

IDENTIFICAÇÃO DE DIFERENTES TIPOS DE COBERTURAS VEGETAIS DO DISTRITO FEDERAL (DF) A PARTIR DE DADOS DO SATÉLITE PLANETSCOPE

Giancarlo Brugnara Chelotti¹
Edson Eyji Sano²

Resumo: O Cerrado do Distrito Federal (DF) sofre com o processo de fragmentação. O lançamento dos nanosatélites *PlanetScope* representa uma oportunidade de levar o monitoramento ambiental desse bioma a um novo patamar. Nesse estudo, utilizamos mosaicos mensais das estações seca e chuvosa e aplicamos o método de classificação Random Forest. As áreas de treinamento foram coletadas em campo com o uso de uma Aeronave Remotamente Pilotada (RPA). Os resultados mostraram alta precisão na identificação de diferentes tipos de cobertura vegetal (índice Kappa $\geq 0,835$ e índice de similaridade 0,901). Os modelos com mais variáveis apresentaram maior precisão e as imagens classificadas conseguiram captar mudanças na cobertura do solo relacionadas à dinâmica agrícola. Além disso, a importância de cada banda no resultado das classificações pôde ser analisada.

Palavras-chave: Vegetação. Classificação. Alta resolução. Aprendizado de Máquina.

IDENTIFICATION OF DIFFERENT TYPES OF VEGETATION FEATURES IN DISTRITO FEDERAL (DF), BRAZIL, USING PLANETSCOPE SATELLITE DATA

Abstract: Resumo: The Brazilian Savanna located in the Distrito Federal (DF) suffer from the fragmentation process. The launch of the PlanetScope nanosatellites represents an opportunity to take the environmental monitoring of this biome to a new level. In this study, we used monthly mosaics of the dry and rainy seasons and applied the Random Forest classification method. The training areas were collected in field using a Remotely Piloted Aircraft (RPA). The results showed high accuracy in identifying several vegetation types (Kappa index ≥ 0.835 and similarity index 0.901). Models with more variables showed greater accuracy and the classified images were able to capture sazonal changes in land cover related to agricultural dynamics. In addition, the importance of each band in the result of the classifications could be analyzed.

Keywords: Vegetation. Classification. High resolution. Machine Learning.

IDENTIFICACIÓN DE DIFERENTES TIPOS DE COBERTURAS VEGETALES DEL DISTRITO FEDERAL, BRAZIL, A PARTIR DE DATOS SATELITAL PLANETSCOPE

Resumen: El Cerrado, la sabana brasileña, sufre el proceso de fragmentación en el Distrito Federal (DF). El lanzamiento de los nanosatélites PlanetScope representa una oportunidad para llevar el monitoreo ambiental de este bioma a un nuevo nivel. En este estudio, utilizamos mosaicos mensuales de las estaciones seca y lluviosa y

¹ Universidade de Brasília, Programa de Pós-Graduação em Ciências Ambientais, Planaltina-DF, Brasil, giancarlo.chelotti@gmail.com, <https://orcid.org/0000-0003-0715-1306>

² Embrapa, Embrapa Cerrados, Planaltina-DF, Brasil, edson.sano@gmail.com, <https://orcid.org/0000-0003-0715-1306>

aplicamos el método de clasificación Random Forest. Las áreas de entrenamiento se recogieron en campo utilizando una Aeronave Pilotada Remotamente (RPA). Los resultados mostraron alta precisión en la identificación de diferentes tipos de cobertura vegetal (índice Kappa $\geq 0,835$ y índice de similitud 0,901). Los modelos con más variables mostraron mayor precisión y las imágenes clasificadas pudieron capturar cambios en la cobertura del suelo relacionados con la dinámica agrícola. También se pudo analizar la importancia de cada banda en el resultado de las clasificaciones.

Palabras clave: Vegetación. Clasificación. Alta resolución. Aprendizaje automático.

Introdução

O Cerrado brasileiro é o segundo maior bioma do país em área e em biodiversidade, correspondendo a cerca de 23% do território, com ocorrência em dezessete estados. Sua vegetação apresenta diversas fisionomias que podem ser agrupadas em formações florestais, savânicas e campestres (RIBEIRO e WALTER, 2008), resultantes da diversidade de solos, de topografia e de climas dessa extensa região. Suas características climáticas são peculiares, com duas estações bem definidas: uma chuvosa, de outubro a abril, e outra seca, de maio a setembro, as quais afetam significativamente o aspecto da paisagem ao longo do ano (SILVA et al., 2008).

A grande expansão da população sobre esse bioma tem acelerado o processo de fragmentação da vegetação, gerando inúmeros problemas ambientais (AQUINO e MIRANDA, 2008). Segundo os dados de 2020 do Projeto TerraClass Cerrado (MMA, 2020), menos da metade da área do bioma ainda mantém vegetação natural primária: 29,3% estão ocupadas por pastagens e 15,9% por atividades agrícolas. O restante está dividido em outras classes de uso e cobertura da terra, como a vegetação natural secundária, as áreas urbanizadas e os corpos d'água.

Em razão disso, o monitoramento das alterações no solo se torna cada vez mais necessário. O conhecimento sólido sobre a dinâmica da paisagem é essencial para o desenvolvimento de planos de manejo e conservação de ecossistemas e seus serviços tanto em pequena quanto em larga escala (GARCIA e BALLESTER, 2016). Nesse sentido, diversos municípios brasileiros começaram a reconhecer os benefícios do uso da geoinformação como ferramenta para melhorar a gestão do seu território (STASSUN e PRADO FILHO, 2012). Apesar disso, o monitoramento tradicional do uso da terra usualmente retrata apenas a situação pretérita das

idades, não sendo capaz de retratar a dinâmica da evolução da ocupação, tampouco auxiliar na previsão de como essa expansão ocorrerá no futuro (CASTRO et al., 2019). Recentemente, foram observados avanços significativos na automação de mapeamentos por imagens de sensoriamento remoto (SRIVASTAVA et al., 2019).

Um exemplo disso é o lançamento da constelação de nanossatélites PlanetScope (PS) que possuem resolução temporal de aproximadamente um dia e resolução espacial próxima de três metros, permitindo a aquisição de um número considerável de imagens sem cobertura de nuvens ao longo do ano (PLANET, 2022). Os mosaicos mensais produzidos a partir de imagens PS divulgados pela Iniciativa Internacional do Clima e Florestas da Noruega (NICFI, 2021) são potenciais candidatos para o monitoramento mais eficiente da paisagem, uma vez que esses mosaicos são gerados a partir de imagens com as melhores qualidades radiométricas captadas dentro de um determinado mês em termos de cobertura de nuvens e ângulo de visada em relação a nadir (PANDEY et al., 2021).

Além da melhora na obtenção de dados de sensoriamento remoto, o processamento e classificação desses dados também têm avançado, principalmente com o uso de técnicas de aprendizagem de máquina (MACARRINGUE et al., 2022). Porém, as informações de sensoriamento remoto orbital, por si só, são insuficientes para descrever o uso da terra, necessitando de incorporação de fontes de dados complementares (SRIVASTAVA et al., 2019).

As imagens produzidas por Aeronaves Remotamente Pilotadas (RPA) têm fornecido avanços importantes no monitoramento da paisagem (SINGH e FRAIZER, 2018; PARK, et al., 2019). As imagens de RPA podem ser utilizadas como amostras georreferenciadas de classes de uso e cobertura da terra tanto para treinamento quanto para avaliação de métodos de classificação (HORNING et al., 2020).

O Distrito Federal (DF) apresenta uma extensão relativamente grande de áreas urbanas consolidadas e em expansão, além de grandes extensões de áreas agrícolas e de vegetação natural, com suas diversas fitofisionomias (RIBEIRO e WALTER, 2008; CODEPLAN, 2017; NEVES et al., 2017). Esse mosaico complexo de diferentes coberturas se torna uma paisagem ideal para testar o potencial de novas geotecnologias no monitoramento ambiental.

O objetivo deste trabalho é identificar diferentes feições naturais do DF, além de feições decorrentes de ações antrópicas tanto na época chuvosa quanto na

época seca por meio de mosaicos mensais do satélite PS disponibilizados pela NICFI.

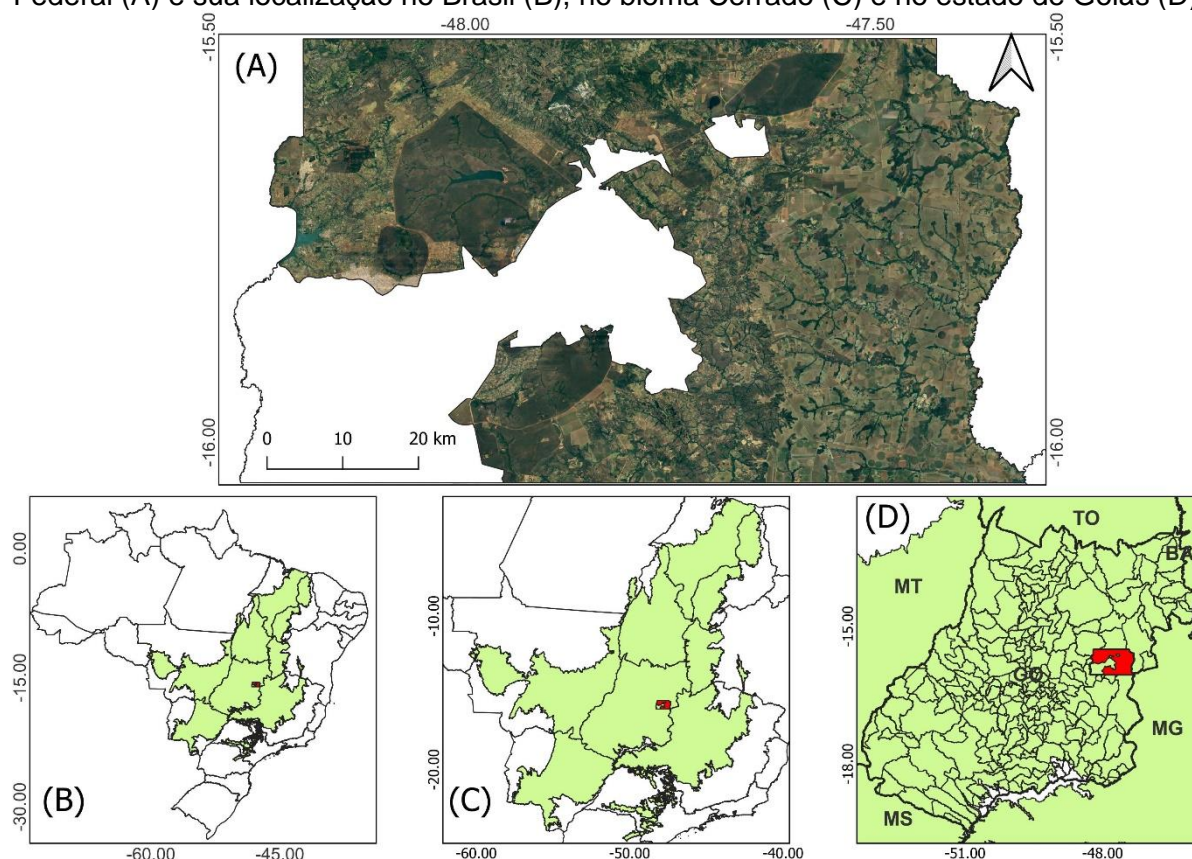
Material e Métodos

Área de Estudo

O DF localiza-se entre os paralelos 15° 30' S e 16° 03' S e os meridianos 47° 25' O e 48° 12' O, ocupando uma área de 5.783 km² e englobando sete bacias hidrográficas que abastecem três regiões hidrográficas brasileiras: Paraná, São Francisco e Tocantins-Araguaia. Sua rede de drenagem é composta de rios, em sua maioria, perenes, havendo ainda três grandes reservatórios artificiais: Descoberto, Paranoá e Santa Maria (CODEPLAN, 2017). O DF está inserido ainda na ecorregião do Planalto Central, caracterizada por acentuada complexidade geomorfológica, com altitudes variando entre 950 m ao longo dos rios principais e 1.400 m no Planalto do Distrito Federal (NEVES *et al.*, 2018). O clima predominante é o tropical sazonal Aw, segundo o sistema de classificação de Köppen, de verão chuvoso e inverno seco, com temperatura média anual de 22,5 °C e precipitação média anual de 1.200 mm a 1.800 mm (ALVARES *et al.*, 2014). No DF, ocorrem todas as fitofisionomias típicas do bioma Cerrado (RIBEIRO e WALTER, 2008).

Originalmente planejado para 700 mil habitantes, o DF possui atualmente quase três milhões de habitantes e sofre com os mesmos problemas presentes em outras grandes metrópoles, tais como crescimento desordenado, favelização, poluição ambiental, fragmentação da vegetação, desabastecimento de água e problemas de mobilidade (NUNES e ROIG, 2015; REQUIA *et al.*, 2016; CHELOTTI *et al.*, 2019; CODEPLAN, 2019). Em 2015, menos de 50% do território do DF correspondia a áreas naturais (NEVES *et al.*, 2018). Em 2019, sua mancha urbana representava mais de 12% do território (CHELOTTI e SANO, 2021), sendo o restante ocupado por atividades rurais.

Figura 1 - Mosaico de imagens *PlanetScope* de abril de 2021 da ZEEDPSE no Distrito Federal (A) e sua localização no Brasil (B), no bioma Cerrado (C) e no estado de Goiás (D).



Elaborada pelos autores

Entre os instrumentos de planejamento e gestão territorial do DF, destaca-se o Zoneamento Ecológico-Econômico (ZEE/DF), cujas diretrizes e critérios passam a orientar as políticas públicas distritais voltadas ao desenvolvimento socioeconômico sustentável e à melhoria da qualidade de vida da população (DISTRITO FEDERAL, 2019). Essa norma dividiu o DF em duas grandes zonas: Zona Ecológico-Econômica de Dinamização Produtiva com Equidade (ZEEDPE), onde se concentram as áreas e atividades urbanas, e a Zona Ecológico-Econômica de Diversificação Produtiva e Serviços Ecosistêmicos (ZEEDPSE) (Figura 1). Essa última é destinada a assegurar atividades produtivas que favoreçam a proteção do meio ambiente, a conservação do Cerrado remanescente e a manutenção do ciclo hidrológico. Dessa forma, a expansão urbana nessa zona não é desejável. Para atingir o objetivo do presente estudo, de avaliar o potencial de detecção de feições tanto naturais quanto antrópicas para contribuir com o monitoramento, controle e fiscalização com vistas ao combate ao parcelamento irregular do solo, previsto no ZEE/DF, foi selecionada a ZEEDPSE como a área de estudo neste capítulo.


Aquisição de Dados

Coletas de Campo

Para avaliar o potencial de identificação de classes de uso e cobertura de terras do bioma Cerrado, foram realizadas campanhas de campo entre os meses de abril e setembro de 2021, período correspondente ao de menor cobertura de nuvens no DF (NASCIMENTO, 2017) e que garante a captação da variabilidade no comportamento espectral dos alvos nos períodos chuvoso e seco. Foram visitados 130 locais, onde foram coletados 1.460 pontos de amostragem que foram previamente definidos com base na interpretação visual de mosaicos de imagens fornecidos pela plataforma *Google Earth TM* (GOOGLE, s.d.). Para cada local, foi obtida uma foto a nadir por meio de uma câmera digital RGB embarcada no RPA *Phantom Mavic Mini 2* a uma altitude de 100 m do solo. A Figura 2 apresenta exemplos de fotos tiradas para as classes de vegetação analisadas neste trabalho. Considerando-se o sensor e lente do RPA (DJI, 2021), a distância amostral do solo (GSD) foi de 4,28 cm/pixel. Os metadados de cada foto contêm as coordenadas geográficas do centroide da imagem.

A Tabela 1 apresenta o número de amostras para cada classe. Essas quantidades foram definidas com base nas variações espectrais dos locais em função do clima e da cobertura do solo, bem como na dificuldade de acesso e comportamento espectral (classes com mais chance de confusão foram amostradas em maior número). Classes sem alteração do comportamento espectral em função da sazonalidade climática (área urbana e água, por exemplo) foram amostradas em menor número.

Figura 2 - Fotografias tiradas por câmera embarcada em RPA a 100 m de altura sobre áreas representativa de reflorestamento (a), formação florestal nativa (b), formação savânica nativa (c), cultura agrícola (d) tiradas em 8/5/21; formação campestre nativa (e), e pastagem (f) tirada em 3/6/21.



Organizada pelos autores

Tabela 1 - Quantidade de amostras por classe de cobertura da terra

Classe	Amostras
Água	60
Área urbana	100
Cultura agrícola	200
Pastagem	200
Reflorestamento	120
Solo exposto	200
Vegetação nativa - campestre	130
Vegetação nativa - florestal	250
Vegetação nativa – savânica	200
TOTAL	1.460

Imagens do satélite *PlanetScope*

Foram utilizados os mosaicos PS disponibilizados pelo NCIFI para *download* na plataforma de computação em nuvem *Google Earth Engine* (GORELICK *et al.*, 2017). (e) (f) (a) (b) (c) (d) 60 Esses mosaicos são preparados principalmente para

monitorar o desmatamento e a degradação florestal e cobrem uma área limitada entre 30° de latitude norte e 30° de latitude sul, ou seja, a região tropical do mundo. Eles são compostos pelas bandas espectrais no azul (B) (0,455 – 0,515 µm), verde (G) (0,500 – 0,590 µm), vermelho (R) (0,590 – 0,670 µm) e infravermelho próximo (NIR) (0,780 – 0,860 µm) e resolução espacial de 4,77 m (PANDEY *et al.*, 2021). Os produtos são baseados nos dados de reflectância de superfície que são corrigidos atmosféricamente e normalizados para reduzir a variabilidade cena a cena. As linhas de conexão de imagens que compõem um mosaico também são suavizadas para minimizar as bordas das cenas. De acordo com Pandey *et al.* (2021), os produtos de reflectância de superfície normalizados do PS funcionam bem para aplicações de aprendizagem de máquina.

Foram gerados dois mosaicos da área de estudo, correspondentes aos meses de abril e agosto de 2021. Esses mosaicos foram ainda convertidos em Índice de Vegetação por Diferença Normalizada (NDVI) (Eq. 1). NDVI é o índice de vegetação mais popular na literatura e retrata principalmente as diferenças nas atividades fotossintéticas das plantas (TUCKER, 1979).

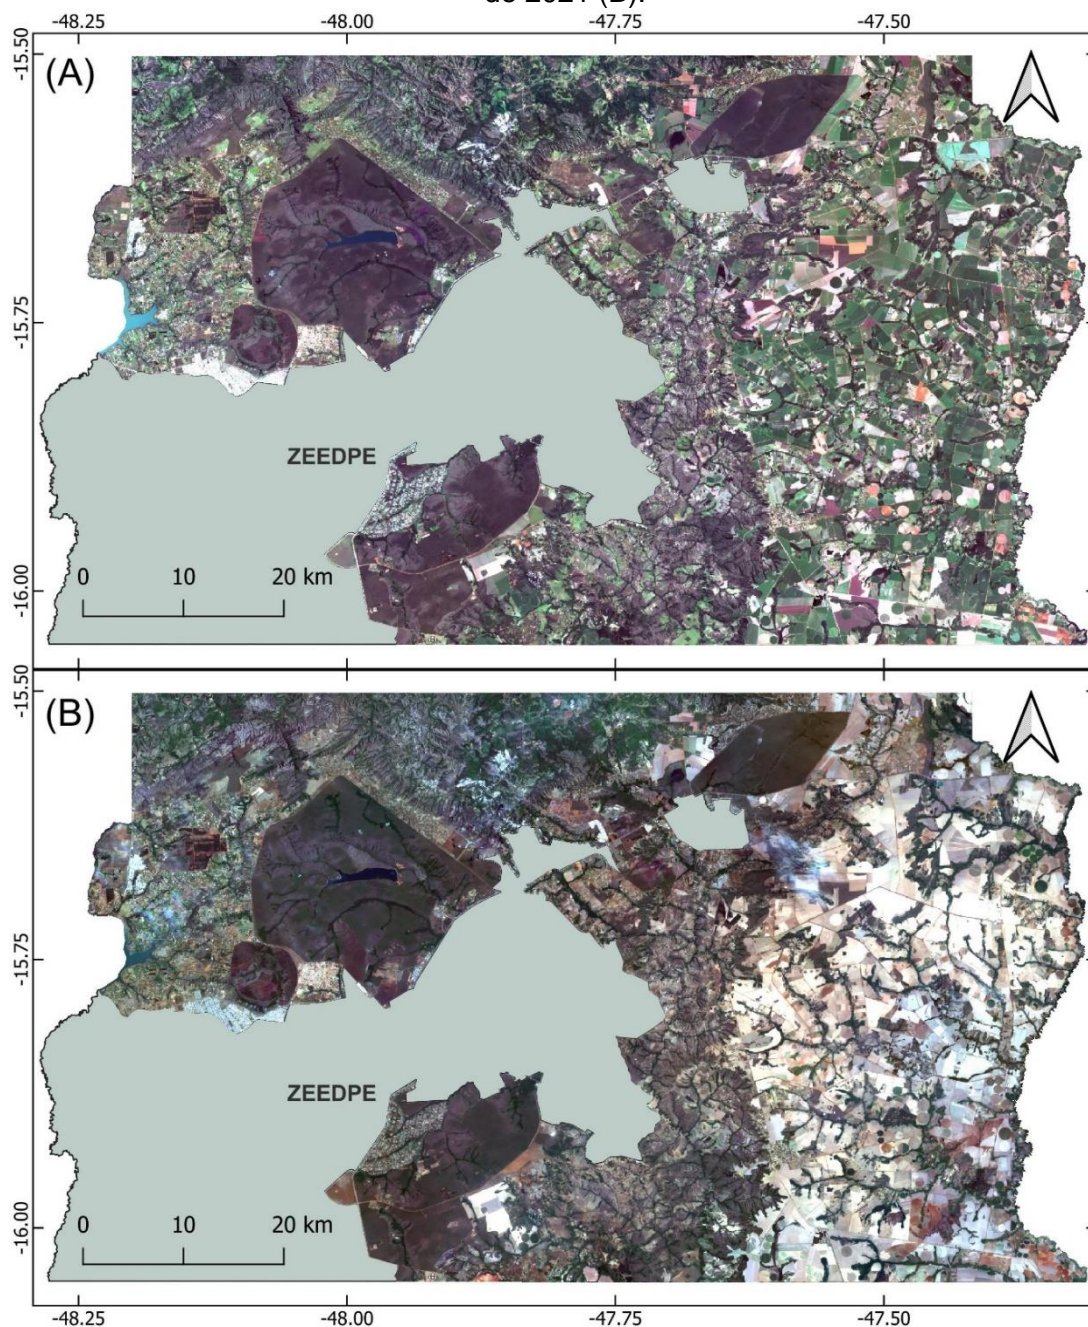
$$NDVI = \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red}} \quad (1)$$

Onde ρ é a reflectância de superfície das bandas espectrais do NIR (banda 4) e do vermelho (banda 3), respectivamente.

A partir desses produtos, foram gerados outros conjuntos de imagens por meio de empilhamento de bandas. Dessa forma, foram produzidos um total de seis modelos:

- Modelo 1: bandas R, G, B e NIR de abril de 2021 (quatro bandas)
- Modelo 2: bandas R, G, B, NIR e NDVI de abril de 2021 (cinco bandas)
- Modelo 3: bandas R, G, B e NIR de agosto de 2021 (quatro bandas)
- Modelo 4: bandas R, G, B, NIR e NDVI de agosto de 2021 (cinco bandas)
- Modelo 5: bandas R, G, B e NIR de abril de 2021 e bandas R, G, B e NIR de agosto de 2021 (oito bandas)
- Modelo 6: bandas R, G, B, NIR e NDVI de abril de 2021 e bandas R, G, B, NIR e NDVI de agosto de 2021 (dez bandas)

Figura 3 - Mosaicos mensais de composições coloridas RGB das bandas 3 (vermelho), 2 (verde) e 1 (azul) do satélite *PlanetScope* da área de estudo de abril de 2021 (A) e agosto de 2021 (B).



Elaborada pelos autores

Para fins ilustrativos, a Figura 3 mostra as composições RGB de mosaicos PS da área de estudo (bandas 3, 2 e 1) de abril e agosto de 2021. Na composição de abril (final da estação chuvosa), as áreas esverdeadas estão ocupadas principalmente por vegetação nativa, florestas plantadas e culturas anuais, enquanto as áreas amareladas correspondem, principalmente, às pastagens cultivadas e as áreas avermelhadas, aos locais com solo exposto. Em agosto (estação seca), as áreas com cor esverdeada são reduzidas em relação à imagem anterior, pois boa parte das áreas cultivadas estão sem plantio ou com culturas de sequeiro que

apresentam coloração amarelada. Percebe-se ainda a ocorrência de mais áreas avermelhadas onde havia cultura plantada em comparação à imagem anterior. A época de plantio da safra principal no DF é entre outubro e novembro, com colheita entre abril e maio. Na entressafra, entre maio e outubro, nem todas as áreas são cultivadas em razão da escassez hídrica (BOLFE *et al.*, 2020).

Todos os modelos foram submetidos à classificação pelo método não-paramétrico *Random Forest* (RF), com uma proporção de subconjunto de treinamento e teste de 60%/40%, utilizando-se a ferramenta *Google Earth Engine* (GORELICK *et al.*, 2017). O método de RF foi proposto por Breiman (2001) para melhorar a precisão da classificação de imagens por meio de várias combinações de subconjuntos aleatórios de árvores. Cada árvore contribui com um voto e a classificação final é feita considerando os votos de todas as árvores da floresta. Testes preliminares com 100, 300, 500 e 1.000 árvores mostraram que a maior quantidade de árvores resultou em um melhor resultado de classificação.

Avaliação estatística dos resultados

Usando o conjunto de dados de validação, obtivemos a matriz de confusão e as seguintes métricas: acurácia global, índice Kappa (COHEN, 1960) e medida da importância das variáveis (VI – *variable importance*) (BREIMAN, 2001) de cada classificação.

O valor mínimo de acurácia para que os resultados de um mapa classificado baseado em sensoriamento remoto sejam considerados válidos pela comunidade de sensoriamento remoto é de 85% (LILLESAND *et al.*, 2015; FEIZIZADEH *et al.*, 2022). A estatística *Kappa* é um método que permite analisar de forma comparativa os resultados das classificações de imagens de sensoriamento remoto (LANDIS e KOCH, 1977). Por esse índice, pode-se mensurar a qualidade de um mapa temático tendo como referência 64 outro mapa temático (NERY *et al.*, 2013). Dessa forma, também é possível comparar a similaridade entre duas classificações por meio desse método.

Em uma classificação RF, para um número fixo de árvores, uma variável com uma pontuação de importância maior em relação a outras variáveis indica que essa variável é mais importante para a classificação. Portanto, em vez de estimar uma relação específica entre as variáveis independentes e a resposta como na

modelagem de dados, as medidas de VI são estatísticas robustas que indicam a importância de casa variável na classificação RF (ARCHER e KIMES, 2008).

Além do índice *Kappa*, as classificações ainda foram analisadas quanto às suas diferenças entre si por meio de álgebra de mapas, comparando-se pixel a pixel. Para isso, foi calculada a similaridade entre classificações por meio da Eq. 2.

$$SC = \frac{\sum p_i}{P} \times 100 \quad (2)$$

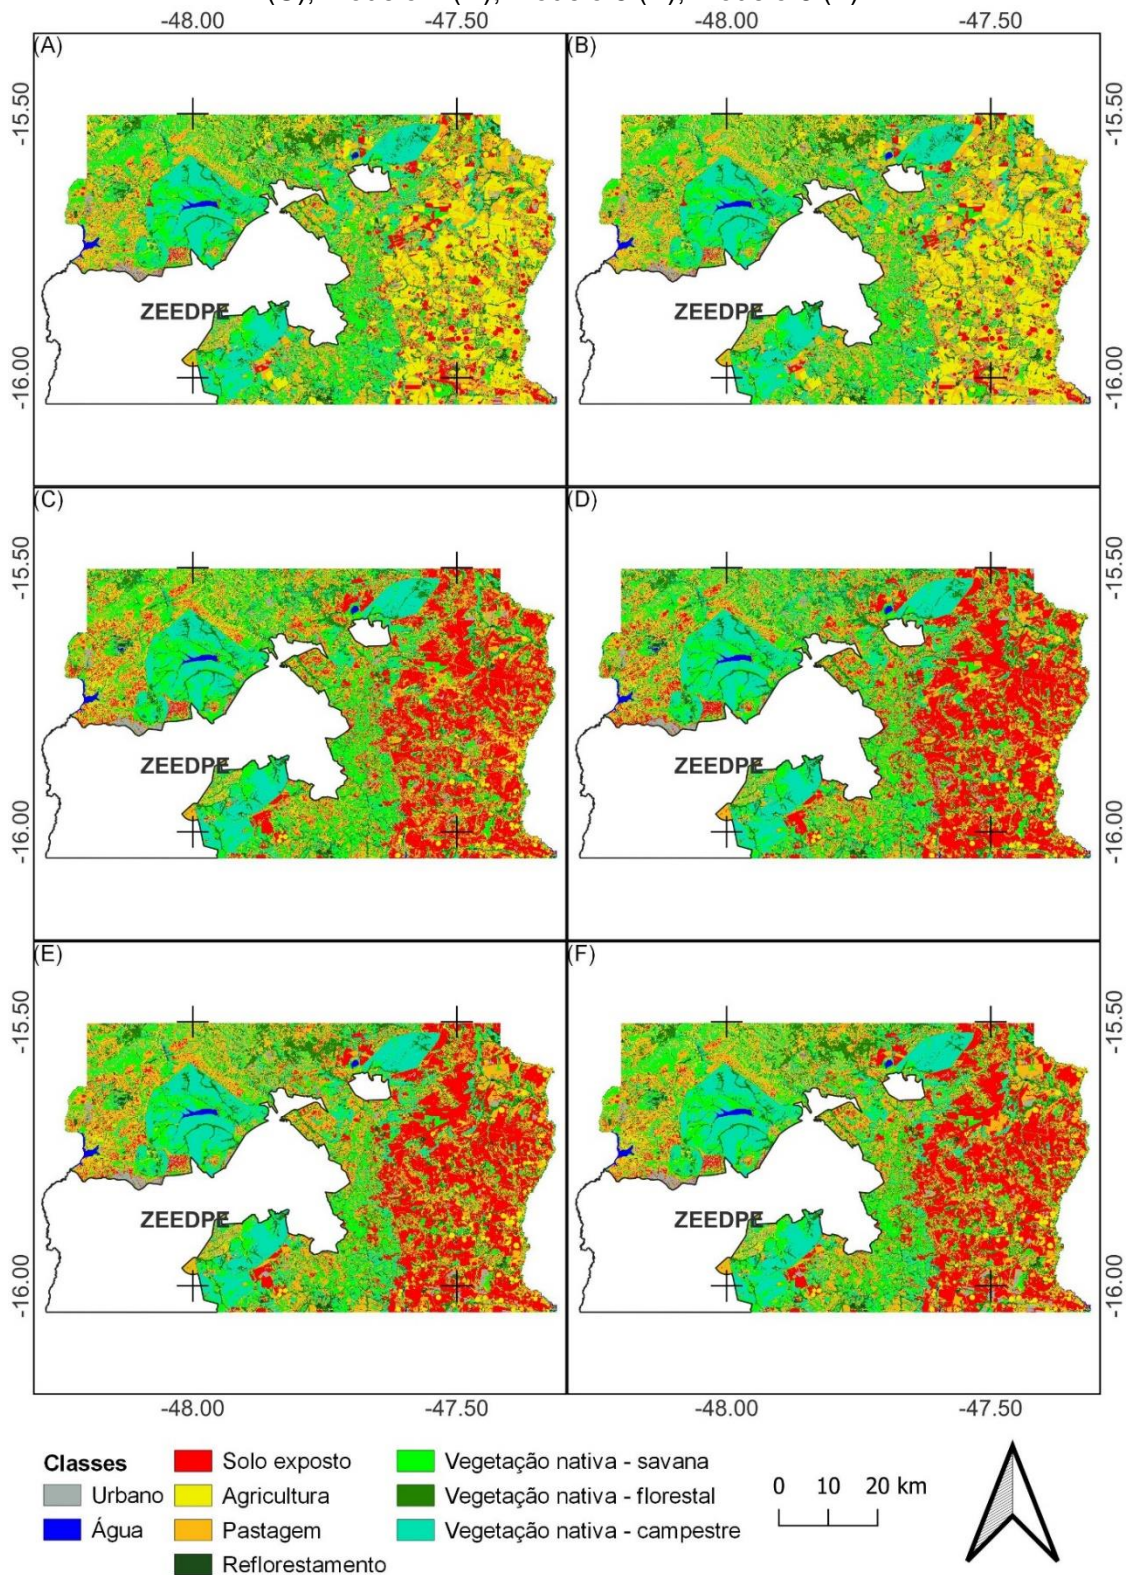
Onde SC é a similaridade das classificações, p_i são os pixels classificados de forma diferente entre dois mapas, e P é o total de pixels da classificação.

Também foram gerados mapas de calor para cada comparação no intuito de espacializar as diferenças e identificar não só as classes, mas também as regiões com maior dificuldade de classificação.

Resultados

A Figura 4 apresenta os seis mapas de classificação RF gerados nesse estudo. É possível observar que os mapas que possuem apenas as bandas de abril de 2021 possuem mais áreas classificadas como “cultura agrícola” e os mapas que possuem apenas as bandas de agosto de 2021 possuem mais áreas classificadas como “solo exposto”.

Figura 4 - Classificações das imagens PS a partir do Modelo 1 (A); Modelo 2 (B); Modelo 3 (C); Modelo 4 (D); Modelo 5 (E); Modelo 6 (F).



Elaborada pelos autores

Já os mapas que foram gerados a partir do empilhamento das bandas das duas datas apresentaram maior similaridade com os mapas de agosto de 2021. A inclusão do NDVI pouco interferiu no resultado das classificações. As demais

classes pouco variaram entre as diferentes classificações. A Tabela 2 apresenta o percentual de área ocupada por cada classe em cada classificação realizada.

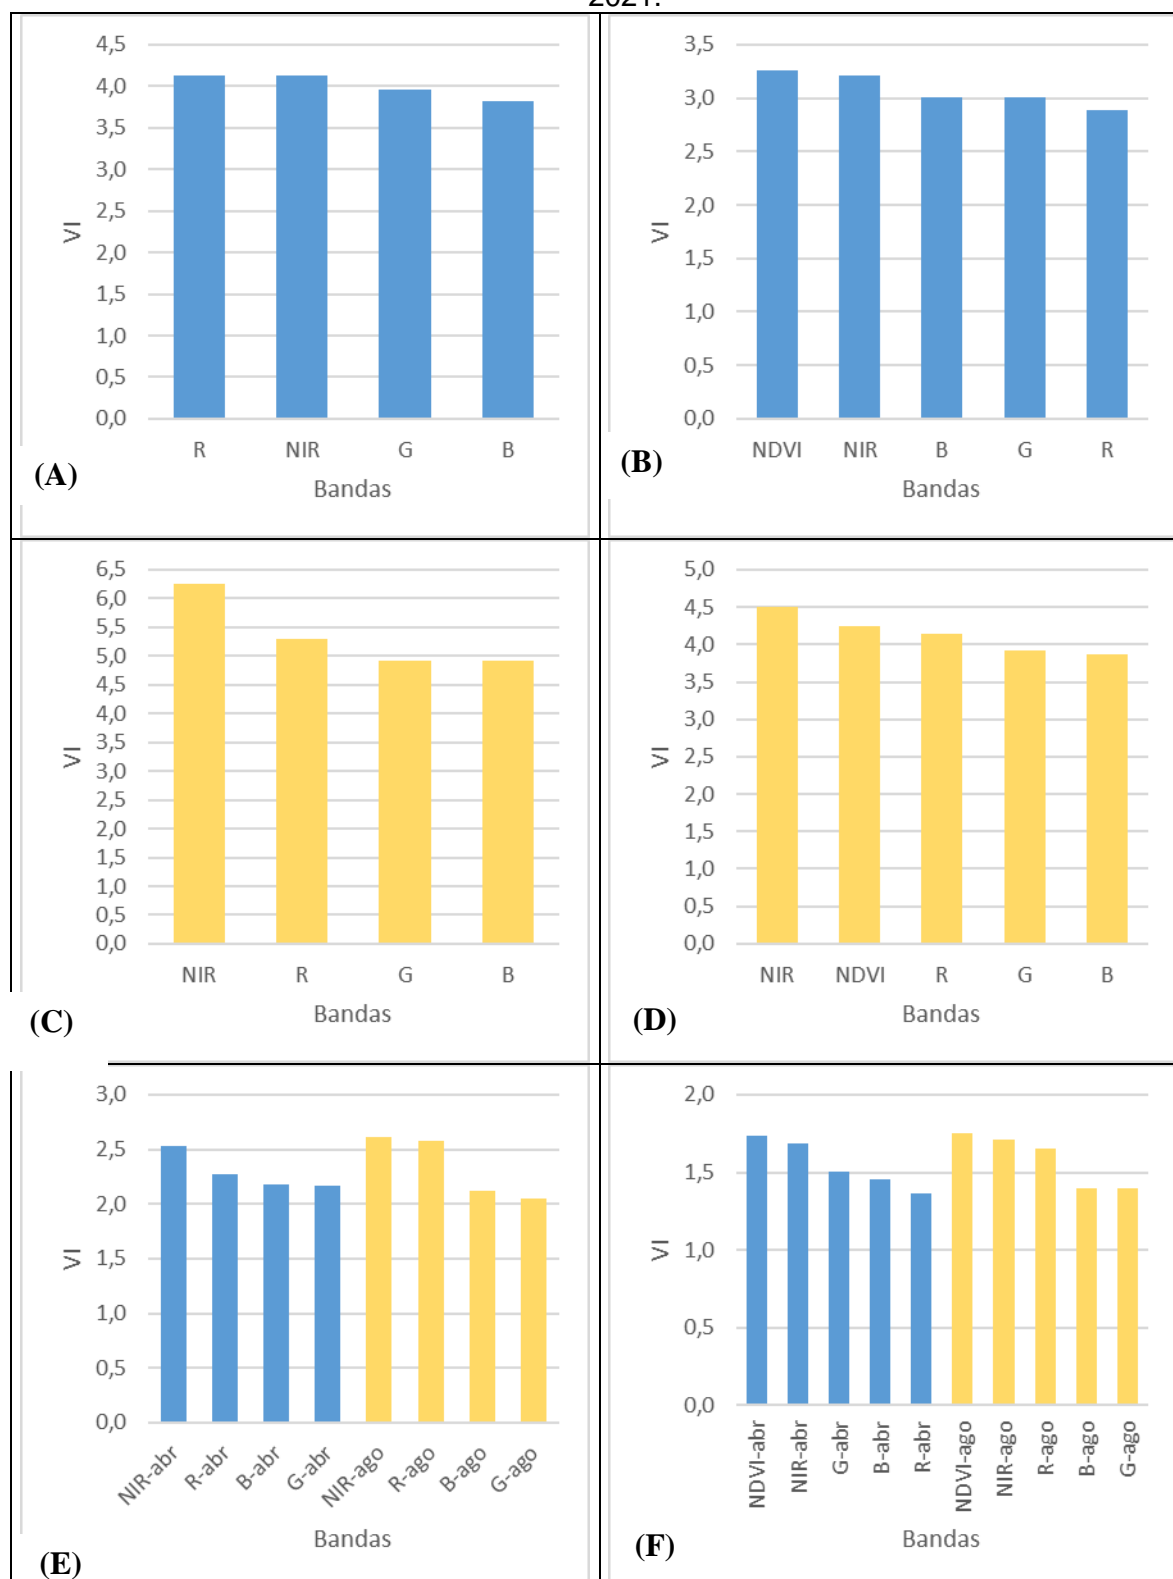
Tabela 2 - Percentual de área ocupada por cada classe em cada classificação realizada neste estudo.

Classe	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6
Área urbana	4,6	5,8	3,3	4,5	2,6	3,5
Massa d'água	0,5	0,5	0,5	0,6	0,5	0,5
Solo exposto	7,6	6,2	23,6	26,0	23,6	22,4
Vegetação nativa - savana	17,9	16,7	18,0	16,4	14,8	16,6
Cultura agrícola	18,7	19,0	9,5	7,0	6,5	7,4
Vegetação nativa - florestal	8,2	8,0	10,0	10,2	10,0	10,3
Reflorestamento	2,8	2,9	1,4	1,6	1,7	1,6
Vegetação nativa - campestre	18,3	17,6	14,4	15,9	16,6	16,3
Pastagem	21,4	23,3	19,4	17,8	23,6	21,4

Nas classificações que consideram apenas a cena de abril/21, a área de solo exposto corresponde entre 6,2% a 7,6%, enquanto as áreas agrícolas correspondem entre 18,7% e 19,0%. Já para os demais mapas, a área de solo exposto corresponde entre 22,4% e 26,0%, enquanto as áreas agrícolas correspondem entre 6,5% e 9,5%. Essa variação decorre da sazonalidade climática e do ciclo da produção agrícola do DF, já que as classificações geradas pelo RF se baseiam puramente na resposta espectral da cobertura do solo no momento do imageamento, e não no seu uso.

A Figura 5 apresenta o ranqueamento de VI das bandas utilizadas em cada classificação. Nos mapas sem o NDVI, a banda do NIR quase sempre foi a mais importante. Na presença do NDVI, essa se tornou a mais importante em duas, das três combinações de bandas testadas. O NDVI assume esse protagonismo nas classificações justamente por ser um índice baseado nas duas bandas mais importantes para as classificações: vermelho e NIR.

Figura 5 - Gráficos de VI das imagens PS a partir dos modelos 1 (A); 2 (B); 3 (C); 4 (D), 5 (E); e 6 (F). Em azul, dos dados de abril de 2021 e, em amarelo, os dados de agosto de 2021.



Elaborada pelos autores

A Tabela 3 mostra os resultados estatísticos das classificações. Quatro dos seis modelos apresentaram acurácia satisfatória, de acordo com Lillesand *et al.* (2015) e Feizizadeh *et al.* (2022). As que não atingiram o patamar de 0,85 foram as

que consideraram apenas os dados de agosto/21 e seu respectivo NDVI (modelos 3 e 4).

Tabela 3 - Resultados estatísticos das classificações RF apresentadas neste estudo.

No.	Atributos	Acurácia global	nº árvores
1	abril 2021 (4 bandas)	0,889	1000
2	abril 2021 + NDVI (5 bandas)	0,891	1000
3	agosto 2021 (4 bandas)	0,849	1000
4	agosto 2021 + NDVI (5 bandas)	0,835	1000
5	abril + agosto 2021 (8 bandas)	0,901	1000
6	abril + agosto 2021 + NDVIs (10 bandas)	0,896	1000

A Figura 6 apresenta os mapas de calor das diferenças entre as classificações indicando as áreas onde há maior diferença em pixels diferentes por hectare. As principais diferenças ocorrem a leste da área de estudo, onde se concentram as maiores áreas agrícolas do Distrito Federal. A diferença de classificação de cobertura da terra nessa região decorre da dinâmica agrícola. A Tabela 4 apresenta o SC, expressa em porcentagem de pixels idênticos entre as classificações, enquanto a Tabela 5 apresenta os índices Kappa entre as classificações.

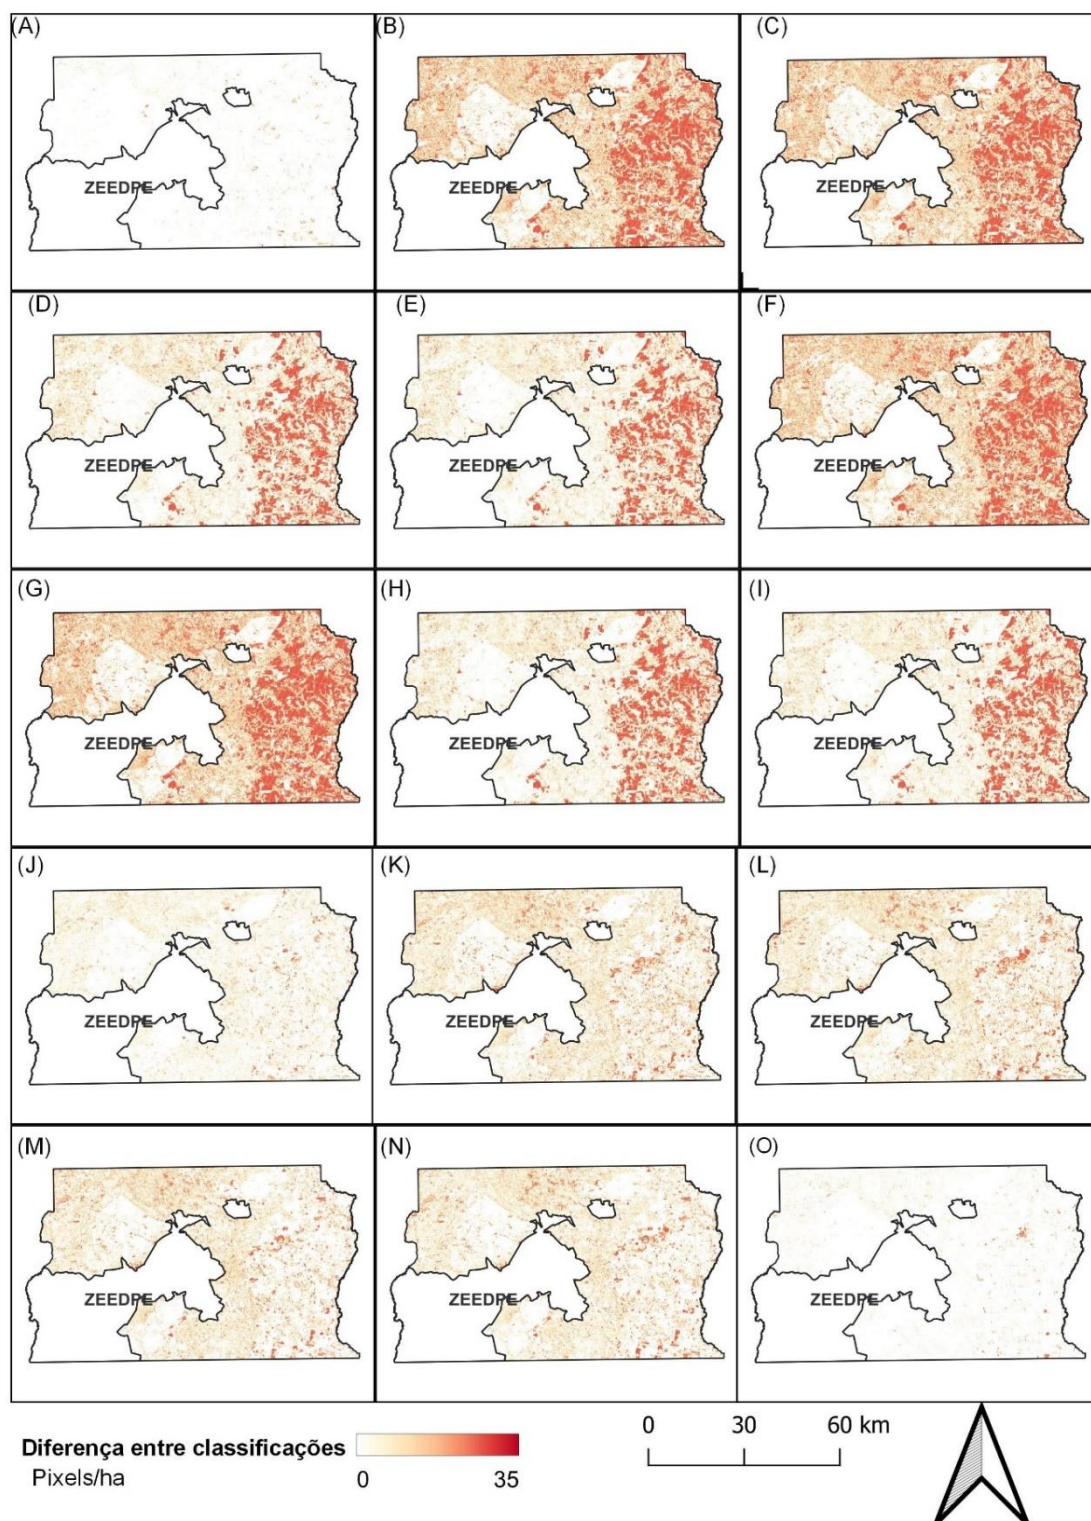
Tabela 4 - Similaridade entre as classificações, expressa em porcentagem.

Modelo	1	2	3	4	5	6
1	100					
2	93,81	100				
3	61,77	61,02	100			
4	60,89	60,02	84,47	100		
5	72,87	72,48	76,89	78,78	100	
6	73,33	73,02	76,85	79,30	92,28	100

Tabela 5 - Índice Kappa entre as classificações.

Modelo	1	2	3	4	5	6
1	1,00					
2	0,93	1,00				
3	0,547	0,539	1,00			
4	0,538	0,529	0,814	1,00		
5	0,68	0,674	0,722	0,745	1,00	
6	0,684	0,680	0,722	0,752	0,907	1

Figura 6 - Mapas de calor das diferenças das classificações a partir dos modelos 1 e 2 (a); 1 e 3 (b); 1 e 4 (c); 1 e 5 (d); 1 e 6 (e); 2 e 3 (f); 2 e 4 (g); 2 e 5 (h); 2 e 6 (i); 3 e 4 (j); 3 e 5 (k); 3 e 6 (l); 4 e 5 (m); 4 e 6 (n); e 5 e 6, expressas em pixels/há



Elaborada pelos autores

Discussão

Acurácia das classificações e aplicações dos dados PS

Os resultados das classificações demonstraram a eficiência do uso dos mosaicos mensais PS para identificar feições de vegetação natural e exótica, bem como para monitorar a sazonalidade e dinâmica temporal da cobertura da terra.

O fato de os dados PS serem de alta resolução espacial (4,77 m) e temporal (diária) é inovador. Em geral, a maioria das atividades de monitoramento do bioma Cerrado por sensoriamento remoto é realizada a partir de imagens de satélite com média ou baixa resolução espacial, de 10 m a 250 m, e baixa resolução temporal, de 16 a 30 dias (OLIVEIRA *et al.*, 2020). Porém, para locais onde os imóveis rurais são menores, como é o caso do DF, cujo tamanho médio é de 16,2 ha (DISTRITO FEDERAL, 2017), os mosaicos mensais PS oferecem uma possibilidade mais promissora de discriminar diversos tipos de vegetação e também de culturas agrícolas. Além disso, a alta frequência de revisita tem potencial para identificar alterações na resposta espectral dos diferentes tipos de vegetação em curtos períodos de tempo, melhorando a capacidade de monitoramento em função do clima e até do crescimento vegetativo de culturas agrícolas (e.g., SANO *et al.*, 2023).

Em relação à resolução espectral, apesar da baixa qualidade radiométrica e falta de calibração da constelação PS, característica comum aos nanosatélites, as quatro bandas espectrais foram suficientes para gerar produtos de mapeamento satisfatórios, como revela a análise de precisão (Tabela 3), indicando que as limitações espectrais e radiométricas foram compensadas pelas resoluções temporais e espaciais mais altas. Fato semelhante foi observado por Parente *et al.* (2019).

Já o empilhamento das imagens das duas datas resultou em uma classificação mais precisa, sendo mais próxima dos modelos que utilizaram apenas a imagem de agosto de 2021. A maior acurácia pode ser explicada pela maior janela temporal utilizada na construção das métricas espectral-temporal e maior variabilidade do espaço de feições analisado pelo RF, o que tende a aumentar a sua capacidade de discriminar alvos (PARENTE *et al.*, 2019).

Outra vantagem em relação aos satélites mais comumente usados é a possibilidade de obtenção de mosaicos mensais em período chuvoso. Em geral, as imagens apresentam alta cobertura de nuvens durante esse período. A alta resolução temporal dos dados do PS garantiu a obtenção de imagens sem cobertura de nuvens da área de estudo, inclusive para um mês chuvoso.

O uso do RPA para coleta de dados se mostrou adequado, uma vez que a utilização das imagens PS exige uma estratégia de amostragem compatível com

dados de alta resolução espacial e representativos da área de estudo (PARENTE *et al.*, 2019). Nesse estudo, as imagens de RPA não foram utilizadas para treinar o algoritmo RF, apenas para informar a localização de cada classe. Contudo, a resolução centimétrica das imagens de RPA e a facilidade de se obter dados também parece levar a um potencial correlação espacial, espectral e temporal entre esses dois dados (PASCUAL *et al.*, 2022). A maior parte dos estudos de mapeamento com RPA é realizada para áreas de pequena escala (DE LUCA *et al.*, 2019; GUERRA-HERNANDES *et al.*, 2021). No entanto, esse estudo foi bem-sucedido no uso do RPA para uma área relativamente grande.

Diferenças entre as classificações

A mudança de classificação de algumas áreas de “cultura agrícola” na imagem de abril de 2021 para “solo exposto” na imagem de agosto de 2021 demonstra que o PS consegue identificar a variação sazonal da dinâmica agrícola descrita por Bolfe *et al.* (2020), no qual a maior parte das culturas só começam a ser plantadas em outubro e novembro. A maior variação na região leste da área de estudo, onde se concentram as atividades agrícolas (NEVES *et al.*, 2017; CODEPLAN, 2019), conforme indicado pelos mapas de calor (Figura 6) são decorrentes dessa dinâmica em função da dominância de culturas de colheita simples.

A maior semelhança com as classificações que utilizam apenas a imagem de agosto de 2021 pode ser explicada por dois fatores: i) maior VI da banda do vermelho e do NDVI de agosto em relação a abril; e ii) a maior parte dos pontos sido coletados em campo em período entre safra, em razão da dificuldade do uso do RPA em período chuvoso. Isso também explica o fato de as classificações que possuem maior acurácia serem as que consideram as duas datas (modelos 5 e 6) e serem visualmente mais próximas dos modelos que consideraram apenas as imagens de agosto de 2021 (modelos 3 e 4), apesar desses dois serem os modelos com menor acurácia.

As imagens adquiridas na estação chuvosa são melhores para mapear a vegetação, pois é quando apresentam maior variação no vigor vegetativo e as áreas agrícolas mudam de solo exposto para o pico de crescimento. Já as imagens da estação seca são melhores para o mapeamento de solo exposto, pois nessa época

apresentam a menor umidade, gerando respostas espectrais mais próximas do coletado em laboratório (MAYNARD e LEVI, 2017).

O uso do índice *Kappa* para comparar a similaridade entre duas classificações a partir de mosaicos mensais de alta resolução espacial revela uma nova aplicação para esse índice. Tradicionalmente, o índice *Kappa* é utilizado para validar mapas e mensurar sua qualidade tendo, como referência, outro mapa temático (NERY *et al.*, 2013). Alternativamente, a estatística *Kappa* também tem sido amplamente utilizada para comparar mapas obtidos por meio de diferentes satélites (e.g., AWAD, 2018; BASHEER *et al.*, 2022) e diferentes métodos (e.g., MACHADO e RODRIGUES, 2020; GANEM *et al.*, 2017). Porém, a nova abordagem proposta nesse estudo permitiu o uso do índice *Kappa* para comparação temporal entre mapas, bem como o efeito da inclusão de mais variáveis a um modelo em imagens de alta resolução espacial.

Ao se adaptar a tabela proposta por Landis e Koch (1977) para uma versão de similaridade entre mapas, obtém-se a Tabela 7. Nesse caso, a inclusão da variável NDVI nos modelos mantém os mapas com alta similaridade. Os mapas menos semelhantes entre si são aqueles que consideram apenas os dados de abril de 2021 em relação aos que consideram apenas os dados de agosto de 2021. Ainda assim, possuem alta similaridade, em razão praticamente de só haver alteração em duas classes, em função da sazonalidade das culturas agrícolas do DF. Já os mapas que incorporam as duas datas possuem muito alta similaridade com todos os que consideram apenas uma data, entretanto, são mais similares às classificações que consideram apenas a data de agosto de 2021.

Tabela 6 - Adaptação das classes do índice *Kappa* para análise de similaridade entre classificações.

Intervalo do índice <i>Kappa</i>	Similaridade entre mapas
< 0,00	Nenhuma
0,00 ÷ 0,2	Muito baixa
0,2 ÷ 0,4	Razoável
0,4 ÷ 0,6	Alta
0,6 ÷ 0,8	Muito Alta
0,8 ÷ 1,0	Altíssima

O índice *Kappa* e a metodologia SC, analisadas nesse estudo, possuem resultados semelhantes, demonstrando certa redundância. Enquanto o índice *Kappa* analisa a probabilidade de um local ser classificado com a mesma classe de outro mapa, o SC considera todos os pixels e retorna o percentual de pixels classificados

identicamente entre os dois mapas. A semelhança dos valores entre esses dois métodos demonstra que SC também é eficiente para comparação entre classificações, podendo ser considerada uma metodologia alternativa para comparação entre classificações e até como análise de qualidade de um mapa.

Considerações Finais

Este trabalho maximiza o potencial de uso dos dados NICFI. Por se tratar de um produto novo, as potencialidades de uso dos mosaicos mensais PS ainda não foram totalmente exploradas. Esse estudo buscou abrir possibilidades de aplicação dessa nova tecnologia. Quanto a isso, os mosaicos se mostraram eficientes para identificar diferentes tipos de vegetação, tanto naturais, quanto antropizadas. Além disso, foram capazes de identificar as mudanças sazonais da cobertura do solo decorrentes das atividades agrícolas.

Outros achados interessantes desse estudo foram:

- a) As bandas do vermelho e NIR foram as mais importantes para a classificação, porém, quando incorporada à variável NDVI, essa se sobressai sobre as demais.
- b) A época de coleta de dados de treinamento tem influência no resultado da classificação.
- c) A incorporação de mais variáveis a um modelo tende a aumentar sua acurácia.
- d) Tanto o índice Kappa quanto o SC, analisados nesse artigo, podem ser bons métodos de comparação temporal entre mapas de alta resolução espacial.

REFERÊNCIAS

- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. M.; SPAVOREK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, p. 711–728, 2014.
- AQUINO, F. G.; MIRANDA, G. H. B. Consequências ambientais da fragmentação de habitats no Cerrado. In: SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F. **Cerrado: Ecologia e Flora**. Planaltina: Embrapa Cerrados; Brasília: Embrapa Informação Tecnológica, 2008. 2 v., 1.279 p.
- ARCHER, K. J.; KIMES, R. V. Empirical characterization of random forest variable importance measures. **Computational Statistics & Data Analysis**, v. 52, n. 4, p. 2249–2260, 2008.

AWAD, M. M. Forest mapping: A comparison between hyperspectral and multispectral images and technologies. **Journal of Forest Research**, v. 29, p. 1395–1405, 2018.

BASHEER, S.; WANG, X.; FAROOQUE, A. A.; NAWAZ, R. A.; LIU, K.; ADEKANMBI, T.; LIU, S. Comparison of land use land cover classifiers using different satellite imagery and machine learning techniques. **Remote Sensing**, v. 14, 4978, 2022.

BOLFE, E. L.; SANO, E. E.; CAMPOS, S. K. **Dinâmica Agrícola no Cerrado. Análise e Projeções**. Brasília: Embrapa, 2020.

BREIMAN, L. Random Forests. **Machine Learning**, v. 45, p. 5–32, 2001.

CASTRO, K. B.; ROIG, H. L.; NEUMANN, M. R. B.; ROSSI, M. S.; SERAPHIM, A. P. A. C. C.; RÉQUIA JUNIOR, W. J.; COSTA, A. B. B.; HOFER, R. New perspectives in land use mapping based on urban morphology: A case study of the Federal District, Brazil. **Land Use Policy**, v. 87, 104032, 2019.

CHELOTTI, G. B.; MARTINEZ, J. M.; ROIG, H. L.; OLIVIETTI, D. Space-temporal analysis of suspended sediment in low concentration reservoir by remote sensing. **Revista Brasileira de Recursos Hídricos**, v. 24, e17, 2019.

CHELOTTI, G. B.; SANO, E. E. Sessenta anos de ocupação urbana na capital do Brasil: Padrões, vetores e impactos na paisagem. Brasília: CODEPLAN, **Texto para Discussão**, n. 73, 2021.

COMPANHIA DE PLANEJAMENTO DO DISTRITO FEDERAL (CODEPLAN). **Atlas do Distrito Federal**. Brasília: CODEPLAN, 2017, 114 p.

COMPANHIA DE PLANEJAMENTO DO DISTRITO FEDERAL (CODEPLAN). **Pesquisa distrital por amostra de domicílios – PDAD 2018**. Brasília: CODEPLAN, 2019, 115 p.

COHEN, J. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, v. 20, n. 1, p. 37-46, 1960.

DE LUCA, G. N.; SILVA, J.; CERASOLI, S.; ARAÚJO, J.; CAMPOS, J.; DI FAZIO, S.; MODICA, G. Object-based land cover classification of cork oak woodlands using UAV imagery and Orfeo ToolBox. **Remote Sensing**, v. 11, 1238, 2019.

DISTRITO FEDERAL. **Zoneamento ecológico-econômico do Distrito Federal – ZEE DF**. Caderno Técnico – Matriz Ecológica. Brasília, 2017, 164 p. Disponível em: http://www.zee.df.gov.br/wp-content/uploads/2018/05/ZEE_DF_CT01_Matriz_Ecologica.pdf. Acesso em: 17 set. 2020

DISTRITO FEDERAL. **Lei nº 6.269, de 29 de janeiro de 2019**. Institui o Zoneamento Ecológico-Econômico do Distrito Federal - ZEE-DF em cumprimento ao art. 279 e ao art. 26 do Ato das Disposições Transitórias da Lei Orgânica do Distrito Federal e dá outras providências. Disponível em: https://www.sinj.df.gov.br/sinj/Norma/912a61dfc1134ffebb691aa3e864673e/Lei_6269_29_01_2019.html. Acesso em: 05 fev. 2023.

DJI. DJI Mini 2. **Manual do Usuário**. v 1.4, 2021.06. 52 p. Disponível em: <https://www.dji.com/br/mini-2>. Acesso em: 30 ago. 2021.

FEIZIZADEH, B.; DARABI, S.; BLASCHKE, T.; LAKES, T. QADI as a new method and alternative to Kappa for accuracy assessment of remote sensing-based image classification. **Sensors**, v. 22, 4506, 2022.

FERREIRA, R. B.; PARREIRA, M. R.; NABOUT, J. C. The impact of global climate change on the number and replacement of provisioning ecosystem services of Brazilian Cerrado plants. **Environmental Monitoring and Assessment**, v. 193, 731, 2021.

GANEM, K. A.; BAPTISTA, G. M. M.; FRANCA ROCHA, W. J. S.; VASCONCELLOS, R. N.; ROSA, M. R.; SOUZA, D. T. M. Comparação entre dados com e sem correção atmosférica na classificação de cobertura da terra em uma área da caatinga utilizando o Google Earth Engine. **Revista Brasileira de Cartografia**, v. 69, n. 6, p. 1053-1074, 2017.

GARCIA, A. S.; BALLESTER, M. V. R. Land cover and land use changes in a Brazilian Cerrado landscape: drivers, processes, and patterns. **Journal of Land Use Science**, v. 11, n. 5, p. 538-559. 2016.

GOOGLE. Google Earth Pro 7.3.6.9345, 2022. Disponível em: <https://www.google.com.br/intl/pt-BR/earth/> Acesso em: 4 abr. 2023.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 2017.

GUERRA-HERNÁNDEZ, J.; DÍAZ-VARELA, R. A.; ÁVAREZ-GONZÁLEZ, J. G.; RODRÍGUEZ-GONZÁLEZ, P. M. Assessing a novel modelling approach with high resolution UAV imagery for monitoring health status in priority riparian forests. **Forest Ecosystems**, v. 8, 61, 2021.

HORNING, N.; FLEISHMAN, E.; ERSTS, P. J.; FOGARTY, F. A.; ZILLIG, M. W. Mapping of land cover with open-source software and ultra-high-resolution imagery acquired with unmanned aerial vehicles. **Remote Sensing in Ecology and Conservation**, v. 6, n. 4, p. 487–497, 2020.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159-174, 1977.

LILLESAND, T.; KIEFER, R. W.; CHIPMAN, J. **Remote sensing and image interpretation**. John Wiley & Sons, 2015.

MACARRINGUE, L. S.; BOLFE, E. L.; PEREIRA, P. R. M. Developments in land use and land cover classification techniques in remote sensing: A review. **Journal of Geographic Information System**, v. 14, p. 1-28, 2022.

MACHADO, A. M. B.; RODRIGUES, T. C. S. Comparação de métodos de classificação para o mapeamento da cobertura da terra no setor norte da ilha do Maranhão. **Geociências**, v. 39, n. 4, p. 1129-1140, 2020.

MAYNARD, J. J.; LEVI, M. R. Hyper-temporal remote sensing for digital soil mapping: Characterizing soil-vegetation response to climatic variability. **Geoderma**, v. 285, p. 94–109, 2017.

MINISTÉRIO DO MEIO AMBIENTE - MMA. Nota Técnica - TerraClass Cerrado 2020. Brasília, 2020, 67 p. Disponível em: <https://www.terraclass.gov.br/geoportao-cerrado/> Acesso em: 25/05/2023.

NASCIMENTO, D. T. F. Caracterização ambiental do Estado de Goiás e Distrito Federal como insumo à gestão dos recursos hídricos. **Revista Sapiência**, v. 6, n. 2, p. 34-50, 2017.

NERY, C. V. M.; OLIVEIRA, D. B.; ABREU, L. H. G. Estudo comparativo entre os índices NDVI obtidos a partir dos sensores Landsat 5 - TM e Resourcesat - Liss III. **Caminhos de Geografia**, v. 14, n. 46, p. 160–167, 2013.

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.

NORWAY'S INTERNATIONAL CLIMATE AND FOREST INITIATIVE - NICFI. **Standing with the World's tropical forests**. 2021. Disponível em: <https://www.nicfi.no/> Acesso em: 10/8/2022.

NUNES, J. F.; ROIG, H. L. Análise e mapeamento do uso e ocupação do solo da bacia do Alto Descoberto, DF/GO, por meio de classificação automática baseada em regras e lógica nebulosa. **Revista Árvore**, v. 39, n. 1, p. 25-36, 2015.

OLIVEIRA, M. T.; CASSOL, H. L. G.; GANEM, K. A.; DUTRA, A. C.; PRIETO, J. D.; ARAI, E.; SHIMABUKURO, Y. E. Mapeamento da vegetação do Cerrado – Uma revisão das iniciativas de sensoriamento remoto. **Revista Brasileira de Cartografia**, v. 72, p. 1250-1274, 2020.

PANDEY, P.; KINGTON, J.; KANWAR, A.; CURDOGLO, M. Addendum to Planet basemaps product specifications. **NICFI basemaps**. Revision: v02. NICFI, 2021. Disponível em: https://assets.planet.com/docs/NICFI_Basemap_Spec_Addendum.pdf Acesso em: 08 fev, 2023.

PARENTE, L.; TAQUARY, E.; SILVA, A. P.; SOUZA, C.; FERREIRA, L. Next generation mapping: Combining deep learning, cloud computing, and big remote sensing data. **Remote Sensing**, v. 11, 2881, 2019.

PARK, J. Y.; MULLER-LANDAU, H. C.; LINCHSTEIN, J. W.; RIFAI, S. W.; DANDOIS, J. P.; BOHLMAN, S. A. Quantifying leaf phenology of individual trees and species in a tropical forest using unmanned aerial vehicle (UAV) images. **Remote Sensing**, v. 11, 1534, 2019.

PASCUAL, A.; TUPINAMBÁ-SIMÕES, F.; GUERRA-HERNÁNDEZ, J.; BRAVO, F. High-resolution planet satellite imagery and multi-temporal surveys to predict risk of tree mortality in tropical eucalypt forestry. **Journal of Environmental Management**, v. 310, 114804, 2022.

PLANET. **Planet imagery product specifications**. 2022. Disponível em: https://assets.planet.com/docs/Planet_Combined_Imagery_Product_Specs_letter_screen.pdf . Acesso em: 08 fev, 2023.

RÉQUIA Jr., E. J.; ROIG, H. L.; KOUTRAKIS, P. A novel land use approach for assessment of human health: The relationship between urban structure types and cardiorespiratory disease risk. **Environment International**, v. 85, p. 334-342, 2015.

RIBEIRO, J. F.; WALTER, B. M. T. As principais fitofisionomias do bioma Cerrado. In: SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F. **Cerrado: Ecologia e Flora**. Embrapa Cerrados: Planaltina, DF; Embrapa Informação Tecnológica: Brasília, DF. 2008, 2 v., 1.279 p.

SANO, E. E.; BOLFE, E. L.; PARREIRAS, T. C.; BETTIOL, G. M.; VICENTE, L. E.; SANCHES, I. D.; VICTORIA, D. C. Estimating Double Cropping Plantations in the Brazilian Cerrado through PlanetScope Monthly Mosaics. **Land**, v. 12, n. 3, 581, 2023.

SILVA, F. A. M.; ASSAD, E. D.; EVANGELISTA, B. A. Caracterização climática do bioma Cerrado. In: SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F. **Cerrado: Ecologia e Flora**. Embrapa Cerrados: Planaltina, DF; Embrapa Informação Tecnológica: Brasília, DF. 2008, 2 v., 1.279 p.

SINGH, K.; FRAIZER, A. E. A meta-analysis and review of unmanned aircraft system (UAS) imagery for terrestrial applications. **International Journal of Remote Sensing**, v. 39, n. 15-16, p. 5078-5098, 2018.

SRIVASTAVA, S.; VARGAS-MUÑOZ, J. E.; DEVIS T. Understanding urban land use from the above and ground perspectives: A deep learning, multimodal solution. **Remote Sensing of Environment**, v. 228, p. 129-143, 2019.

STASSUN, C. C. S.; PRADO FILHO, K. Geoprocessamento como prática biopolítica no governo municipal. **Revista de Administração Pública**, v. 46, n. 6, p. 1649-1669, 2012.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, p. 127-150, 1979.

NOTAS DE AUTOR

CONTRIBUIÇÃO DE AUTORIA

Giancarlo Brugnara Chelotti - Concepção. Coleta de dados, Análise de dados, Elaboração do manuscrito e Revisão.

Edson Eyji Sano - Supervisão. Revisão e aprovação da versão final do trabalho

FINANCIAMENTO

Não se aplica.

CONSENTIMENTO DE USO DE IMAGEM

Não se aplica.

APROVAÇÃO DE COMITÊ DE ÉTICA EM PESQUISA

Não se aplica.

CONFLITO DE INTERESSES

Não se aplica.

LICENÇA DE USO

Este artigo está licenciado sob a [Licença Creative Commons CC-BY](#). Com essa licença você pode compartilhar, adaptar, criar para qualquer fim, desde que atribua a autoria da obra.

HISTÓRICO

Recebido em: 12-06-2023

Aprovado em: 23-01-2024