Predictive Soil Mapping with R**. OpenGeo Hub foundation, Wageningen, the Netherlands, 2019. 370 p. ISBN: 978-0-359-30635-0. Disponível em: www.soilmapper.org, Acessado em: 20 de março de 2020.

HILLEL, D. **Introduction to soil physics**. San Diego: Academic Press, 1982. 264p.

HOU, D.; BOLAN, N. S.; TSANG, D. C. W.; KIRKHAM, M. B.; O'CONNOR, D. Sustainable soil use and management: An interdisciplinary and systematic approach. **Science of the Total Environment**, 138961. 2020. doi:10.1016/j.scitotenv.2020.138961

HOUAISS, A.; VILLAR, M. S. Dicionário Houaiss da língua portuguesa. Rio de Janeiro: Objetiva, 2009.

HUNKE, P.; MUELLER, E. N.; SCHRÖDER, B.; ZEILHOFER, P. The Brazilian Cerrado: assessment of water and soil degradation in catchments under intensive agricultural use. **Ecohydrology**, v. 8, n. 6, p. 1154–1180. 2014. doi:10.1002/eco.1573

HUNT, G. R.; SALISBURY, J. W. Visible and near infrared spectra of minerals and rocks: I. Silicate minerals. **Modern Geology**, v. 1, p. 283–300, 1970.

IBGE – Instituto Brasileiro de Geografia e Estatística. **IBGE Cidades@: Brasília – DF**. 2017. Disponível em: <https://cidades.ibge.gov.br/brasil/df/> Acesso: 29 jan. 2021.

INMET – Instituto Nacional de Meteorologia. **Banco de Dados Meteorológicos para Ensino e Pesquisa – BDMEP**. Brasília, DF, Brasil. Disponível em: <http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>. Acesso: abril de 2020.

IUSS WORKING GROUP WRB, **World reference base for soil resources 2014 International soil classification system, World Soil Resources Reports No. 106**. FAO, 2015. <https://doi.org/10.1017/S0014479706394902>

JACOME, A.; BERNIER, M.; CHOKMANI, K.; GAUTHIER, Y.; POULIN, J.; DE SÈVE, D. Monitoring volumetric surface soil moisture content at the La Grande Basin Boreal Wetland by radar multi polarization data. **Remote Sensing**, 5(10), 4919–4941. 2013. <http://doi.org/10.3390/rs5104919>

JENNY, H. **Factors of soil formation: a system of quantitative pedology**. New York: Dover Publications, 1941. 320 p. Disponível em: < <http://www.msu.ac.zw/lear>

ning/material/1235306390factors%20of%20soil%20formation%20reading%20material%20very%20critical.pdf >. Acesso em 23 de março de 2020.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**. Tradução português 2 Ed. São José dos Campos, SP: Parentese. 2009. 598 p.

KÄMPF, N.; CURI, N. Formação e Evolução dos solos (PEDOGÊNESE). In: KER, J. C.; CURI, N.; SCHAEFER, C. E.; TORRADO, P. V. (Org.). **Pedologia: Fundamentos**. 1. ed. Viçosa, MG: SBCS. 2012. p. 208-291.

KING, L. C. Geomorfologia do Brasil Oriental. **Revista Brasileira de Geografia**, 18: 147-265. 1956. Disponível em: http://biblioteca.ibge.gov.br/visualizacao/periodicos/115/rbg_1956_v18_n2.pdf. Acesso em: 03 de abril de 2019.

KÖPPEN, W. Klassifikation der Klimate nach Temperatur, Niederschlag und Jahresablauf (Classification of climates according to temperature, precipitation and seasonal cycle). **Petermanns geographische Mitteilungen**, v. 64, p. 193–203, 1918.

KUHN, T. S. **The structure of scientific revolutions**. Third edicion. The University of Chicago Press, Chicago. 1996. ISBN: 0-226-45808-3.

LACERDA, M. P. C.; BARBOSA, I. O. Relações pedomorfogeológicas e distribuição de pedoformas na Estação Ecológica de Águas Emendadas, Distrito Federal. **Revista Brasileira de Ciência do Solo**, v. 36, n. 3, p. 709–721. 2012. <https://doi.org/10.1590/S0100-06832012000300003>.

LACERDA, M. P. C.; DEMATTÊ, J. A. M.; SATO, M. V.; FONGARO, C. T.; GALLO, B. C.; SOUZA, A. B. Tropical texture determination by proximal sensing using a regional spectral library and its relationship with soil classification. **Remote Sensing**. v. 8, n. 701, 2016. <https://doi.org/10.3390/rs8090701>.

LAW, D. **Portal for ArcGIS 101. Managing GIS**. 2014. <https://www.esri.com/about/newsroom/arcuser/portal-for-arcgis-101/>

LEÃO, T. P.; COSTA, B. F. D.; BUFON, V. B.; ARAGÓN, F. F. H. Using time domain reflectometry to estimate water content of three soil orders under savanna in Brazil. **Geoderma Regional**. v. 2, n. e00280, 2020. <https://doi.org/10.1016/j.geodrs.2020.e00280>

LIBARDI, P. L.; MOTA, J. C. A.; ASSIS JÚNIOR, R. N.; BRITO, A. S.; AMARO FILHO, J. Water balance components in covered and uncovered soil growing irrigated muskmelon. **Revista Brasileira de Ciência do Solo**, v. 39, n. 5, p. 1322-1334. 2015. <https://dx.doi.org/10.1590/01000683rbc20140713>

LIMA, L. A. S.; REATTO, A.; ROIG, H. L. Soil mapping of a small watershed in a Brazilian savanna biome: A semi-automatic approach. **Journal of Geographic Information System**, 6, 79-87. 2014. <http://dx.doi.org/10.4236/jgis.2014.62009>

LIU, J.; XIE, J.; HAN, J.; WANG, H.; SUN, J.; LI, R.; LI, S. Visible and near-infrared spectroscopy with chemometrics are able to predict soil physical and chemical

properties. **Journal of Soils Sediments**. 2020. <https://doi.org/10.1007/s11368-020-02623-1>.

LOBELL, D. B.; ASNER, G. P. Moisture effects on soil reflectance. **Soil Science Society of America Journal**, v. 66, p. 722–727, 2002.

LOPES RIBEIRO, F.; GUEVARA, M.; VÁZQUEZ-LULE, A.; CUNHA, A. P.; ZERI, M.; VARGAS, R. The impact of drought on soil moisture trends across Brazilian biomes, **Natural Hazards Earth System Science**, 21, 879–892, 2021. <https://doi.org/10.5194/nhess-21-879-2021>,

LOURENÇO, V. R.; TEIXEIRA, D. B. S.; COSTA, C. A. G.; TANIGUCHI, C. A. K. Soil classes separation applying Principal Component Analysis (PCA). **Journal of Hyperspectral Remote Sensing**. v. 10, p. 130-137. 2020.

MA, Y. X.; MINASNY, B.; MALONE, B. P.; MCBRATNEY, A. B. Pedology and digital soil mapping (DSM). **European Journal of Soil Science**. 70, 216–235. 2019. <https://doi.org/10.1111/ejss.12790>

MARTINS, E. S.; BAPTISTA, G. M. M. Compartimentação geomorfológica e sistemas morfodinâmicos do Distrito Federal. *In*: CAMPOS, J. E. G. & FREITAS-SILVA, F. H. (coords). **Inventário hidrogeológico e dos recursos hídricos superficiais do Distrito Federal**. Brasília, SEMATEC: IEMA: MMA-SRH, 1998. CD ROM.

MARTINS, E. S.; REATTO, A.; CARVALHO Jr., O. A.; GUIMARÃES, R. F. **Evolução Geomorfológica do Distrito Federal**. Planaltina, DF: Embrapa Cerrados, 2004. 57 p. – Documentos/Embrapa Cerrados, n. 122.

McBRATNEY, A. B.; MENDONÇA-SANTOS, M. L.; MINASNY, B. On digital soil mapping. **Geoderma**, v. 117, p. 3-52, 2003. [https://doi.org/10.1016/S0016-7061\(03\)00223-4](https://doi.org/10.1016/S0016-7061(03)00223-4)

MENDES, W. S.; DEMATTÊ, J. A. M.; BARROS, A. S.; SALAZAR, D. F. U.; AMORIM, M. T. A. Geostatistics or machine learning for mapping soil attributes and agricultural practices. **Revista Ceres**. v. 67, n.4, p. 330-336. 2020.

MENDONÇA-SANTOS, M. L.; SANTOS, H. G. Chapter 3 The state of the art of Brazilian soil mapping and prospects for digital soil mapping. Digital Soil Mapping - An Introductory Perspective. *In*: LAGACHERIE, P.; McBRATNEY, A. B.; VOLTZ, M. (Eds.). **Developments in Soil Science**, vol. 31, 39–601. 2006. Disponível em: [https://doi.org/10.1016/s0166-2481\(06\)31003-3](https://doi.org/10.1016/s0166-2481(06)31003-3). Acesso em: 20 de maio de 2020.

MENESES, P. R.; ALMEIDA, T. Reflectância dos solos. *In*: MENESES, P. R.; ALMEIDA, T.; BAPTISTA, G. M. M. **Reflectância dos materiais terrestres: análise e interpretação**. Oficinas de Textos. 2019. p. 11–38.

MILLER, J. D. **Statistics for Data Science. Leverage the power of statistics for Data Analysis, Classification, Regression, Machine Learning, and Neural Networks**. Packt Publishing. Birmingham, UK. 2017. Disponível em: http://www.elfhs.ssru.ac.th/morakot_wo/file.php/1/9781788290678-STATISTICS_FOR_DATA_SCIENCE.pdf. Acessado em: 20 de fevereiro de 2021.

- MINASNY, B.; McBRATNEY, A. B. Digital soil mapping: A brief history and some lessons. **Geoderma**, 264, 301–311. 2016. doi:10.1016/j.geoderma.2015.07.017
- MOHANTY, B. P.; COSH, M. H.; LAKSHMI, V.; MONTZKA, C. Soil moisture remote sensing: State-of-the-science. **Vadose Zone Journal**, v. 16, n. 1. 2017 doi:10.2136/vzj2016.10.0105
- MUNSELL COLOR CO. **Munsell Soil Color Charts: with Genuine Munsell Color Chips**. Grand Rapids, MI: Munsell Color, 2015.
- NEVES, G.; SENA SOUZA, J. P.; VASCONCELOS, V.; MARTINS, E. S.; COUTO JÚNIOR, A. F. Dinâmica da cobertura da terra do Distrito Federal dentro de suas unidades geomorfológicas. **Sociedade & Natureza**, v. 29, n. 3, p. 383-396, 2018. <https://doi.org/10.14393/SN-v29n3-2017-2>
- NOVAES-PINTO, M. Superfícies de aplainamento do Distrito Federal. **Revista Brasileira de Geografia**, v. 49, p. 9–27, 1987.
- NOVAIS, J. J. **Mapeamento digital de solos da microbacia do Ribeirão Extrema, DF, a partir de imagens multitemporais ASTER e biblioteca espectral** (Dissertação de Mestrado em Agronomia). Brasília: Faculdade de Agronomia e Medicina Veterinária, Universidade de Brasília, 2017, 211 p.
- NOVAIS, J. J.; LACERDA, M. P. C. Uso de imagens Sentinel-2 no monitoramento ambiental do uso e ocupação das terras em uma microbacia no Brasil-Central. **Gaia Scientia**, v. 15, n. 1, 2021. <https://doi.org/10.22478/ufpb.1981-1268.2021v15n1.54515>.
- NOVAIS, J. J.; LACERDA, M. P. C.; SANO, E. E.; DEMATTÊ, J. A. M.; OLIVEIRA JÚNIOR, M. P. Digital soil mapping using multispectral modeling with Landsat time series cloud computing based. **Remote Sensing**, v. 13, p. 1181, 2021. <https://doi.org/10.3390/rs13061181>
- OLIVEIRA JÚNIOR, M. P. **Feições geomorfológicas e mapeamento digital de solos da porção leste do Distrito Federal** (Tese de Doutorado em Agronomia). Faculdade de Agronomia e Medicina Veterinária, Universidade de Brasília - Brasília, 2017; 165 p.
- PALOSCIA, S.; PETTINATO, S.; SANTI, E.; NOTARNICOLA, C.; PASOLLI, L.; REPPUCCI, A. Soil moisture mapping using Sentinel-1 images: Algorithm and preliminary validation. **Remote Sensing of Environment**, v. 134, p. 234–248. 2013. doi:10.1016/j.rse.2013.02.027
- PARIKH, S. J.; JAMES, B. R. Soil: The Foundation of Agriculture. **Nature Education Knowledge**. 3(10):2. 2012.
- PENTEADO, M. M. Tipos de concreções ferruginosas nos compartimentos geomorfológicos do Planalto de Brasília. **Notícias Geomorfologia**, 16:39-53, 1976.
- PÉREZ, D. V.; BREFIN, M. L. M.; POLIDORO, J. C. Solo, da origem da vida ao alicerce das civilizações: uso, manejo e gestão. **Pesquisa Agropecuária Brasileira**. 51(9), 2016. <https://doi.org/10.1590/s0100-204x201600090000i>

POLIDORO, J. C.; MENDONÇA-SANTOS, M. L.; LUMBRERAS, J. F.; COELHO, M. R.; CARVALHO FILHO, A.; MOTTA, P. E. F.; CARVALHO JÚNIOR, W.; DART, R. O. **Programa Nacional de Solos do Brasil (PronaSolos)**. Empresa Brasileira de Pesquisa Agropecuária. Embrapa Solos, Rio de Janeiro: 2016. 53 p183. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/156792/1/Doc-183-Programa-Nacional-de-Solos-do-Brasil.pdf> Acesso em: 20 de maio de 2020.

POPPIEL, R. R.; LACERDA, M. P. C.; DEMATTÊ, J. A. M.; OLIVEIRA, M. P.; GALLO, B. C.; SAFANELLI, J. L. Soil class map of the Rio Jardim watershed in Central Brazil at 30 meter spatial resolution based on proximal and remote sensed data and MESMA method. **Data in Brief**, 25, 104070. 2019a. doi:10.1016/j.dib.2019.104070

POPPIEL, R. R.; LACERDA, M. P. C.; DEMATTÊ, J. A. M.; OLIVEIRA, M. P.; GALLO, B. C.; SAFANELLI, J. L. Pedology and soil class mapping from proximal and remote sensed data. **Geoderma**. 2019b. <https://doi.org/10.1016/j.geoderma.2019.04.028>

POPPIEL, R. R.; LACERDA, M. P. C.; SAFANELLI, J. L.; RIZZO, R.; OLIVEIRA Jr., M. P.; NOVAIS, J. J.; DEMATTÊ, J. A. M. Mapping at 30 m resolution of soil attributes at multiple depths in midwest Brazil. **Remote Sensing**. 11, 2905. 2019c. <https://doi.org/10.3390/rs11242905>

PRADO, R. B.; FIDALGO, E. C. C.; MONTEIRO, J. M. G.; SCHULER, A. E.; VEZZANI, F. M.; GARCIA, J. R.; SIMÕES, M. Current overview and potential applications of the soil ecosystem services approach in Brazil. **Pesquisa Agropecuária Brasileira**, Brasília, v. 51, n. 9, p. 1021-1038, 2016. <https://doi.org/10.1590/s0100-204x2016000900002>

PRATOLA, C.; BARRETT, B.; GRUBER, A.; KIELY, G.; DWYER, E. Evaluation of a global soil moisture product from finer spatial resolution SAR data and ground measurements at Irish sites. **Remote Sensing**, v. 6, p. 8190–8219, 2014.

QGIS DEVELOPMENT TEAM. **QGIS Geographic Information System User Guide**. Open Source Geospatial Foundation Project. 2002. https://docs.qgis.org/3.16/en/docs/user_manual/

QIU, S.; LIN, Y.; SHANG, R.; ZHANG, J.; MA, L.; ZHU, Z. Making Landsat time series consistent: Evaluating and improving Landsat analysis ready data. **Remote Sensing**. 2019, 11(1), 51; <https://doi.org/10.3390/rs11010051>

R CORE TEAM. **Language and Environment for Statistical Computing**. R Foundation for Statistical Computing. 2019. Disponível em: <https://www.r-project.org/> Acesso em: Jun 2019.

REATTO, A.; CORREIA, J. R.; SPERA, S. T.; CHAGAS, C. S.; MARTINS, E. S.; ANDAHUR, J. P.; GODOY, M. J. S.; ASSAD, M. L. C. L. **Levantamento semi-detalhado dos solos da bacia do rio Jardim-DF, escala 1:50.000**. 58. Planaltina, DF: Embrapa Cerrados, 2000.

REATTO, A.; MARTINS, E. S.; FARIAS, M. F. R.; SILVA, A. V.; CARVALHO, O. A. J.; OLIVEIRA, R. C. J.; RODRIGUES, T. E.; SANTOS, P. L.; VALENTE, M. A. **Mapa pedológico digital - SIG atualizado do Distrito Federal escala 1:100.000 e uma síntese do texto explicativo**. Planaltina, DF: Embrapa Cerrados, 2004. Disponível

em: https://ainfo.cnptia.embrapa.br/digital/bitstream/CPAC-2009/26344/1/doc_120.pdf

REDDY, G. P. O. Geographic Information System: Principles and Applications. In: **Geospatial Technologies in Land Resources Mapping, Monitoring and Management**. Publisher: Springer, Switzerland. 2018. DOI:10.1007/978-3-319-78711-4

RIBEIRO, J. F.; WALTER, B. M. T. As Principais Fitofisionomias do Bioma Cerrado. In: SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F. (Ed.). **Cerrado: ecologia e flora** v. 2. Brasília: EMBRAPA-CERRADOS, 2008. 876 p.

RILEY, S. J.; GLORIA, S. D.; ELLIOT, R. A terrain ruggedness index that quantifies topographic heterogeneity. **Intermountain Journal of Sciences**, vol. 5, No. 1-4, 1999.

RIZZO, R.; DEMATTÊ, J. A. M.; LEPSCH, I. F.; GALLO, B. C.; FONGARO, C. T. Digital soil mapping at local scale using a multi-depth Vis–NIR spectral library and terrain attributes. **Geoderma**, v. 274, p. 19-27, 2016.

ROBERTS, D. A.; GARDNER, M.; CHURCH, R.; USTIN, S.; SCHEER, G.; GREEN, R. O. Mapping chaparral in the Santa Monica Mountains using multiple endmember spectral mixture models. **Remote Sensing of Environment**, v. 65, n. 3, p. 267. 1998.

ROGGE, D.; BAUER, A.; ZEIDLER, J.; MUELLER, A.; ESCH, T.; HEIDEN, U. Building an exposed soil composite processor (SCMaP) for mapping spatial and temporal characteristics of soils with Landsat imagery (1984–2014). **Remote Sensing of Environment**. 205, 1–17. 2018. <https://doi.org/10.1016/j.rse.2017.11.004>.

ROMERO, D. J.; BEN-DOR, E.; DEMATTÊ, J. A. M.; SOUZA, A. B. E.; VICENTE, L. E.; TAVARES, T. R.; MARTELLO, M.; STRABELI, T. F.; BARROS, P. P. S.; FIORIO, P. R.; GALLO, B. C.; SATO, M. V.; EITELWEIN, M. T. Internal soil standard method for the Brazilian soil spectral library: Performance and proximate analysis. **Geoderma**. 2018. <https://doi.org/10.1016/j.geoderma.2017.09.014>

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W., Monitoring vegetation systems in the Great Plains with ERTS, *In*: FREDEN, S. C; MERCANTI, E. P.; BECKER, M. (eds) **Third Earth Resources Technology Satellite – 1º Symposium**. Volume I, NASA, NASA, Washington, D.C., 1974. p. 309-317.

ROY, D. P.; KOVALSKYY, V.; ZHANG, H. K.; VERMOTE, E. F.; YAN, L.; KUMAR, S. S.; EGOROV, A. Characterization of Landsat-7 to Landsat-8 reflective wavelength and normalized difference vegetation index continuity. **Remote sensing of Environment**, 185, 57-70. 2016.

RUHOFF, A. L.; PAZ, A. R.; COLLISCHONN, W.; ARAGÃO, L. E. O. C.; ROCHA, H. R.; MALHI, Y. S. A MODIS-based energy balance to estimate evapotranspiration for clear sky days in Brazilian tropical savannas. **Remote Sensing**, v. 4, p.703-725, 2012.

SAMPAIO, T. V. M.; AUGUSTIN, C. H. R. R. Índice de concentração da rugosidade: uma nova proposta metodológica para o mapeamento e quantificação da dissecação do relevo como subsídio a cartografia geomorfológica. **Revista Brasileira de Geomorfologia**, v. 15, nº 1, 2014. <http://dx.doi.org/10.20502/rbg.v15i1.376>.

- SAMUEL-ROSA, A.; DALMOLIN, R. S. D.; MOURA-BUENO, J. M.; TEIXEIRA, W. G.; ALBA, J. M. F. Open legacy soil survey data in Brazil: geospatial data quality and how to improve it. **Scientia Agricola**, v. 77, n. 1. 2020. doi:10.1590/1678-992x-2017-0430
- SANO, E. E.; BORGES, E. F. Séries temporais: Comportamento espectral de imagens multidatadas. In: MENESES, P. R.; ALMEIDA, T.; BAPTISTA, G. M. M. **Reflectância dos materiais terrestres: análise e interpretação**. Oficinas de Textos. 2019a. p. 266
- SANO, E. E.; BORGES, E. F. Reflectância dos alvos na faixa de micro-ondas. In: MENESES, P. R.; ALMEIDA, T.; BAPTISTA, G. M. M. **Reflectância dos materiais terrestres: análise e interpretação**. Oficinas de Textos. 2019b. p. 293–315.
- SANO, E. E.; HUETE, A. R.; TROUFLEAU, D.; MORAN, M. S.; VIDAL, A. Relation between ERS-1 synthetic aperture radar data and measurements of surface roughness and moisture content of rocky soils in a semiarid rangeland. **Water Resources Research**, v. 34, n. 6, p. 1491–1498. 1998. doi:10.1029/98wr00032
- SANO, E. E.; MATRICARDI, E. A. T.; CAMARGO, F. F. Estado da arte do sensoriamento remoto por radar: Fundamentos, sensores, processamento de imagens e aplicações. **Revista Brasileira de Cartografia**, v. 72, p. 1458-1483, 2020. DOI: 10.14393/rbcv72nespecial50anos-56568
- SANO, E. E.; RODRIGUES, A. A.; MARTINS, E. S.; BETTIOL, G. M.; BUSTAMANTE, M. M. C.; BEZERRA, A. S.; COUTO, A. F.; VASCONCELOS, V.; SCHÜLER, J.; BOLFE, E. L. Cerrado ecoregions: A spatial framework to assess and prioritize Brazilian savanna environmental diversity for conservation. **Journal of Environment Management**. 2019. <https://doi.org/10.1016/j.jenvman.2018.11.108>
- SANTOS, H. G.; HOCHMÜLLER, D. P.; CAVALCANTI, A. C.; RÉGO, R. S.; KER, J. C.; PANOSO, L. A.; AMARAL, J. A. M. **Procedimentos normativos de levantamentos pedológicos**. Brasília, DF: EMBRAPA-SPI; Rio de Janeiro: EMBRAPA-CNPq, 1995. 108 p.
- SANTOS, H. G.; JACOMINE, P. K. T.; ANJOS, L. H. C.; OLIVEIRA, V. A.; LUMBRERAS, J. F.; COELHO, M. R.; ALMEIDA, J. A.; ARAUJO FILHO, J. C.; OLIVEIRA, J. B.; CUNHA, T. J. F. **Sistema Brasileiro de Classificação de Solos**. 5. ed. rev. e ampl. Brasília, DF: Embrapa, 2018. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/199517/1/SiBCS-2018-ISBN-9788570358004.pdf> Acesso em 20 de maio de 2020.
- SANTOS, R. D.; SANTOS, H. G.; KER, J. C.; ANJOS, L. H. C.; SHIMIZU, S. H. **Manual de descrição e coleta de solo no campo**. 7. ed. Viçosa, MG: Embrapa, 2015. 102p.
- SARADJIAN, M. R.; HOSSEINI, M. Soil moisture estimation by using multipolarization SAR image. **Advances in Space Research**, v. 48, n. 2, 278–286. 2011. doi:10.1016/j.asr.2011.03.029
- SATALINO, G.; MATTIA, F.; BALENZANO, A.; PANCIERA, R.; WALKER, J. Soil moisture maps from time series of ScanSAR data over Australia. **IEEE International Geoscience and Remote Sensing Symposium – IGARSS**, 2013, pp. 719-722, doi: 10.1109/IGARSS.2013.6721258.

SCHEINOST, A. C.; CHAVERNAS, A.; BARRÓN, V.; TORRENT J. Use and limitations of second-derivative diffuse reflectance spectroscopy in the visible to near-infrared range to identify and quantify Fe oxide minerals in soils. **Clays and Clay Minerals**. v. 46, n. 5, p. 528–536. 1998. DOI:10.1346/CCMN.1998.0460 506.

SCHMUGGE, T. **Effect of soil texture on the microwave emission from soils. Technical Memorandum 80632**. 1980.

SCHOENEBERGER, P. J.; WYSOCKI, D. A.; BENHAM, E. C. **Field Book for Describing and Sampling Soils**, Version 3.0. Soil Survey Staff. Natural Resources Conservation Service. National Soil Survey Center, Lincoln, NE, 2012.

SEKERTEKIN A.; MARANGOZ A.; ABDIKAN S. Soil moisture mapping using Sentinel-1A synthetic aperture radar data. **International Journal of Environment and Geoinformatics**. v. 5, n. 2, p. 178-188. 2018. <https://doi.org/10.30897/ijegeo.425606>

SEKERTEKIN, A.; MARANGOZ, A. M.; ABDIKAN, S. ALOS-2 and Sentinel-1 SAR data sensitivity analysis to surface soil moisture over bare and vegetated agricultural fields. **Computers and Electronics in Agriculture**, 171, 105303. 2020. doi:10.1016/j.compag.2020.105303

SEMA – Secretaria do Meio Ambiente do Distrito Federal. **Mapa da Cobertura Vegetal e Uso do Solo do Distrito Federal**. Brasília. 2021. Disponível em: <http://www.sema.df.gov.br/mapa-da-cobertura-vegetal-e-uso-do-solo-do-distrito-federal/> Acesso em: 04 de maio de 2021.

SENEVIRATNE, S. I.; CORTI, T.; DAVIN, E. L.; HIRSCHI, M.; JAEGER, E. B.; LEHNER, I.; ORLOWSSKY, B.; TEULING, A. J. Investigating soil moisture–climate interactions in a changing climate: A review. **Earth-Science Reviews**, v. 99, p. 125–161, 2010.

SETIYONO, T. D.; HOLECZ, F.; KHAN, N. I.; BARBIERI, M.; QUICHO, E.; COLLIVIGNARELLI, F.; ROMUGA, G. C. Synthetic aperture radar (SAR)-based paddy rice monitoring system: Development and application in key rice producing areas in tropical Asia. **IOP Conference Series: Earth and Environmental Science**, 54, 012015. 2017. doi:10.1088/1755-1315/54/1/012015

SILVA, F. A. M.; EVANGELISTA, B. A.; MALAQUIAS, J. V.; OLIVEIRA, A. D.; MULLER, A. G. **Análise temporal de variáveis climáticas monitoradas entre 1974 e 2013 na estação principal da Embrapa Cerrados**. Planaltina, DF: Embrapa Cerrados, 2017. 122 p. http://bbeletronica.cpac.embrapa.br/versaomodelo/html/2017/bolpd/bold_340.shtml Acesso em: 25 de maio de 2020.

SILVA, F. L.; PIERANGELI, M. A.; SANTOS, F. A. S.; SOUSA, J. B.; SERAINM, M. E.; SOUSA, C. A. Caracterização pedológica de campos de murundus da bacia hidrográfica do Rio Guaporé no Estado de Mato Grosso. **Revista Geonorte**, v.10, n.1, p.51-58, 2014.

SOIL SURVEY STAFF. **Keys to Soil Taxonomy**, 12th ed. USDA-Natural Resources Conservation Service, Washington, DC. 2014.

SOIL SURVEY STAFF, **Soil Survey Manual Agriculture. Handbook 18**. USDA, United States Department of Agriculture, Natural Resources and Conservation Service, 2017. <https://doi.org/10.1097/00010694-195112000-00022>

STEFFAN, J. J.; BREVIK, E. C.; BURGESS, L. C.; CERDÀ, A. The effect of soil on human health: an overview. **European Journal of Soil Science**, 69(1), 159–171. 2017. doi:10.1111/ejss.12451

STROMANN, O.; NASCETTI, A.; YOUSIF, O.; BAN, Y. Dimensionality reduction and feature selection for object-based land cover classification based on Sentinel-1 and Sentinel-2 time series using Google Earth Engine. **Remote Sensing**. 2020; 12(1):76. <https://doi.org/10.3390/rs12010076>

TEIXEIRA, P. C.; DONAGEMMA, G. K.; FONTANA, A.; TEIXEIRA, W. G. (Eds). **Manual de métodos de análise de solos**. Embrapa - CNPS. 3.ed. Rio de Janeiro, 2017. 576p. Disponível em: <
<https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1085209/1/ManualdeMetodosdeAnalisedeSolo2017.pdf> > acesso em 02 de maio de 2020.

TEN CATEN, A.; DALMOLIN, R. S. D.; PEDRON, F. A.; MENDONÇA SANTOS, M. L. M. Extrapolação das relações solo-paisagem a partir de uma área de referência. **Ciência Rural**, v.41, n.5, p.812-816, 2011.

TEUBER, S.; AHLRICHS, J. J.; HENKNER, J.; KNOPF, T.; KÜHN, P.; SCHOLTEN, T. Soil cultures – the adaptive cycle of agrarian soil use in Central Europe: an interdisciplinary study using soil scientific and archaeological research. **Ecology and Society**. 22(4):13. 2017. <https://doi.org/10.5751/ES-09729-220413>

TORRES, R.; SNOEIJ, P., GEUDTNER, D., BIBBY, D., DAVIDSON, M., ATTEMA, E., ROSTAN, F. GMES Sentinel-1 mission. **Remote Sensing of Environment**, 120, 9–24. 2012. doi:10.1016/j.rse.2011.05.028

ULABY, F. T.; DUBOIS, P. C.; VAN ZYL, J. Radar mapping of surface soil moisture. **Journal of Hydrology**, v. 184, n. 1-2, p. 57–84. 1996 doi:10.1016/0022-1694(95)02968-0

USGS. United States Geological Service. **Landsat Earth Observation Satellites**. South Dakota 2020. <https://doi.org/10.3133/fs20153081>. Acesso em: maio de 2020.

VAN ES, H. A. new definition of SOIL. SSSA – Soil Science Society of America. **CSA News**, 62. 2017. doi:10.2134/csa2017.62.1016.

VERECKEN, H.; KAMAI, T.; HARTE, T.; KASTEEL, R.; HOPMANS, J.; VANDERBORGHT, J. Explaining soil moisture variability as a function of mean soil moisture: A stochastic unsaturated flow perspective. **Geophysical Research Letters**. 2007, 34.

VITOLO, C.; ELKHATIB, Y.; REUSSER, D.; MACLEOD, C. J. A.; BUYTAERT, W. Web technologies for environmental big data. **Environmental Modelling & Software**, 63, 185–198. 2015. doi:10.1016/j.envsoft.2014.10.007

WANG, Y.; PENG, J.; SONG, X.; LENG, P.; LUDWIG, R. E.; LOEW, A. Surface soil moisture retrieval using optical/thermal infrared remote sensing data. **Transactions**

on **Geoscience and Remote Sensing**. v. 56, n. 9, p. 5433–5442. 2018. DOI: 10.1109/TGRS.2018.2817370

WATERS, N. GIS: History. International Encyclopedia of Geography: **People, the Earth, Environment and Technology**, 1–12. 2017. doi:10.1002/9781118786352.wbieg0841

WEIL, R. R.; BRADY, N. C. **Elements of the nature and properties of soils**. Fourth edition. NY. Pearson. 2019. 742 p.

WEISS, A. Topographic position and landforms analysis. In: **Poster presentation, ESRI User Conference**, San Diego, CA, Vol. 200. 2001, July. http://www.jennessent.com/downloads/tpi-poster-tnc_18x22.pdf

WU, C.; CAO, G.; CHEN, K. E. C.; MAO, Y.; ZHAO, S.; WEI, Y. Remotely sensed estimation and mapping of soil moisture by eliminating the effect of vegetation cover. **Journal of Integrative Agriculture**, v. 18, n. 2, p. 316–327. 2019. doi:10.1016/s2095-3119(18)61988-4

WU, X.; SHI, W.; GUO, B.; TAO, F.. Large spatial variations in the distributions of and factors affecting forest water retention capacity in China. **Ecological Indicators**, 113, 106152. 2020. doi:10.1016/j.ecolind.2020.106152

YANG, Y.; GUAN, H.; LONG, D.; LIU, B.; QIN, G.; QIN, J., BATELAAN, O. Estimation of surface soil moisture from thermal infrared remote sensing using an improved trapezoid method. **Remote Sensing**. v.7, p. 8250–8270, 2015.

ZHANG, D.; ZHOU, G. Estimation of soil moisture from optical and thermal remote sensing: A review. **Sensors**. 2016, 16, 1308. <https://doi.org/10.3390/s16081308>

ZHANG, Y.; GONG, J.; SUN, K.; YIN, J.; CHEN, X. Estimation of soil moisture index using multi-temporal Sentinel-1 images over Poyang Lake ungauged zone. **Remote Sensing**. v. 10, n. 12. 2018. <https://doi.org/10.3390/rs10010012>

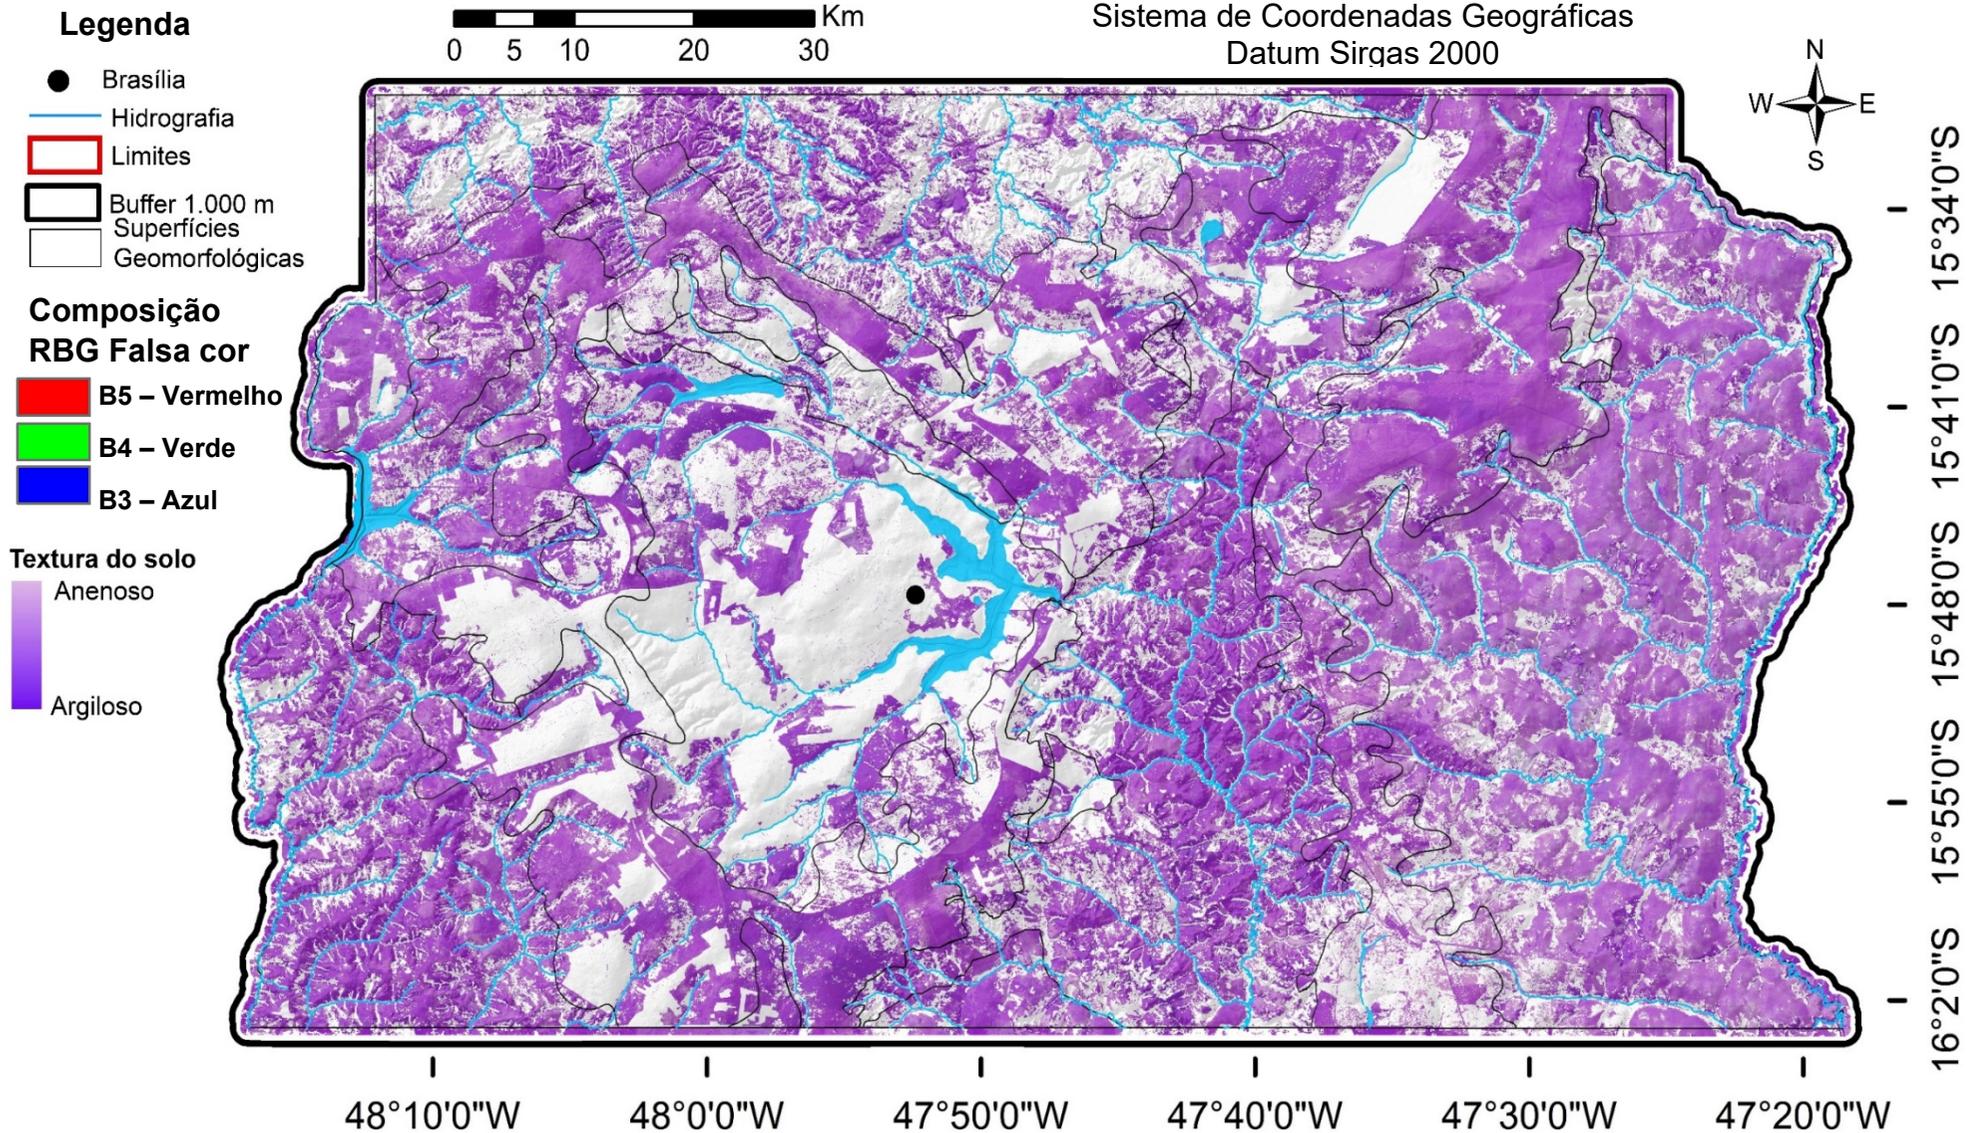
ZHANG, Y.; TAN, K.; WANG, X.; CHEN, Y. Retrieval of soil moisture content based on a modified hapke photometric model: A novel method applied to laboratory hyperspectral and Sentinel-2 MSI data. **Remote Sensing**. 2020; 12(14):2239. <https://doi.org/10.3390/rs12142239>

ZHOU, S.; WILLIAMS, A. P.; LINTNER, B. R.; BERG, A. M.; ZHANG, Y.; KEENAN, T. F.; COOK, B. I.; HAGEMANN, S.; SENEVIRATNE, S. I.; GENTINE P. Soil moisture–atmosphere feedbacks mitigate declining water availability in drylands. **Nature Climate Changing**. 11, 38–44. 2021. <https://doi.org/10.1038/s41558-020-00945-z>

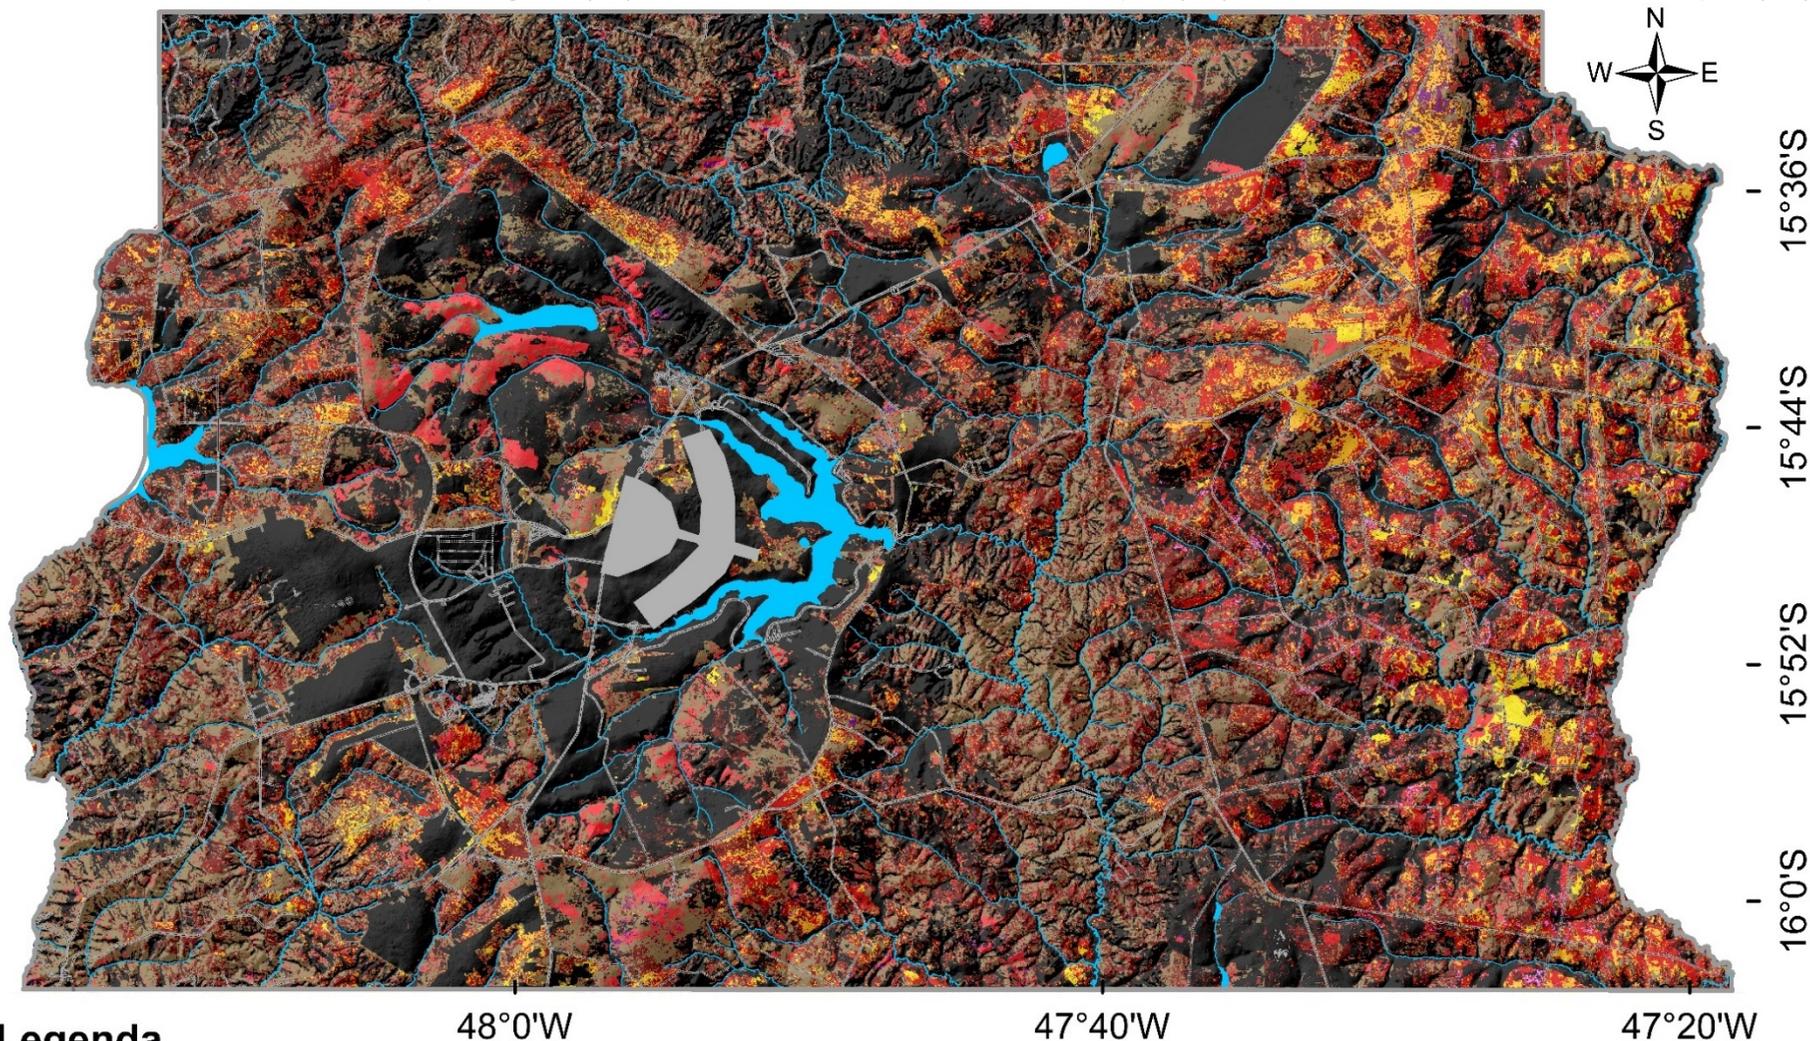
ZRIBI, M.; MUDDU, S.; BOUSBIH, S.; AL BITAR, A.; TOMER, S. K.; BAGHDADI, N.; BANDYOPADHYAY, S. Analysis of L-band SAR data for soil moisture estimations over agricultural areas in the tropics. **Remote Sensing**. 2019; 11, 9, 1122. <https://doi.org/10.3390/rs11091122>

APÊNDICES

Apêndice A. Imagem Sintética de Solo (SySI) do Distrito Federal. Fonte: Elaborado pelo autor com base em Demattê et al. (2018).



Apêndice B. Mapa digital de solos expostos do Distrito Federal. LATOSSOLO VERMELHO Distrófico típico (LV-I = argiloso e LV-II = muito argiloso), LATOSSOLO VERMELHO-AMARELO Distrófico típico (LVA-I = argiloso e LVA-II = muito argiloso), PLINTOSSOLO PÉTRICO Concrecionário típico (FF = argiloso a muito argiloso), PLINTOSSOLO HÁPLICO Distrófico típico argiloso (FX), CAMBISSOLO HÁPLICO tb Distrófico típico (CX) NEOSSOLO REGOLÍTICO Distrófico típico (RR).



Legenda

- Brasília (Plano Piloto)
- Limites DF
- Corpos hídricos
- Rodovias Simples
- Áreas Suprimidas

Classes de Solos

- | | |
|--------|--------------------------------|
| LV I | Associações FF + RR |
| LV II | Associações FF + LV + LVA |
| LVA I | Associações FF+ FX + CX |
| LVA II | Associações FF + RR + CX + LVA |

km
 0 3 6 12 18 24
 Sistema de coordenadas geográficas
 Datum Sirgas 2000

Apêndice C1. Algoritmo para pré-processamento de imagens Sentinel-1.

```
//Filtre por retângulo envolvente do Distrito Federal
var df_retenv = ee.Geometry.Rectangle({coords: [-48.374, -15.400, -
47.206, -16.088], geodesic: false});
//Defina série temporal
var img1s = ee.Date('2019-10-05'); var img1f = ee.Date('2019-10-06');
// Filtre a coleção Sentinel-1, Orbita Descendente, produto IW, GDR.
var orbit = 'DESCENDING'; var collectionS1 =
ee.ImageCollection('COPERNICUS/S1_GRD')
.filter(ee.Filter.listContains('transmitterReceiverPolarisation',
'VV')) .filter(ee.Filter.eq('instrumentMode', 'IW'))
.filter(ee.Filter.eq('orbitProperties_pass', orbit))
.filterBounds(df_retenv) .filterDate(img1s, img1f);
// Filtre pela polarização VV e VH.
var collectionVV = collectionS1.select('VV');
var collectionVH = collectionS1.select('VH');
// renomear polarizações.
var VV = ee.Image(collectionVV.median());
var VH = ee.Image(collectionVH.median());
// Visualizar mediana da serie temporal dupla polarização
Map.centerObject(df_retenv, 9);Map.addLayer(VV, {min: -25, max: 5},
'VV', true); Map.addLayer(VH, {min: -25, max: 5}, 'VH', true);
// Importe para diretório do Google Drive.
Export.image.toDrive({image: VH, description: 'VH_I', scale: 10,
region: df_retenv}); Export.image.toDrive({image: VV, description:
'VV_I', scale: 10, region: df_retenv});
```

Fonte: Elaborado pelo autor

Apêndice C2. Código para obtenção das imagens NDVI do Sentinel-2.

```
//Filtre por retângulo envolvente do Distrito Federal
var df_retenv = ee.Geometry.Rectangle({coords: [-48.374, -15.400, -
47.206, -16.088], geodesic: false});
// Calcule o Índice de Vegetação por Diferença Normalizada
var S2_display = {bands: ['B4', 'B3', 'B2'], min: 0, max: 3000};
var ndvi_palette = 'FFFFFF, CE7E45, DF923D, F1B555, FCD163, 99B718,
74A901, 66A000, 529400, ' + '3E8601, 207401, 056201, 004C00, 023B01,
012E01, 011D01, 011301';
function addnd(input) { var nd = input.normalizedDifference(['B8',
'B4']).rename('ndvi'); return input.addBands(nd);
// Filtre a mediana de 30 dias em torno da série I
var S2_I = ee.ImageCollection("COPERNICUS/S2")
.filterBounds(df_retenv) .filterDate('2019-09-20', '2019-10-20')
.filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'less_than',
5).map(addnd);
var ndvi_I = S2_I.select('ndvi').median().clip(df_retenv);
Map.addLayer(ndvi_I, {min: -0.1, max: 1, palette: ndvi_palette},
'NDVI I'); Map.centerObject(df_retenv);
//Exporte as imagens individualmente para um repositório virtual
Export.image.toDrive({image: ndvi_I, description: 'NDVI_I',
scale: 10, region: df_retenv});
```

Fonte: Elaborado pelo autor

Apêndice C3. Tabela de atributos dos solos do setor A (Embrapa Cerrados).

| ID | Prof. | Argila | Silte | Areia | pH H ₂ O | P | Ca | Mg | Al ³⁺ | H ⁺ + Al ³⁺ | K | Na | SB | t | T | V | m | MO | C |
|---|----------|--------------------|--------|--------|---------------------|---------------------|------------------------|------|------------------|-----------------------------------|------|------|--------------------|------|-------|-------|-------|-------|-------|
| | | g.kg ⁻¹ | | | | mg.dm ⁻³ | Cmolc.dm ⁻³ | | | | | % | g.kg ⁻¹ | | | | | | |
| LATOSSOLO VERMELHO-AMARELO Distrófico petroplântico | | | | | | | | | | | | | | | | | | | |
| PA1 | 0 - 20 | 385,20 | 34,93 | 579,87 | 4,90 | 1,75 | 0,55 | 0,50 | 0,15 | 5,98 | 0,04 | 0,06 | 1,15 | 1,30 | 7,13 | 16,13 | 11,54 | 24,65 | 12,19 |
| | 80 - 100 | 443,44 | 33,41 | 523,15 | 5,60 | 1,75 | 0,38 | 0,49 | 0,00 | 4,25 | 0,07 | 0,07 | 1,01 | 1,01 | 5,26 | 19,20 | 0,00 | 11,91 | 5,09 |
| LATOSSOLO VERMELHO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PA2 | 0 - 20 | 539,39 | 95,20 | 365,41 | 5,80 | 4,90 | 2,10 | 1,80 | 0,10 | 3,70 | 0,27 | 0,12 | 4,29 | 4,39 | 7,99 | 53,69 | 2,28 | 22,36 | 13,00 |
| | 80 - 100 | 578,61 | 3,05 | 418,34 | 5,70 | 1,30 | 0,40 | 0,30 | 0,00 | 3,20 | 0,05 | 0,08 | 0,83 | 0,83 | 4,03 | 20,60 | 0,00 | 10,49 | 6,10 |
| LATOSSOLO VERMELHO-AMARELO Distrófico petroplântico | | | | | | | | | | | | | | | | | | | |
| PA3 | 0 - 20 | 429,52 | 105,48 | 465,00 | 5,20 | 7,60 | 2,20 | 2,00 | 0,20 | 4,60 | 0,35 | 0,10 | 4,65 | 4,85 | 9,25 | 50,27 | 4,12 | 24,42 | 14,20 |
| | 80 - 100 | 488,73 | 86,15 | 425,12 | 5,60 | 1,00 | 1,10 | 0,80 | 0,00 | 2,50 | 0,09 | 0,07 | 2,06 | 2,06 | 4,56 | 45,18 | 0,00 | 5,16 | 3,00 |
| PLINTOSSOLO HÁPLICO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PA4 | 0 - 20 | 609,15 | 229,67 | 161,17 | 5,60 | 5,30 | 2,80 | 2,10 | 0,40 | 5,80 | 0,85 | 0,11 | 5,86 | 6,26 | 11,66 | 50,26 | 6,39 | 34,74 | 20,20 |
| | 80 - 100 | 722,57 | 116,65 | 160,77 | 5,60 | 2,20 | 1,10 | 0,30 | 0,10 | 3,70 | 0,05 | 0,08 | 1,53 | 1,63 | 5,23 | 29,25 | 6,13 | 7,40 | 4,30 |
| LATOSSOLO VERMELHO-AMARELO Distrófico petroplântico | | | | | | | | | | | | | | | | | | | |
| PA5 | 0 - 20 | 485,89 | 155,98 | 358,13 | 5,20 | 2,20 | 0,90 | 0,60 | 0,80 | 6,70 | 0,26 | 0,07 | 1,83 | 2,63 | 8,53 | 21,45 | 30,42 | 19,95 | 11,60 |
| | 80 - 100 | 515,87 | 203,75 | 280,38 | 5,20 | 1,40 | 0,60 | 0,50 | 0,10 | 3,40 | 0,05 | 0,07 | 1,22 | 1,32 | 4,62 | 26,41 | 7,58 | 9,29 | 5,40 |
| PLINTOSSOLO PÉTRICO Distrófico êndico | | | | | | | | | | | | | | | | | | | |
| PA6 | 0 - 20 | 100,28 | 12,86 | 886,86 | 5,00 | 0,80 | 0,30 | 0,10 | 0,20 | 3,70 | 0,04 | 0,07 | 0,51 | 0,71 | 4,21 | 12,11 | 28,17 | 12,04 | 7,00 |
| | 50+ | 119,76 | 27,18 | 853,07 | 5,20 | 0,70 | 0,30 | 0,10 | 0,20 | 3,40 | 0,03 | 0,06 | 0,49 | 0,69 | 3,89 | 12,60 | 28,99 | 6,19 | 3,60 |
| NEOSSOLO QUARTZARÊNICO Órtico típico | | | | | | | | | | | | | | | | | | | |
| PA7 | 0 - 20 | 96,82 | 1,81 | 901,37 | 5,10 | 0,80 | 0,40 | 0,10 | 0,40 | 4,30 | 0,05 | 0,08 | 0,63 | 1,03 | 4,93 | 12,78 | 38,83 | 10,66 | 6,20 |
| | 100+ | 119,61 | 9,86 | 870,54 | 5,30 | 0,50 | 0,30 | 0,10 | 0,00 | 2,50 | 0,04 | 0,06 | 0,50 | 0,50 | 3,00 | 16,67 | 0,00 | 4,64 | 2,70 |
| PLINTOSSOLO HÁPLICO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PA8 | 0 - 20 | 588,72 | 151,03 | 260,25 | 5,80 | 2,00 | 0,60 | 0,10 | 0,10 | 2,00 | 0,12 | 0,21 | 1,03 | 1,13 | 3,03 | 33,99 | 8,85 | 52,46 | 30,50 |
| | 60+ | 746,34 | 109,36 | 144,29 | 5,20 | 1,90 | 0,20 | 0,10 | 0,50 | 6,70 | 0,05 | 0,17 | 0,52 | 1,02 | 7,22 | 7,20 | 49,02 | 6,54 | 3,80 |
| LATOSSOLO VERMELHO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PA9 | 0 - 20 | 715,57 | 77,13 | 207,30 | 5,40 | 0,80 | 1,00 | 1,00 | 0,00 | 4,30 | 0,08 | 0,09 | 2,17 | 2,17 | 6,47 | 33,54 | 0,00 | 28,04 | 16,30 |
| | 80 - 100 | 787,95 | 33,32 | 178,74 | 5,50 | 0,60 | 0,30 | 0,10 | 0,00 | 2,50 | 0,04 | 0,07 | 0,51 | 0,51 | 3,01 | 16,94 | 0,00 | 12,21 | 7,10 |
| LATOSSOLO VERMELHO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PA10 | 0 - 20 | 692,17 | 110,45 | 197,37 | 5,40 | 2,40 | 1,50 | 1,50 | 0,20 | 4,60 | 0,45 | 0,10 | 3,55 | 3,75 | 8,15 | 43,56 | 5,33 | 27,69 | 16,10 |
| | 80 - 100 | 775,98 | 54,57 | 169,46 | 5,50 | 0,70 | 0,70 | 0,30 | 0,00 | 3,40 | 0,05 | 0,12 | 1,17 | 1,17 | 4,57 | 25,60 | 0,00 | 11,70 | 6,80 |

¹ pH em H₂O; ² Soma das bases; ³ Capacidade de troca catiônica; ⁴ Saturação por bases; ⁵ Saturação por alumínio; Matéria orgânica no solo; * Desvio-padrão.

Apêndice C4. Tabela de atributos dos solos do setor B (PAD-DF).

| ID | Prof. | Argila | Silte | Areia | pH H ₂ O | P | Ca | Mg | Al ³⁺ | H ⁺ + Al ³⁺ | K | Na | SB | t | T | V | m | MO | C |
|---|----------|--------------------|--------|--------|---------------------|---------------------|------------------------|------|------------------|-----------------------------------|------|------|------|--------------------|-------|-------|-------|-------|-------|
| | | g.kg ⁻¹ | | | | mg.dm ⁻³ | Cmolc.dm ⁻³ | | | | | % | | g.kg ⁻¹ | | | | | |
| LATOSSOLO VERMELHO-AMARELO Distrófico petroplântico | | | | | | | | | | | | | | | | | | | |
| PB1 | 0 - 20 | 494,27 | 153,97 | 351,76 | 5,40 | 15,70 | 2,70 | 1,80 | 0,10 | 4,00 | 0,35 | 0,13 | 4,98 | 5,08 | 8,98 | 55,46 | 1,97 | 26,49 | 15,40 |
| | 80 - 100 | 720,49 | 36,60 | 242,91 | 5,90 | 1,10 | 1,00 | 0,40 | 0,10 | 2,40 | 0,10 | 0,10 | 1,60 | 1,70 | 4,00 | 40,00 | 5,88 | 12,04 | 7,00 |
| NEOSSOLO QUARTZARÊNICO Órtico típico | | | | | | | | | | | | | | | | | | | |
| PB2 | 0 - 20 | 46,63 | 2,20 | 951,17 | 5,50 | 1,00 | 0,40 | 0,10 | 0,40 | 5,00 | 0,07 | 0,08 | 0,65 | 1,05 | 5,65 | 11,50 | 38,10 | 15,31 | 8,90 |
| | 120+ | 47,03 | 0,81 | 952,16 | 5,50 | 0,80 | 0,30 | 0,10 | 0,30 | 3,70 | 0,02 | 0,07 | 0,49 | 0,79 | 4,19 | 11,69 | 37,97 | 6,36 | 3,70 |
| LATOSSOLO VERMELHO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PB3 | 0 - 20 | 842,60 | 31,00 | 126,40 | 5,40 | 11,10 | 3,00 | 1,50 | 0,00 | 5,00 | 0,34 | 0,12 | 4,96 | 4,96 | 9,96 | 49,80 | 0,00 | 30,44 | 17,70 |
| | 80 - 100 | 841,40 | 58,35 | 100,25 | 5,70 | 1,10 | 1,60 | 0,50 | 0,10 | 3,00 | 0,16 | 0,10 | 2,36 | 2,46 | 5,36 | 44,03 | 4,07 | 15,65 | 9,10 |
| LATOSSOLO VERMELHO-AMARELO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PB4 | 0 - 20 | 325,52 | 34,21 | 640,26 | 5,50 | 4,80 | 1,60 | 0,80 | 0,00 | 3,70 | 0,12 | 0,09 | 2,61 | 2,61 | 6,31 | 41,36 | 0,00 | 14,96 | 8,70 |
| | 80 - 100 | 383,39 | 46,17 | 570,44 | 5,60 | 1,00 | 0,80 | 0,20 | 0,00 | 2,50 | 0,11 | 0,09 | 1,20 | 1,20 | 3,70 | 32,43 | 0,00 | 6,19 | 3,60 |
| PLINTOSSOLO PÉTRICO Concrecionário típico | | | | | | | | | | | | | | | | | | | |
| PB5 | 0 - 20 | 613,52 | 339,24 | 47,24 | 5,70 | 2,09 | 1,78 | 0,71 | 0,00 | 7,22 | 0,09 | 0,10 | 2,68 | 2,68 | 9,90 | 37,12 | 0,00 | 22,44 | 11,12 |
| | 20 - 40 | 634,99 | 314,21 | 50,80 | 5,70 | 1,75 | 1,06 | 0,88 | 0,03 | 5,99 | 0,05 | 0,07 | 2,06 | 2,09 | 8,05 | 34,39 | 1,44 | 7,13 | 4,01 |
| LATOSSOLO VERMELHO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PB6 | 0 - 20 | 786,27 | 112,55 | 101,18 | 5,50 | 4,80 | 2,20 | 1,20 | 0,00 | 4,30 | 0,17 | 0,10 | 3,67 | 3,67 | 7,97 | 46,05 | 0,00 | 25,46 | 14,80 |
| | 20 - 80 | 856,44 | 45,38 | 98,18 | 5,70 | 0,80 | 1,40 | 0,70 | 0,00 | 2,40 | 0,06 | 0,10 | 2,26 | 2,26 | 4,66 | 48,50 | 0,00 | 12,38 | 7,20 |
| NEOSSOLO REGOLÍTICO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PB7 | 0 - 20 | 283,63 | 586,11 | 130,27 | 5,60 | 2,80 | 4,30 | 2,60 | 0,70 | 3,40 | 0,08 | 0,10 | 7,08 | 7,78 | 10,48 | 67,56 | 9,00 | 26,49 | 15,40 |
| PLINTOSSOLO PÉTRICO Concrecionário típico | | | | | | | | | | | | | | | | | | | |
| PB8 | 0 - 20 | 678,86 | 139,49 | 181,65 | 5,50 | 4,20 | 3,90 | 2,10 | 0,00 | 3,20 | 0,73 | 0,13 | 6,86 | 6,86 | 10,06 | 68,19 | 0,00 | 23,56 | 13,70 |
| | 20 - 30 | 619,72 | 160,48 | 219,80 | 5,60 | 3,50 | 1,90 | 1,90 | 0,00 | 3,00 | 0,48 | 0,10 | 4,38 | 4,38 | 7,38 | 59,35 | 0,00 | 14,28 | 8,30 |
| LATOSSOLO VERMELHO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PB9 | 0 - 20 | 723,82 | 234,81 | 41,36 | 6,20 | 5,70 | 3,70 | 1,90 | 0,00 | 3,50 | 0,08 | 0,11 | 5,68 | 5,68 | 9,18 | 61,87 | 0,00 | 44,00 | 26,00 |
| | 80 - 100 | 750,15 | 215,68 | 34,17 | 6,40 | 2,00 | 2,00 | 1,20 | 0,00 | 2,60 | 0,05 | 0,12 | 3,25 | 3,25 | 5,85 | 55,56 | 0,00 | 26,00 | 15,00 |
| NEOSSOLO REGOLÍTICO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PB10 | 0 - 20 | 446,21 | 480,78 | 73,02 | 5,70 | 1,20 | 0,70 | 0,50 | 0,30 | 2,40 | 0,15 | 0,10 | 1,45 | 1,75 | 3,85 | 37,66 | 17,14 | 13,24 | 7,70 |

¹ pH em H₂O; ² Soma das bases; ³ Capacidade de troca catiônica; ⁴ Saturação por bases; ⁵ Saturação por alumínio; Matéria orgânica no solo; * Desvio-padrão.

Apêndice C5. Tabela de atributos dos solos do setor C (Fazenda Água Limpa, UnB).

| ID | Prof. | Argila | Silte | Areia | pH H ₂ O | P | Ca | Mg | Al ³⁺ | H ⁺ + Al ³⁺ | K | Na | SB | t | T | V | m | MO | C |
|---|----------|-------------------------------|--------|--------|---------------------|---------------------|-----------------------------------|------|------------------|-----------------------------------|------|-------------|---------------------------|------|-------|-------|-------|-------|-------|
| | | -----g.kg ⁻¹ ----- | | | | mg.dm ⁻³ | -----Cmolc.dm ⁻³ ----- | | | | | -----%----- | ---g.kg ⁻¹ --- | | | | | | |
| PLINTOSSOLO PÉTRICO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PC1 | 0 - 20 | 703,00 | 186,87 | 110,14 | 5,60 | 3,40 | 3,90 | 2,20 | 0,00 | 5,00 | 0,22 | 0,13 | 6,40 | 6,40 | 11,40 | 57,00 | 0,00 | 50,7 | 29,50 |
| | 30 - 50 | 704,21 | 130,85 | 164,94 | 5,80 | 1,00 | 0,50 | 0,30 | 0,00 | 4,00 | 0,09 | 0,10 | 0,99 | 0,99 | 4,99 | 19,84 | 0,00 | 45,06 | 26,20 |
| LATOSSOLO VERMELHO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PC2 | 0 - 20 | 692,13 | 162,95 | 144,92 | 5,50 | 1,20 | 0,30 | 0,20 | 0,10 | 5,00 | 0,10 | 0,11 | 0,71 | 0,81 | 5,71 | 12,43 | 12,35 | 44,03 | 25,60 |
| | 80 - 100 | 762,09 | 119,71 | 118,20 | 5,90 | 0,70 | 0,20 | 0,10 | 0,00 | 2,70 | 0,03 | 0,08 | 0,41 | 0,41 | 3,11 | 13,18 | 0,00 | 19,26 | 11,20 |
| LATOSSOLO VERMELHO-AMARELO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PC3 | 0 - 20 | 750,10 | 141,66 | 108,24 | 5,50 | 0,90 | 0,40 | 0,10 | 0,10 | 4,00 | 0,11 | 0,10 | 0,71 | 0,81 | 4,71 | 15,07 | 12,35 | 38,53 | 22,40 |
| | 80 - 100 | 788,21 | 50,25 | 161,54 | 5,70 | 0,80 | 0,30 | 0,10 | 0,10 | 2,70 | 0,09 | 0,10 | 0,59 | 0,69 | 3,29 | 17,93 | 14,49 | 23,05 | 13,40 |
| LATOSSOLO VERMELHO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PC4 | 0 - 20 | 827,22 | 126,22 | 46,56 | 5,40 | 1,00 | 0,30 | 0,20 | 0,10 | 3,40 | 0,14 | 0,10 | 0,74 | 0,84 | 4,14 | 17,87 | 11,90 | 44,38 | 25,80 |
| | 80 - 100 | 880,17 | 84,73 | 35,11 | 5,80 | 0,70 | 0,30 | 0,10 | 0,00 | 2,40 | 0,03 | 0,09 | 0,52 | 0,52 | 2,92 | 17,81 | 0,00 | 17,72 | 10,30 |
| PLINTOSSOLO HÁPLICO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PC5 | 0 - 20 | 767,56 | 112,97 | 119,47 | 5,20 | 1,20 | 0,40 | 0,20 | 0,40 | 5,00 | 0,12 | 0,16 | 0,88 | 1,28 | 5,88 | 14,97 | 31,25 | 51,77 | 30,10 |
| | 60 - 80 | 826,78 | 97,50 | 75,72 | 5,80 | 0,90 | 0,30 | 0,10 | 0,00 | 2,40 | 0,02 | 0,10 | 0,52 | 0,52 | 2,92 | 17,81 | 0,00 | 13,07 | 7,60 |
| LATOSSOLO VERMELHO-AMARELO Distrófico petroplíntico | | | | | | | | | | | | | | | | | | | |
| PC6 | 0 - 20 | 778,84 | 53,35 | 167,81 | 5,13 | 0,80 | 0,73 | 0,54 | 0,68 | 7,18 | 0,08 | 0,07 | 1,35 | 2,03 | 8,53 | 12,87 | 33,50 | 49,50 | 25,14 |
| | 80 - 100 | 822,30 | 109,62 | 68,08 | 5,09 | 0,20 | 0,03 | 0,02 | 0,00 | 4,26 | 0,03 | 0,07 | 0,08 | 0,08 | 4,31 | 1,16 | 0,00 | 18,00 | 8,25 |
| LATOSSOLO VERMELHO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PC7 | 0 - 20 | 214,87 | 109,96 | 675,17 | 5,10 | 1,10 | 0,40 | 0,10 | 0,50 | 4,00 | 0,16 | 0,10 | 0,76 | 1,26 | 4,76 | 15,97 | 39,68 | 15,82 | 9,20 |
| | 80 - 100 | 250,78 | 128,63 | 620,59 | 5,20 | 0,60 | 0,30 | 0,10 | 0,10 | 2,70 | 0,03 | 0,08 | 0,51 | 0,61 | 3,21 | 15,89 | 16,39 | 6,88 | 4,00 |
| NEOSSOLO REGOLÍTICO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PC8 | 0 - 20 | 153,78 | 43,41 | 802,81 | 5,00 | 2,00 | 0,30 | 0,10 | 0,30 | 3,70 | 0,08 | 0,08 | 0,56 | 0,86 | 4,26 | 13,15 | 34,88 | 13,07 | 7,60 |
| | 40 - 60 | 180,06 | 13,53 | 806,41 | 5,20 | 0,90 | 0,30 | 0,10 | 0,10 | 2,70 | 0,03 | 0,07 | 0,55 | 0,56 | 3,20 | 16,00 | 17,00 | 7,70 | 4,50 |
| LATOSSOLO VERMELHO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PC9 | 0 - 20 | 178,98 | 55,79 | 765,23 | 5,10 | 0,80 | 0,50 | 0,10 | 0,30 | 4,30 | 0,12 | 0,07 | 0,79 | 1,09 | 5,09 | 15,52 | 27,52 | 13,93 | 8,10 |
| | 80 - 100 | 232,32 | 15,64 | 752,04 | 5,40 | 0,80 | 0,30 | 0,10 | 0,00 | 2,40 | 0,05 | 0,06 | 0,51 | 0,51 | 2,91 | 17,53 | 0,00 | 8,43 | 4,90 |
| PLINTOSSOLO HÁPLICO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PC10 | 0 - 20 | 112,46 | 194,47 | 693,08 | 5,10 | 0,80 | 0,30 | 0,20 | 0,30 | 3,20 | 0,08 | 0,08 | 0,66 | 0,96 | 3,86 | 17,10 | 31,25 | 16,17 | 9,40 |
| | 60+ | 153,66 | 24,12 | 822,22 | 5,30 | 0,60 | 0,20 | 0,10 | 0,10 | 2,70 | 0,07 | 0,07 | 0,44 | 0,54 | 3,14 | 14,01 | 18,52 | 10,49 | 6,10 |

¹ pH em H₂O; ² Soma das bases; ³ Capacidade de troca catiônica; ⁴ Saturação por bases; ⁵ Saturação por alumínio; Matéria orgânica no solo; * Desvio-padrão.

Apêndice C6. Tabela de atributos dos solos do setor D (Parque Nacional de Brasília).

| ID | Prof. | Argila | Silte | Areia | pH H ₂ O | P | Ca | Mg | Al ³⁺ | H ⁺ + Al ³⁺ | K | Na | SB | t | T | V | m | MO | C |
|---|----------|-------------------------------|--------|--------|---------------------|---------------------|-----------------------------------|------|------------------|-----------------------------------|------|-------------|------|------|---------------------------|-------|-------|-------|-------|
| | | -----g.kg ⁻¹ ----- | | | | mg.dm ⁻³ | -----Cmolc.dm ⁻³ ----- | | | | | -----%----- | | | ---g.kg ⁻¹ --- | | | | |
| LATOSSOLO VERMELHO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PD1 | 0 - 20 | 256,61 | 42,54 | 700,85 | 5,40 | 1,20 | 1,50 | 0,70 | 0,10 | 4,00 | 0,12 | 0,09 | 2,41 | 2,51 | 6,41 | 37,60 | 3,98 | 33,54 | 19,50 |
| | 80 - 100 | 480,89 | 368,65 | 150,46 | 5,40 | 1,10 | 0,40 | 0,10 | 0,00 | 2,70 | 0,04 | 0,08 | 0,62 | 0,62 | 3,32 | 18,67 | 0,00 | 13,76 | 8,00 |
| PLINTOSSOLO PÉTRICO Concrecionário típico | | | | | | | | | | | | | | | | | | | |
| PD2 | 0 - 20 | 355,63 | 525,62 | 118,75 | 5,60 | 1,40 | 1,30 | 0,90 | 0,00 | 2,50 | 0,05 | 0,09 | 2,34 | 2,34 | 4,84 | 48,35 | 0,00 | 21,16 | 12,30 |
| | 20 - 40 | 401,72 | 458,11 | 140,17 | 5,80 | 0,70 | 0,90 | 0,80 | 0,00 | 2,40 | 0,04 | 0,09 | 1,83 | 1,83 | 4,23 | 43,26 | 0,00 | 14,45 | 8,40 |
| NEOSSOLO REGOLÍTICO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PD3 | 0 - 10 | 224,12 | 201,92 | 573,95 | 5,80 | 2,00 | 3,00 | 1,30 | 0,10 | 2,70 | 0,27 | 0,08 | 4,65 | 4,75 | 7,35 | 63,27 | 2,11 | 30,10 | 17,50 |
| PLINTOSSOLO PÉTRICO Concrecionário típico | | | | | | | | | | | | | | | | | | | |
| PD4 | 0 - 20 | 240,35 | 201,69 | 557,96 | 5,60 | 2,60 | 2,20 | 0,40 | 0,20 | 3,40 | 0,12 | 0,08 | 2,80 | 3,00 | 6,20 | 45,16 | 6,67 | 17,20 | 10,00 |
| | 40 - 60 | 305,17 | 120,50 | 574,33 | 5,40 | 1,40 | 0,50 | 0,20 | 0,20 | 3,20 | 0,11 | 0,08 | 0,89 | 1,09 | 4,09 | 21,76 | 18,35 | 13,93 | 8,10 |
| NEOSSOLO QUARTZARÊNICO Órtico típico | | | | | | | | | | | | | | | | | | | |
| PD5 | 0 - 20 | 102,08 | 4,65 | 893,27 | 5,50 | 1,70 | 1,40 | 0,50 | 0,00 | 3,20 | 0,33 | 0,13 | 2,36 | 2,36 | 5,56 | 42,45 | 0,00 | 39,73 | 23,10 |
| | 120+ | 120,09 | 1,14 | 878,77 | 5,50 | 0,90 | 0,60 | 0,20 | 0,10 | 2,40 | 0,09 | 0,07 | 0,96 | 1,06 | 3,36 | 28,57 | 9,43 | 11,18 | 6,50 |
| LATOSSOLO VERMELHO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PD6 | 0 - 20 | 365,81 | 566,36 | 67,83 | 5,40 | 1,10 | 3,60 | 1,20 | 0,00 | 4,30 | 0,37 | 0,13 | 5,30 | 5,30 | 9,60 | 55,21 | 0,00 | 39,04 | 22,70 |
| | 80 - 100 | 473,97 | 413,69 | 112,34 | 5,60 | 0,60 | 0,30 | 0,10 | 0,20 | 2,50 | 0,05 | 0,07 | 0,52 | 0,72 | 3,02 | 17,22 | 27,78 | 2,92 | 1,70 |
| LATOSSOLO VERMELHO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PD7 | 0 - 20 | 747,99 | 203,71 | 48,30 | 5,60 | 1,50 | 0,80 | 0,20 | 0,00 | 3,70 | 0,13 | 0,17 | 1,30 | 1,30 | 5,00 | 26,00 | 0,00 | 65,70 | 38,20 |
| | 80 - 100 | 882,66 | 63,33 | 54,01 | 5,80 | 1,10 | 0,50 | 0,10 | 0,10 | 3,20 | 0,13 | 0,10 | 0,83 | 0,93 | 4,03 | 20,60 | 10,75 | 15,48 | 9,00 |
| PLINTOSSOLO HÁPLICO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PD8 | 0 - 10 | 489,77 | 165,34 | 344,88 | 5,50 | 1,40 | 0,50 | 0,20 | 0,00 | 4,60 | 0,12 | 0,10 | 0,92 | 0,92 | 5,52 | 16,67 | 0,00 | 33,02 | 19,20 |
| | 50+ | 574,95 | 391,44 | 33,61 | 6,30 | 0,70 | 0,50 | 0,10 | 0,30 | 1,90 | 0,09 | 0,10 | 0,79 | 1,09 | 2,69 | 29,37 | 27,52 | 17,37 | 10,10 |
| LATOSSOLO VERMELHO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PD9 | 0 - 20 | 814,22 | 87,27 | 98,52 | 5,40 | 1,40 | 0,40 | 0,10 | 0,00 | 4,00 | 0,13 | 0,19 | 0,82 | 0,82 | 4,82 | 17,01 | 0,00 | 61,23 | 35,60 |
| | 80 - 100 | 873,92 | 45,36 | 80,72 | 5,60 | 0,80 | 0,10 | 0,10 | 0,10 | 3,00 | 0,05 | 0,08 | 0,33 | 0,43 | 3,33 | 9,91 | 23,26 | 11,18 | 6,50 |
| PLINTOSSOLO HÁPLICO Distrófico típico | | | | | | | | | | | | | | | | | | | |
| PD10 | 0 - 10 | 711,01 | 130,13 | 158,86 | 5,30 | 3,40 | 0,20 | 0,10 | 0,20 | 5,40 | 0,07 | 0,11 | 0,48 | 0,68 | 5,88 | 8,16 | 29,41 | 14,62 | 8,50 |
| | 50+ | 786,18 | 131,31 | 82,51 | 6,10 | 0,90 | 0,20 | 0,10 | 0,00 | 2,00 | 0,04 | 0,09 | 0,43 | 0,43 | 2,43 | 17,70 | 0,00 | 9,98 | 5,80 |

¹ pH em H₂O; ² Soma das bases; ³ Capacidade de troca catiônica; ⁴ Saturação por bases; ⁵ Saturação por alumínio; Matéria orgânica no solo; * Desvio-padrão.

Apêndice C7. Quadro resumo das características dos pontos e setores.

| Ponto | Setor | Coordenadas | | Altitude m | Declividade (%) | SG ¹ | Litologia | Uso/ Ocupação |
|-------|-------|-------------|-------------|---------------|--------------------|-----------------|-----------|------------------|
| | | Latitude | Longitude | | | | | |
| 1 | A | 15° 37' 53" | 47° 44' 02" | 1153 | 3 – 8 | I | Mpa3 | Cerrado |
| 2 | A | 15° 36' 06" | 47° 42' 45" | 998 | 0 – 3 | II | Mpa4 | Agricultura |
| 3 | A | 15° 35' 41" | 47° 43' 14" | 989 | 0 – 3 | II | Mpa4 | Agricultura |
| 4 | A | 15° 35' 26" | 47° 43' 30" | 983 | 3 – 8 | II | Mpa4 | Agricultura |
| 5 | A | 15° 36' 28" | 47° 42' 59" | 1035 | 8 – 20 | I | Mpa4 | Agricultura |
| 6 | A | 15° 36' 40" | 47° 43' 51" | 1145 | 3 – 8 | I | Mpa4 | Cerrado |
| 7 | A | 15° 36' 46" | 47° 44' 05" | 1162 | 0 – 3 | I | Mpa4 | Pastagem |
| 8 | A | 15° 37' 06" | 47° 45' 02" | 1186 | 0 – 3 | I | Mpa2 | Campo |
| 9 | A | 15° 37' 10" | 47° 45' 33" | 1202 | 0 – 3 | I | Mpa2 | Pastagem |
| 10 | A | 15° 36' 35" | 47° 42' 10" | 986 | 3 – 8 | II | Mpa4 | Silvicultura |
| 11 | B | 15° 43' 11" | 47° 34' 30" | 1152 | 0 – 3 | I | Mpa3 | Pastagem |
| 12 | B | 15° 44' 56" | 47° 34' 13" | 1101 | 0 – 3 | I | Mpa2 | Cerrado |
| 13 | B | 15° 43' 15" | 47° 33' 23" | 1150 | 0 – 3 | I | Mpa3 | Agricultura |
| 14 | B | 15° 43' 37" | 47° 32' 35" | 1105 | 3 – 8 | I | Mpa3 | Agricultura |
| 15 | B | 15° 47' 07" | 47° 33' 06" | 1001 | 3 – 8 | II | Npi | Agricultura |
| 16 | B | 15° 48' 36" | 47° 32' 54" | 959 | 3 – 8 | II | Npi | Agricultura |
| 17 | B | 15° 49' 51" | 47° 33' 11" | 914 | 8 – 20 | II | Npi | Silvicultura |
| 18 | B | 15° 50' 55" | 47° 32' 04" | 962 | 3 – 8 | II | Npi | Agricultura |
| 19 | B | 15° 51' 29" | 47° 29' 24" | 920 | 3 – 8 | II | TQdl | Agricultura |
| 20 | B | 15° 51' 40" | 47° 28' 20" | 898 | 8 – 20 | II | Npi | Silvicultura |
| 21 | C | 15° 56' 43" | 47° 57' 01" | 1074 | 8 – 20 | II | Mpa2 | Campo |
| 22 | C | 15° 57' 23" | 47° 57' 17" | 1138 | 0 – 3 | II | Mpa2 | Campo |
| 23 | C | 15° 57' 30" | 47° 56' 49" | 1102 | 3 – 8 | II | Mpa2 | Cerrado |
| 24 | C | 15° 56' 10" | 47° 55' 30" | 1070 | 3 – 8 | II | QHa | Cerrado |
| 25 | C | 15° 55' 17" | 47° 55' 38" | 1148 | 3 – 8 | II | QHa | Campo |
| 26 | C | 15° 56' 39" | 47° 54' 41" | 1094 | 3 – 8 | I | Mpa2 | Cerrado |
| 27 | C | 15° 58' 41" | 47° 57' 19" | 1199 | 3 – 8 | I | Mpa2 | Cerrado |
| 28 | C | 15° 58' 47" | 47° 56' 58" | 1197 | 0 – 3 | I | TQdl | Cerrado |
| 29 | C | 15° 58' 48" | 47° 56' 25" | 1201 | 3 – 8 | I | TQdl | Campo |
| 30 | C | 15° 58' 33" | 47° 56' 06" | 1195 | 3 – 8 | I | TQdl | Campo |
| 31 | D | 15° 42' 41" | 47° 54' 54" | 1067 | 3 – 8 | II | Mpa2 | Cerrado |
| 32 | D | 15° 43' 24" | 47° 54' 33" | 1027 | 8 – 20 | II | Mpa2 | Campo |
| 33 | D | 15° 41' 43" | 47° 54' 12" | 1059 | 8 – 20 | II | Mpa2 | Campo |
| 34 | D | 15° 42' 03" | 47° 53' 27" | 1043 | 8 – 20 | II | Mpa2 | Campo |
| 35 | D | 15° 41' 10" | 47° 51' 46" | 1226 | 0 – 3 | I | Mpa3 | Cerrado |
| 36 | D | 15° 39' 25" | 47° 54' 00" | 1276 | 0 – 3 | I | Mpa3 | Cerrado |
| 37 | D | 15° 34' 42" | 48° 00' 32" | 1277 | 3 – 8 | I | Mpa3 | Campo |
| 38 | D | 15° 36' 40" | 48° 02' 33" | 1275 | 3 – 8 | I | Mpa3 | Campo |
| 39 | D | 15° 37' 09" | 48° 03' 26" | 1281 | 0 – 3 | III | Mpa3 | Cerrado |
| 40 | D | 15° 38' 52" | 48° 04' 51" | 1249 | 3 – 8 | I | Mpa3 | Campo |

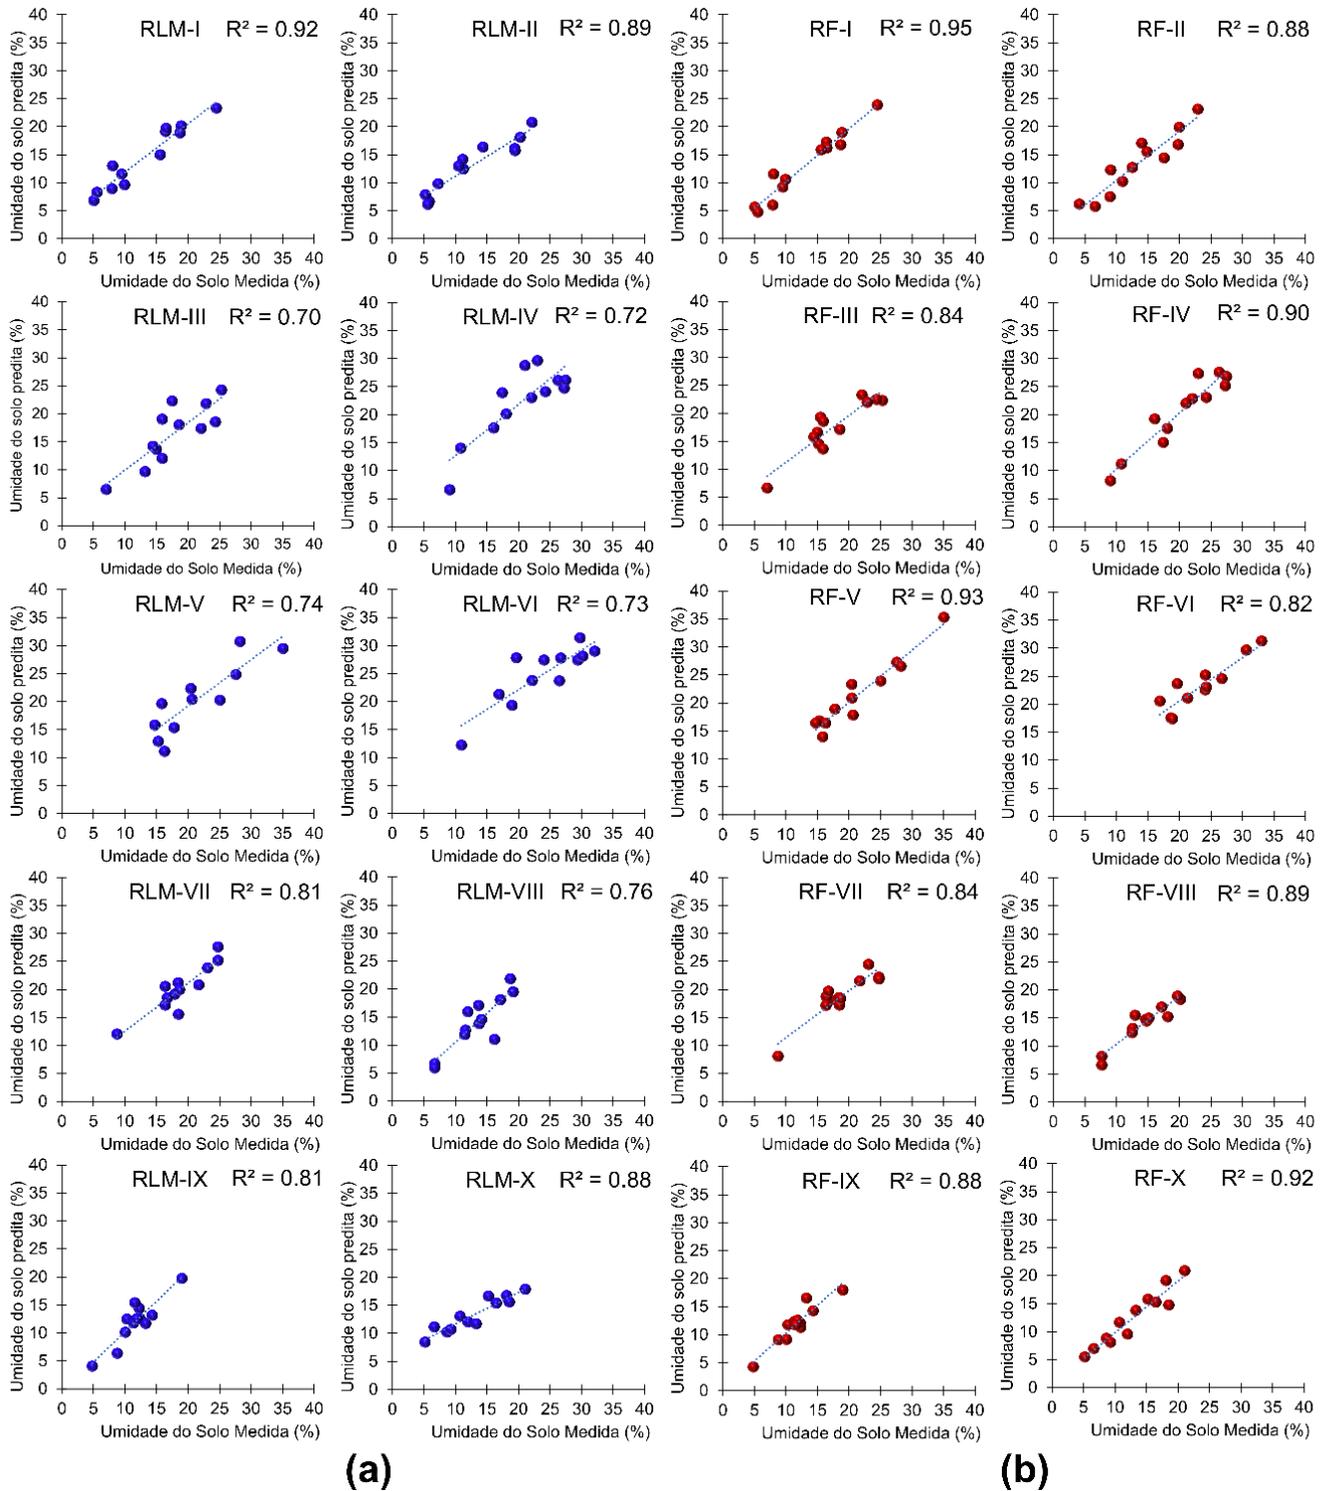
¹ Classe de declividade (TEIXEIRA et al., 2017); ² Superfície Geomorfológica (NOVAES-PINTO, 1987). Mpa3 = Quartzito, Filito, Metassiltito; Mpa4 = Quartzito, Filito, Metassiltito; Mpa2 = Metassiltito, Ardosia, Calcário; TQdl = Laterita; Npi = Siltito, Argilito, Calcário; QHa = Material mineral Aluvional.

Apêndice C8. Classes e textura dos solos estudados.

| ID | D. | Classe de solo (Santos et al., 2018) | Sigla | T. |
|----|----|---|-------|--------|
| 1 | t1 | LATOSSOLO VERMELHO-AMARELO Distrófico petroplântico | LVAc | a.a. |
| 2 | t1 | LATOSSOLO VERMELHO Distrófico típico | LVd | a. |
| 3 | t2 | LATOSSOLO VERMELHO-AMARELO Distrófico petroplântico | LVAc | a. |
| 4 | t1 | PLINTOSSOLO HÁPLICO Distrófico típico | FXd | m.a. |
| 5 | t1 | LATOSSOLO VERMELHO-AMARELO Distrófico petroplântico | LVAc | a. |
| 6 | t1 | PLINTOSSOLO PÉTRICO Concrecionário êndico | FFc | a.f. |
| 7 | t1 | NEOSSOLO QUARTZARÊNICO Órtico típico | RQo | ar. |
| 8 | t2 | PLINTOSSOLO HÁPLICO Distrófico típico | FXd | m.a. |
| 9 | t2 | LATOSSOLO VERMELHO Distrófico típico | LVd | m.a. |
| 10 | t1 | LATOSSOLO VERMELHO Distrófico típico | LVd | m.a. |
| 11 | t2 | LATOSSOLO VERMELHO-AMARELO Distrófico petroplântico | LVAc | m.a. |
| 12 | t1 | NEOSSOLO QUARTZARÊNICO Órtico típico | RQo | ar. |
| 13 | t1 | LATOSSOLO VERMELHO Distrófico típico | LVd | m.a. |
| 14 | t1 | LATOSSOLO VERMELHO-AMARELO Distrófico típico | LVAd | a.a. |
| 15 | t2 | PLINTOSSOLO PÉTRICO Concrecionário típico | FFc | m.a. |
| 16 | t1 | LATOSSOLO VERMELHO Distrófico típico | LVd | m.a. |
| 17 | t1 | NEOSSOLO REGOLÍTICO Distrófico típico | RRd | f.a.s. |
| 18 | t1 | PLINTOSSOLO PÉTRICO Concrecionário típico | FFc | m.a. |
| 19 | t1 | LATOSSOLO VERMELHO Distrófico típico | LVd | m.a. |
| 20 | t2 | NEOSSOLO REGOLÍTICO Distrófico típico | RRd | m.a. |
| 21 | t1 | PLINTOSSOLO PÉTRICO Concrecionário típico | FFc | m.a. |
| 22 | t2 | LATOSSOLO VERMELHO Distrófico típico | LVd | m.a. |
| 23 | t1 | LATOSSOLO VERMELHO-AMARELO Distrófico típico | LVAd | m.a. |
| 24 | t1 | LATOSSOLO VERMELHO Distrófico típico | LVd | m.a. |
| 25 | t2 | PLINTOSSOLO HÁPLICO Distrófico típico | FXd | m.a. |
| 26 | t1 | LATOSSOLO VERMELHO-AMARELO Distrófico petroplântico | LVAc | m.a. |
| 27 | t1 | LATOSSOLO VERMELHO Distrófico típico | LVd | f.a.a. |
| 28 | t1 | NEOSSOLO REGOLÍTICO Distrófico típico | RRd | f.a. |
| 29 | t2 | LATOSSOLO VERMELHO Distrófico típico | LVd | f.a.a. |
| 30 | t1 | PLINTOSSOLO HÁPLICO Distrófico típico | FXd | f.a. |
| 31 | t2 | LATOSSOLO VERMELHO Distrófico típico | LVd | m.a. |
| 32 | t1 | PLINTOSSOLO PÉTRICO Concrecionário típico | FFc | f.a.s. |
| 33 | t1 | NEOSSOLO REGOLÍTICO Distrófico típico | RRd | f.a.a. |
| 34 | t1 | PLINTOSSOLO PÉTRICO Concrecionário típico | FFc | f.a.s. |
| 35 | t2 | NEOSSOLO QUARTZARÊNICO Órtico típico | RQo | ar. |
| 36 | t1 | LATOSSOLO VERMELHO Distrófico típico | LVd | m.a. |
| 37 | t2 | LATOSSOLO VERMELHO Distrófico típico | LVd | m.a. |
| 38 | t1 | PLINTOSSOLO HÁPLICO Distrófico típico | FXd | a. |
| 39 | t1 | LATOSSOLO VERMELHO Distrófico típico | LVd | m.a. |
| 40 | t1 | PLINTOSSOLO HÁPLICO Distrófico típico | FXd | m.a. |

ID = Identificação do ponto; D = Tipo de dado dos modelos, t1 = dados de treinamento, t2 = dados de teste; T. = Textura; aa = argiloarenosa; a = argilosa; ma = muito argilosa; af = areia franca; ar = areia; fas = franco-argilo-siltosa; faa = franco argilo arenosa; fa = franco-argilosa

Apêndice C9. Gráfico bidirecional dos valores de umidade do solo medida e predita pelos métodos: (a) regressão linear múltipla (RLM) e (b) *Random Forest* (RF).



Apêndice D1. Relatório fotográfico dos pontos de amostragem do setor A (Embrapa Cerrados)



Perfil 1. LATOSSOLO VERMELHO-AMARELO Distrófico petroplíntico – LVAc



Perfil 2. LATOSSOLO VERMELHO Distrófico típico - LVd



Perfil 3. LATOSSOLO VERMELHO-AMARELO Distrófico petroplíntico - LVAc



Perfil 4. PLINTOSSOLO HÁPLICO Distrófico típico – FXd



Perfil 5. LATOSSOLO VERMELHO-AMARELO Distrófico petroplíntico – LVAc



Perfil 6. PLINTOSSOLO PÉTRICO Concrecionário êndico - FFc



Perfil 7. NEOSSOLO QUARTZARÊNICO Órtico típico - RQo



Perfil 8. PLINTOSSOLO HÁPLICO Distrófico típico - FXd



Perfil 9. LATOSSOLO VERMELHO Distrófico típico - LVd



Perfil 10. LATOSSOLO VERMELHO Distrófico típico - LVd

Apêndice D2. Relatório fotográfico dos pontos de amostragem do setor B – PAD/DF



Perfil 11. LATOSSOLO VERMELHO-AMARELO Distrófico petroplântico - LVAc



Perfil 12. NEOSSOLO QUARTZARÊNICO Órtico típico - RQo



Perfil 13. LATOSSOLO VERMELHO Distrófico típico - LVd



Perfil 14. LATOSSOLO VERMELHO-AMARELO Distrófico típico - LVAd



Perfil 15. PLINTOSSOLO PÉTRICO Concrecionário típico – FFc



Perfil 16. LATOSSOLO VERMELHO Distrófico típico - LVd



Perfil 17. NEOSSOLO REGOLÍTICO Distrófico típico - RRd



Perfil 18. PLINTOSSOLO PÉTRICO Concrecionário típico - FFc



Perfil 19. LATOSSOLO VERMELHO Distrófico típico - LVd



Perfil 20. NEOSSOLO REGOLÍTICO Distrófico típico - RRd

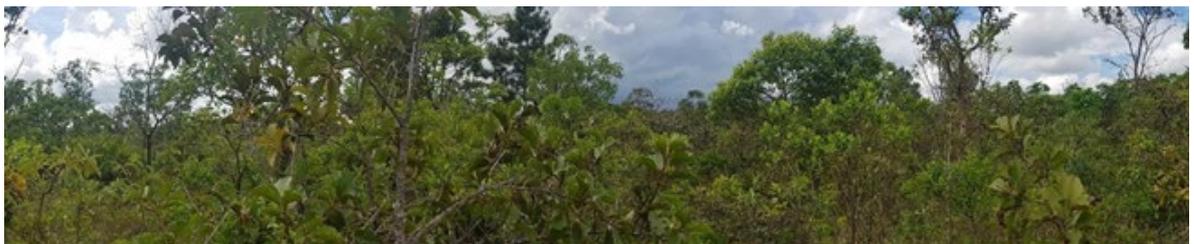
Apêndice D3. Relatório fotográfico dos pontos de amostragem do setor C – Fazenda Água Limpa (FAV/UnB)



Perfil 21. PLINTOSSOLO PÉTRICO Concrecionário típico - FFc



Perfil 22. LATOSSOLO VERMELHO Distrófico típico – LVd



Perfil 23. LATOSSOLO VERMELHO-AMARELO Distrófico típico – LVAd



Perfil 24. LATOSSOLO VERMELHO Distrófico típico – LVAd



Perfil 25. PLINTOSSOLO HÁPLICO Distrófico típico – FXd



Perfil 26. LATOSSOLO VERMELHO-AMARELO Distrófico petroplíntico - LVAc



Perfil 27. LATOSSOLO VERMELHO Distrófico típico - LVd



Perfil 28. NEOSSOLO REGOLÍTICO Distrófico típico - RRd



Perfil 29. LATOSSOLO VERMELHO Distrófico típico - LVd



Perfil 30. PLINTOSSOLO HÁPLICO Distrófico típico - FXd

Apêndice D4. Relatório fotográfico dos pontos de amostragem do setor D – Parque Nacional de Brasília



Perfil 31. LATOSSOLO VERMELHO Distrófico típico – LVd



Perfil 32. PLINTOSSOLO PÉTRICO Concrecionário típico – FFc



Perfil 33. NEOSSOLO REGOLÍTICO Distrófico típico – RRd



Perfil 34. PLINTOSSOLO PÉTRICO Concrecionário típico - FFc



Perfil 35. NEOSSOLO QUARTZARÊNICO Órtico típico – Rqo



Perfil 36. LATOSSOLO VERMELHO Distrófico típico - LVd



Perfil 37. LATOSSOLO VERMELHO Distrófico típico - LVd



Perfil 38. PLINTOSSOLO HÁPLICO Distrófico típico - FXd

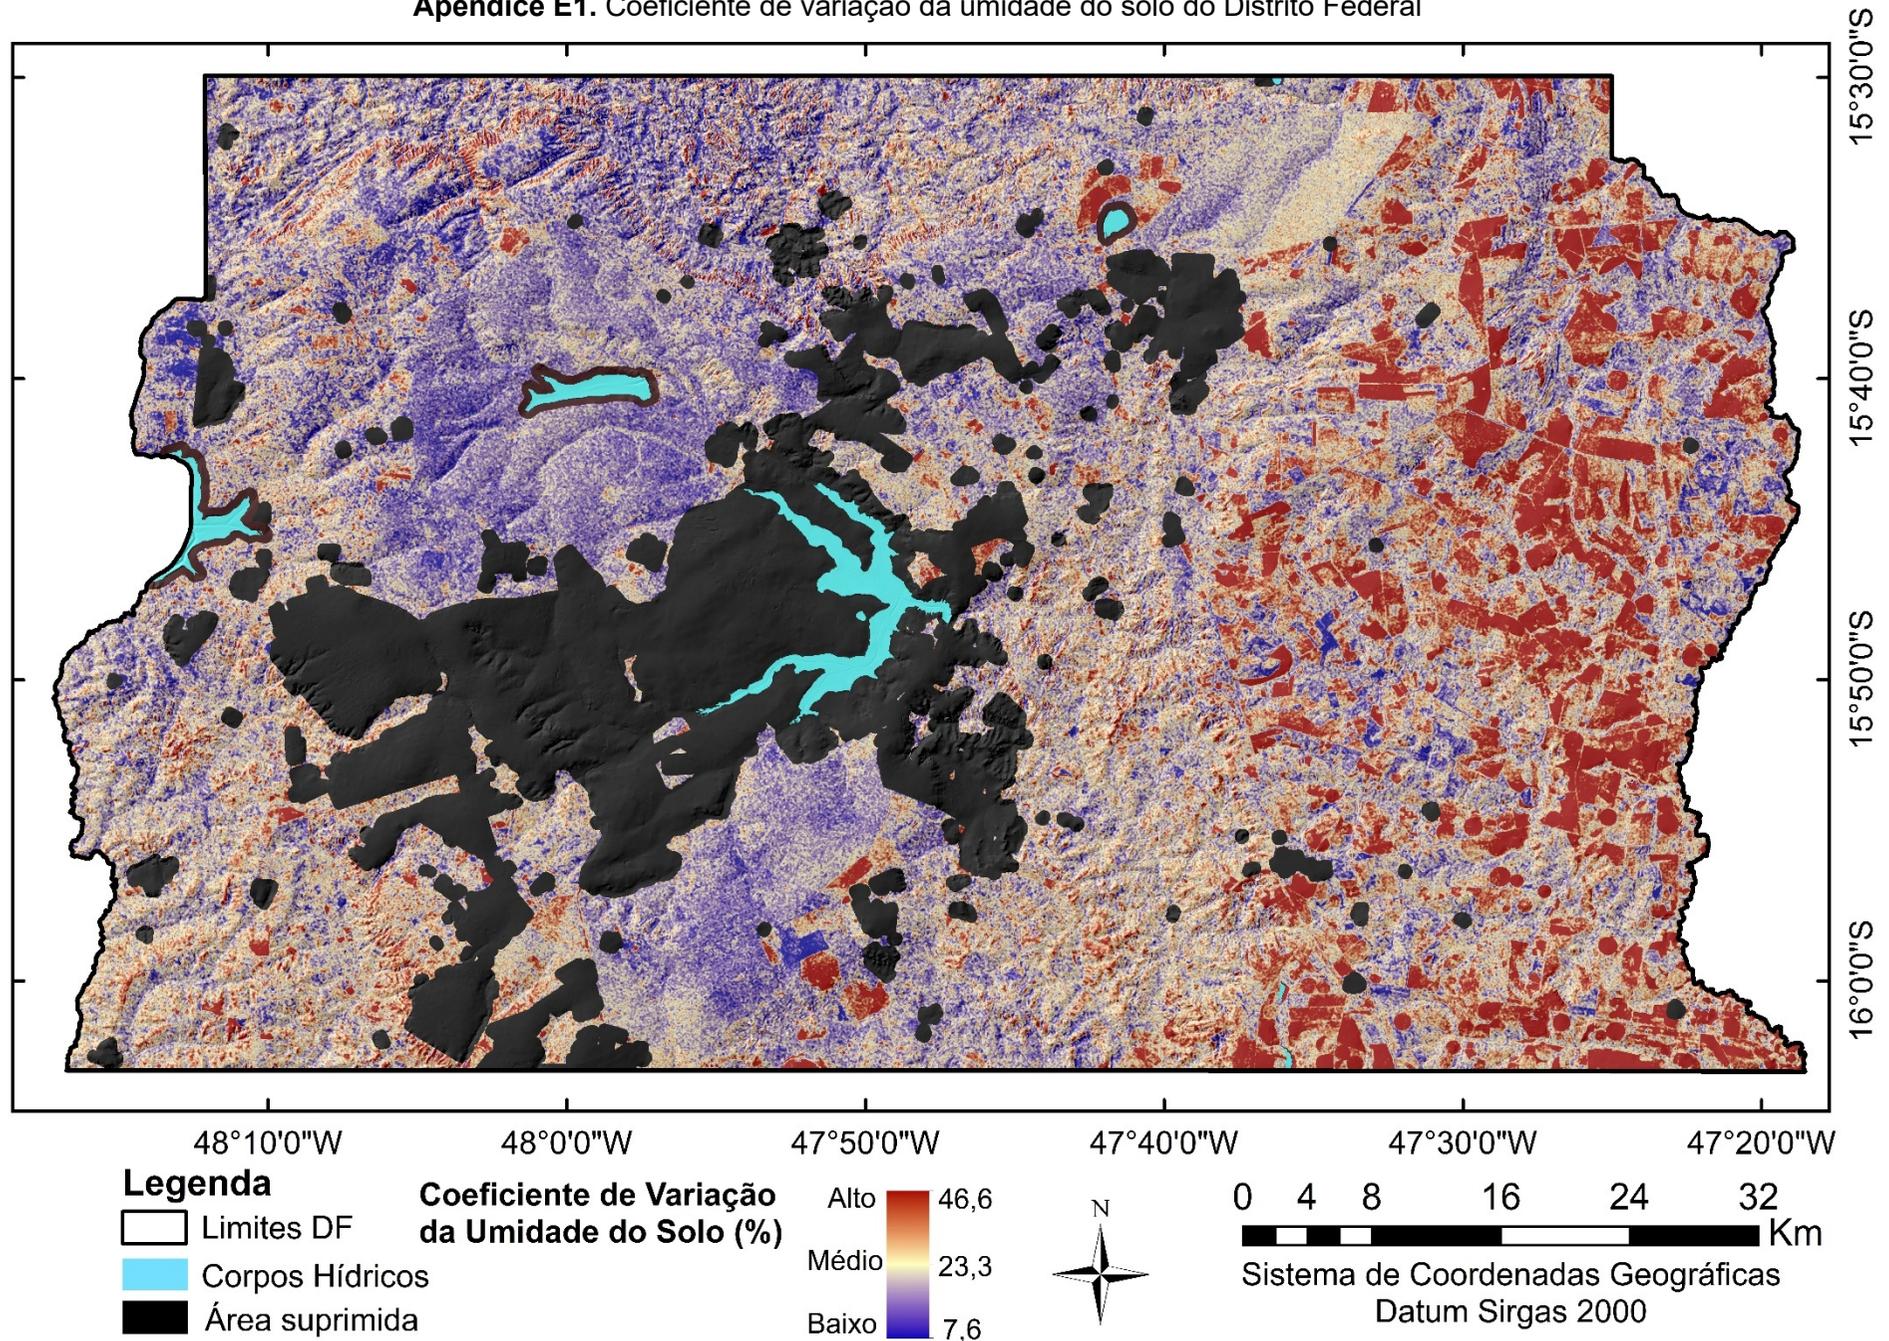


Perfil 39. LATOSSOLO VERMELHO Distrófico típico - LVd



Perfil 40. PLINTOSSOLO HÁPLICO Distrófico típico - FXd

Apêndice E1. Coeficiente de variação da umidade do solo do Distrito Federal



Apêndice E2. Índice relativo de umidade do solo do Distrito Federal

