



Classificador Support Vector Machines para o mapeamento da cobertura do solo usando imagens CBERS-4/MUX e Landsat-8/OLI

Juarez Antônio da Silva Júnior¹, Admilson da Penha Pacheco²

¹ Eng. Cartógrafo e Agrimensor, Universidade Federal de Pernambuco, Av. Prof. Moraes Rego, 1235 - Cidade Universitária, Recife - PE, 50670-901. juarez.silvajunior@ufpe.br (autor correspondente). ² Dr. Professor Titular, Universidade Federal de Pernambuco. Av. Prof. Moraes Rego, 1235 - Cidade Universitária, Recife - PE, 50670-901. admilson.pacheco@ufpe.br.

Artigo recebido em 05/02/2023 e aceito em 20/04/2023

RESUMO

O mapeamento do uso/cobertura da terra desempenha um papel vital no planejamento e supervisão da utilização dos recursos naturais com base no aumento gradual das demandas humanas no ecossistema atual. As detecções de mudanças na cobertura do solo são essenciais para entender quais vetores de degradação atuam na região, além do monitoramento do risco ambiental no entorno de reservatórios de abastecimento de água no Bioma Caatinga. O sensoriamento remoto e o classificador SVM fornecem uma plataforma consistente para estudar as transformações da paisagem em toda a superfície da Terra. Este estudo objetiva o mapeamento de uso e ocupação do solo no entorno da Barragem barra do Juá localizado no estado de Pernambuco através da comparação entre sensores orbitais, o Câmera Multiespectral Regular (MUX) e o *Operational Land Instrument* (OLI) dos satélites CBERS-4 e Landsat-8 respectivamente. A análises foram baseadas em Tabela de Contingência obtidas por meio de um mapa oficial de referência. Após a verificações comparativas com o produto de referência, foram obtidos uma acurácia do produtor e de usuário médio de 62,44% e 71,74% para o MUX e 60,88% e 62,38% para o OLI, respectivamente. As diferentes especificações e capacidades técnicas entre os sensores na captura bem como o comportamento espectral dos alvos foram relevantes para a variabilidade espacial e temática entre os mapas de uso do solo MUX e OLI. Os resultados obtidos mostraram que o MUX apresentou mapas de cobertura da terra com melhor desempenho em relação aos dados OLI.

Support Vector Machines classifier for land cover mapping using CBERS-4/MUX and Landsat-8/OLI images

ABSTRACT

Land use/land cover mapping plays a vital role in planning and supervising the use of natural resources based on the gradual increase in human demands on today's ecosystem. The detection of changes in land cover is essential to understand which degradation vectors act in the region, in addition to monitoring the environmental risk around water supply reservoirs in the Caatinga Biome. Remote sensing and the SVM classifier provide a consistent platform for studying landscape transformations across the Earth's surface. This study aims to map land use and occupation around the Barra do Juá dam located in the state of Pernambuco through the comparison between orbital sensors, the Regular Multispectral Camera (MUX) and the Operational Land Instrument (OLI) of the CBERS-4 satellites and Landsat-8 respectively. The analyzes were based on a Contingency Table obtained through an official reference map. After comparative verifications with the reference product, an accuracy of 62.44% and 71.74% for the MUX and 60.88% and 62.38% for the OLI were obtained for the average producer and user, respectively. The different specifications and technical capabilities between the sensors in the capture as well as the spectral behavior of the targets were relevant to the spatial and thematic variability between the MUX and OLI land use maps. The results obtained showed that the MUX presented land cover maps with better performance in relation to the OLI data.

Introdução

Mudanças na cobertura da terra desempenham um papel essencial nos estudos de alterações ambientais regionais, locais e globais. A cobertura do solo se refere a como a superfície da Terra é coberta, por exemplo, por florestas, pântanos, superfícies impermeáveis, terras

construídas, habitats de vida selvagem, agrícolas e água e outros tipos de terra (FICHERA *et al.* 2012). As alterações humanas na superfície da Terra afetam significativamente aspectos-chave do funcionamento do sistema terrestre (incluindo o equilíbrio de energia, água e solo). Além disso, a

pressão sobre os recursos naturais limitados, causada pelo aumento da população, contribui para mudanças na cobertura da superfície do solo (Hu *et al.* 2021). Existem inúmeras fontes de mudanças de cobertura do solo (Yan *et al.* 2019) como a degradação florestal, ampliação agrícola, globalização e urbanização como as principais causas para mudanças nas coberturas do solo regionais e globais. Essas mudanças na cobertura da terra são dinâmicas e contínuas e por isso, os mapas de cobertura da terra atualizados e precisos são de considerável importância para o planejamento adequado, mudanças globais, monitoramento do ambiente e estimativa da degradação florestal.

Recentemente, dados de sensores orbitais multiespectrais e multitemporais de alta e média resolução espacial surgiram como ferramentas essenciais para estimar aspectos como cobertura vegetal, degradação florestal e expansão urbana (Naikoo *et al.* 2020). O sensoriamento remoto e a tecnologia GIS fornecem uma plataforma para estudar as transformações da paisagem em toda a superfície da Terra. Nos métodos convencionais, o mapeamento é realizado usando registros disponíveis, levantamentos de campo e mapas. Assim, os métodos convencionais são demorados e caros. Além disso, os mapas produzidos tornam-se rapidamente desatualizados em ambientes que mudam rapidamente (Silva Júnior e Pacheco, 2020).

Em contraste com a aquisição de dados tradicional, os dados de sensoriamento remoto fornecem informações valiosas em um tempo relativamente curto e de maneira econômica. Imagens de satélite de alta resolução ou fotos aéreas são importantes para estudar as mudanças na cobertura da terra em grandes cidades. No entanto, dados de resolução média, como os conjuntos de dados Landsat Multi-Spectral Scanner (MSS), TM e Operational Land Imager (OLI), foram usados em todo o mundo para análise de detecção de mudança na cobertura do solo (Roy e Inamdar, 2019). Além disso, o cubo de dados CBERS-4 de média resolução trouxe uma melhoria no escopo dos estudos de monitoramento ambiental, como mapeamento de desmatamento, avaliação de emissão de gases de efeito estufa e detecção de incêndios florestais conforme Simões *et al.* (2020) e para o monitoramento da floresta segundo Liu *et al.* (2019) e urbanização (Giannini *et al.* 2017).

Algoritmos de classificação de imagens de satélite por aprendizado de máquina que incluem

Máquina de Vetor de Suporte (SVM), Máquina de Aprendizado Extremo (ELM) e Máquina de Aprendizado Extremo de Kernel (KELM) têm sido amplamente usados para classificação de imagens (Lamine *et al.* 2018). Tradicionalmente, esses algoritmos de aprendizado de máquina utilizam apenas informações espectrais embora precisão da classificação pode ser melhorada ou avaliada combinando informações espaciais com informações espectrais (Parida e Mandal, 2020) ou dados espaciais oficiais de referência. Portanto técnicas de aprendizado supervisionado tem demonstrado grande capacidade de extração de informações espaciais de imagens brutas (Gibril *et al.* 2016).

A principal contribuição deste artigo é analisar a qualidade temática dos mapas de cobertura do solo obtidos por imagens multiespectrais das plataformas Landsat-8/OLI e CBERS-4/MUX diante das respectivas diferenças especificações técnicas. Além disso, este estudo também avaliou o efeito dos hiperparâmetros de entrada do Classificador Support Vector Machine na classificação da cobertura da terra. A aplicação do processamento de imagens inspirado na análise e vigilância ambiental é considerada um aspecto vital no contexto do uso e qualidade de dados geoespaciais.

Material e métodos

Fluxo de trabalho

A Figura 1 mostra o fluxograma deste estudo. Ele inclui principalmente cinco partes:

- (1) Obtenção das cenas CBERS4-MUX e Landsat8-OLI.
- (2) Etapa de pré-processamento, consiste na transformação de unidades, georreferenciamento e composição das cenas.
- (3) Treinamento amostral, ajuste de parâmetros da Classificação supervisionada pelo algoritmo Support Vector Machines.
- (4) Comparação por Tabela de Contingência dos mapas classificados com o produto referência espacial WorldCover.
- (5) Ajuste dos parâmetros SVM, acurácia e Regressão linear por proporção 2x2 dos mapas de cobertura do solo obtidos pela classificação das cenas MUX e OLI.

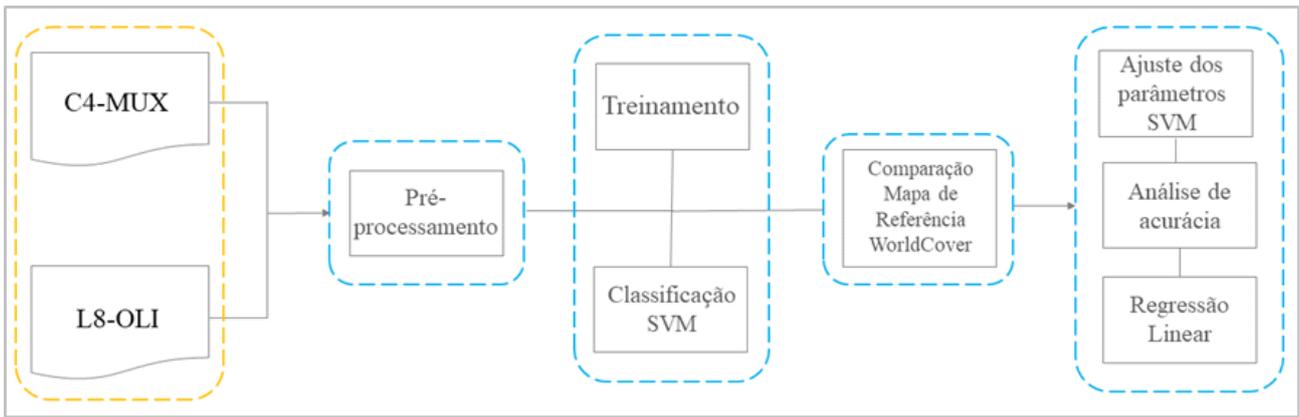


Figura 1. Fluxograma da classificação e análise dos mapas de cobertura do solo.

Área de estudo

O açude Barra do Juá, localizado na zona rural do município de Floresta, em Pernambuco, foi construído em 1982 pelo Departamento de Obras Contra as Secas (DNOCS) tendo como finalidade inicial a irrigação de terras à montante e à jusante (Fig. 2). O reservatório está inserido na bacia do

Rio Pajeú, sendo a maior bacia do estado de Pernambuco, possuindo uma área de 16.685,63 km², correspondendo a 16,97% da área do Estado. Sua capacidade de armazenamento é de 71.474.000 m³, sua área de drenagem é de 1.870 km² e possui evapotranspiração média de 450 Ls-1 (APAC, 2019).

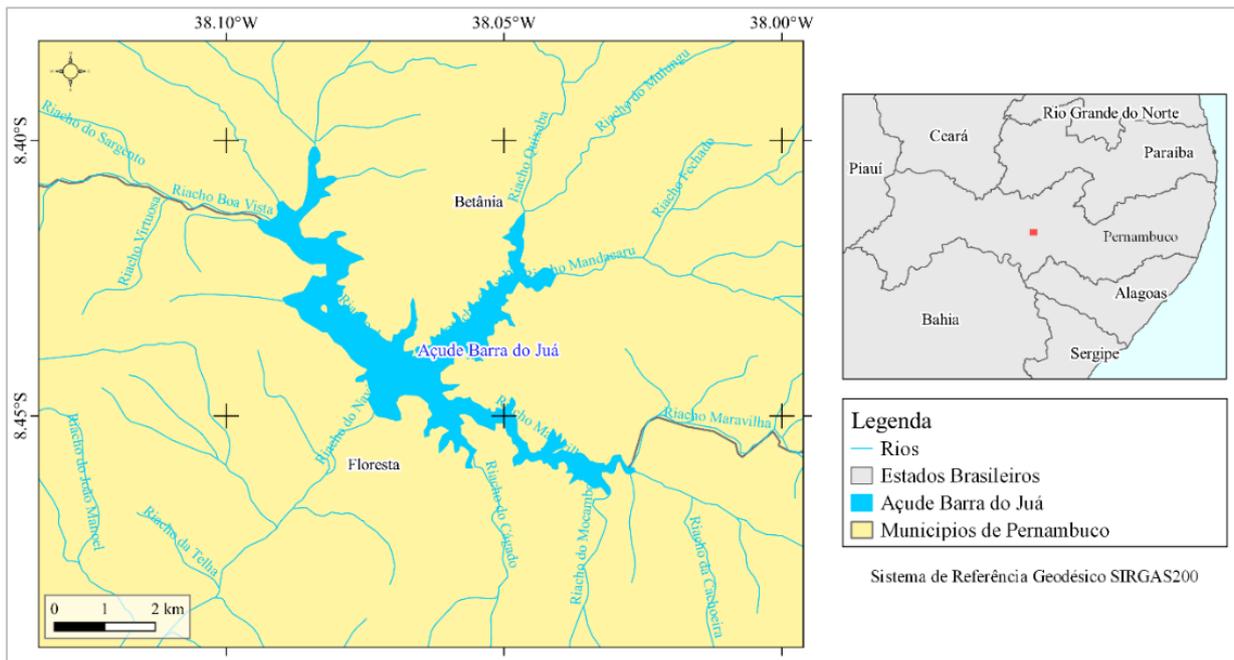


Figura 2. Área de estudo

As caatingas, em geral, são formações vegetais xerófilas, lenhosas, decíduas, com muitas espécies espinhosas, compreendendo um estrato arbóreo esparso, outro arbóreo-arbustivo e/ou arbustivo, e um herbáceo estacional, conforme o período das chuvas (Batalha *et al.* 2005).

Características do Landsat-8/OLI e CBERS-4/MUX

Buscando atingir o objetivo do presente estudo foram obtidas imagens orbitais do sensor,

Câmera Multiespectral Regular (MUX) instalado a bordo do satélite CBERS-4. Também foram adquiridas imagens do sensor Operational Land Instrument (OLI) do satélite Landsat-8 (Tabela 1). O L8/OLI, lançado pela National Aeronautics and Space Administration (NASA) e United States Geological Survey (USGS), possui dois sensores: Operational Land Imager (OLI) (30 m de resolução espacial e nove bandas) e Thermal InfraRed Sensor (TIRS) (100 m de resolução espacial, porém reamostrada para 30m e duas bandas). A resolução

temporal é de 16 dias e a resolução radiométrica é de 16 bits e a área coberta por cena é 185×180 km (LAGBAS, 2019). O MUX / CBERS-4 é uma câmera multiespectral com quatro bandas espectrais cobrindo a faixa de comprimento de onda do azul ao infravermelho próximo (450 nm a 890 nm) com uma resolução espacial de 20 m e uma largura de faixa de solo de 120 km. É o sensor que garante cobertura global em resolução espacial padrão a cada 26 dias e possui função é manter a

continuidade com os sensores CBERS anteriores (PINTO, 2016).

As análises foram realizadas com as cenas sem a presença de nuvens com intuito de avaliar melhor os resultados. Para isso buscou-se imagens em período de seca na região, que ocorre entre julho e dezembro. A imagem do sensor Landsat-8/OLI foi gerada no dia 09/10/2022, enquanto a cena do CBERS-4/MUX em 02/10/2022.

Tabela 1. Características dos sensores L8/OLI e C4/MUX.

Banda Espectral	L8-OLI Comprimento de onda central (nm) / Resolução espacial	C4-MUX Comprimento de onda central (nm) / Resolução espacial
Coastal/Aerosol	442.9 (30 m)	-
Azul	482 (30 m)	485 (20 m)
Verde	561.4 (30 m)	555 (20 m)
Vermelho	654.6 (30 m)	660 (20 m)
Infravermelho Próximo (NIR)	864.7 (30 m)	830 (20 m)
Pancromatica	589.5 (15 m)	-
Cirrus	1373.4 (30 m)	-
Vapor d'água	-	-
Infravermelho médio (SWIR)	1608.9 (30 m)	-
	2200.7 (30 m)	-
Pancromatica	589.5 (15 m)	-
Cirrus	1373.4 (30 m)	-

A integração entre os dados L8 / OLI e C4 / MUX fornece um intervalo médio global de revisita de cerca de 21 dias, o que permite o monitoramento de superfície com observações livres de nuvens em algumas regiões, e o desenvolvimento de produtos agrícolas no espaço médio resolução (Bolton *et al.* 2020). Com os novos satélites Landsat 9 e CBERS-4A e, a constelação virtual se tornará ainda mais frequente se aproximando de um ciclo de revisita de 2 dias (Zeng *et al.* 2020). Isso possibilita o desenvolvimento de métodos considerando diferentes resoluções temporais e espaciais para derivar parâmetros biofísicos da vegetação e a mistura espectral de frações sub-pixel, o que permite mapear processos dinâmicos em resolução sub-hectare (Wulder *et al.* 2019).

Mapeamento de Referência (WorldCover Map)

O WorldCover da Agência Espacial Européia (ESA) é um mapa de cobertura do solo global com 11 classes diferentes de cobertura do solo produzido em resolução de 10m com base na combinação de dados Sentinel-1 e Sentinel-2. Em áreas onde as imagens do Sentinel-2 são cobertas por nuvens por um longo período, os dados do Sentinel-1 fornecem informações complementares

sobre as características estruturais da cobertura do solo observada. Portanto, a combinação dos dados do Sentinel-1 e Sentinel-2 possibilitou o uso do mapa de cobertura do solo quase em tempo real. O WorldCover Map foi produzido em 2022 (01 de janeiro a 31 de dezembro) com uma cobertura global como parte do 5º Programa de Desenvolvedores de Observação da Terra (EOEP-5). Os dados são fornecidos em formato Geotiff, georreferenciado e disponibilizado gratuitamente através do site: <https://viewer.esa-worldcover.org/worldcover/>. Os mapas Worldcover supri informações valiosas para aplicações como biodiversidade, segurança alimentar, avaliação de carbono e modelagem climática (Zanaga *et al.* 2021).

Treinamento e classificação por Support Vector Machine (SVM)

O SVM é baseado na teoria de aprendizagem estatística e tem o objetivo de determinar a localização dos limites de decisão que produzem a separação ótima de classes (Vapnik, 1995). No caso de um problema de reconhecimento de padrões de duas classes em que as classes são linearmente separáveis, o SVM seleciona entre o número infinito de limites de decisão linear aquele

que minimiza o erro de generalização. Assim, o limite de decisão selecionado será aquele que deixa a maior margem entre as duas classes, onde a margem representa a distância entre o hiperplano e os vetores de suporte. A análise SVM tenta posicionar a margem de forma que o espaço entre ela e os vetores de suporte sejam maximizados.

Quando os dados não se adequam a um hiperplano óbvio é preciso mudar o ponto de vista para um espaço dimensional superior. Dessa forma, o SVM permite que os usuários escolham uma função do kernel que melhor se adapte aos dados com os quais estão trabalhando. Em estudos de classificação de áreas queimadas, de acordo com Dragozi *et al.* (2014) e Pereira *et al.* (2017), o kernel da Função de Base Radial (RBF) do classificador SVM é comumente usados e apresenta um bom desempenho. Portanto, neste estudo, foi utilizado o kernel RBF para implementar o algoritmo SVM, embora exista dois parâmetros que precisam ser configurados ao aplicar o classificador SVM com kernel RBF: os parâmetros ótimos de custo (C) e o parâmetro de largura do kernel (γ) também chamado de “gamma” (Sheykhmousa *et al.* 2020). O parâmetro C decide o tamanho do erro de classificação permitido para dados de treinamento não separáveis, o que torna possível o ajuste da rigidez dos dados de treinamento. O parâmetro de largura do kernel (γ) afeta a suavização da forma do hiperplano de divisão de classes (HOSSEINI *et al.* 2021). Valores maiores de C podem levar a um modelo de sobreajuste, enquanto o aumento do valor de γ afetará a forma do hiperplano de divisão de classes, o que pode afetar os resultados de precisão da classificação (NOI e KAPPAS, 2015).

Para realizar a classificação, é necessária uma etapa de treinamento para permitir que o classificador aprenda o processo por meio de exemplos que indicam a correspondência entre uma amostra de treinamento e uma classe. Seguindo o estudo de Li *et al.* (2014) e Noi e Kappas (2018) para encontrar os parâmetros ideais para SVM, cinco valores de C (0.001, 0.01, 0.1, 1,10, 100, 1000), e quatro valores de γ (0.001, 0.01, 0.1, 1,10, 100, 1000), foram testados. A melhor combinação C e γ pré-estabelecido, será avaliado com 100 interações comumente utilizado na literatura Benbriqa *et al.* (2021), e por fim, será realizado a classificação SVM para todo o conjunto de dados MUX e OLI, utilizando os melhores valores dos hiperparâmetros treinados. A seleção das amostras de treinamento foi realizada no software QGIS 3.10 (QGIS, 2021). Os testes de hiperparâmetros e classificação foi realizado no

software RStudio Desktop 1.4.1717 através do pacote ‘e1071’ (MEYER, 2021).

Avaliação da Precisão

Para comparar as categorias de cobertura da terra determinadas pelos mapas MUX e OLI, cinco medidas de precisão foram consideradas com base numa Tabela de Contingência, a saber, Acurácia geral (AG), Acurácia do usuário (AU), Acurácia do produtor (AP), Coeficiente de dados (CD) e Coeficiente Kappa para cada uma das seis categorias de cobertura da terra (Congalton, 1991).

A Acurácia geral (AG) é calculada somando o número de valores classificados corretamente e dividindo pelo número total de valores. A acurácia do usuário (AU) é a probabilidade de que um pixel estava previsto para estar em uma determinada classe dessa classe. A precisão do usuário está associada ao erro de comissão que é a proporção de um pixel que estava previsto para estar em uma classe, mas não pertence a essa classe. A acurácia do produtor (AP) é a probabilidade de que um valor em uma classe foi classificado corretamente. O seu inverso é associado ao erro de omissão que é a proporção de pixels observados no terreno que não são classificados no mapa (Congalton, 1991).

O Coeficiente de Dados (DC) é uma medida da sobreposição entre o mapa classificado e o mapa de referência, em termos do número de pixels comuns. Essa métrica de similaridade tem sido amplamente utilizada na avaliação de resultados de classificação de imagens uma vez que as regiões de verdadeiros negativos não afetam a magnitude do coeficiente, desempenhando uma boa detecção ao desequilíbrio entre dois conjuntos de dados. Um Coeficiente de dados de 0 indica que não há sobreposição entre os dados, enquanto um valor de 1 significa que os dados têm sobreposição total (Silva Júnior *et al.* 2021). Por fim, o Coeficiente Kappa é uma técnica multivariada discreta utilizada em avaliações de acurácia, onde um coeficiente Kappa igual a 1 significa concordância perfeita, enquanto um valor próximo de zero significa que a concordância não é melhor do que seria esperado ao acaso (Foody, 2020).

Regressão Linear

Foi usado uma Regressão Linear para comparar a proporção de cada classe de ocupação do solo detectada do produto com a mostrada nos dados de referência (Eva e Lambin, 1998; Smith *et al.* 2007). Uma grade de 2×2 km foi criada sobre a cobertura do OLI e MUX, onde o Coeficiente de Determinação (R^2), angular e linear foram utilizadas como parâmetros de análise. Esta mesma

aplicação foi usada em análises anteriores (ROY e BOSCHETTI, 2009; GIGLIO et al 2018). Resumidamente, a fração das áreas de presença de classe em cada célula de grade na imagem

WorldCover foi agregada para comparar efetivamente a concordância espacial entre os produtos classificados derivados de menor resolução espacial.

Resultados e discussão

Efeitos Dos Parâmetros De Ajuste Nas Precisões De Classificação

Os resultados do teste para encontrar os melhores parâmetros do classificador SVM de combinação C e γ da função RBF no processo de pré-classificação do uso e ocupação do solo para todo o conjunto de dados MUX e OLI, é mostrado

na figura 4. Este tipo de análise de ajustamento do modelo de classificação é importante pois permite conhecer e alterar simultaneamente a flexibilidade dos limites de classificação do modelo SVM.

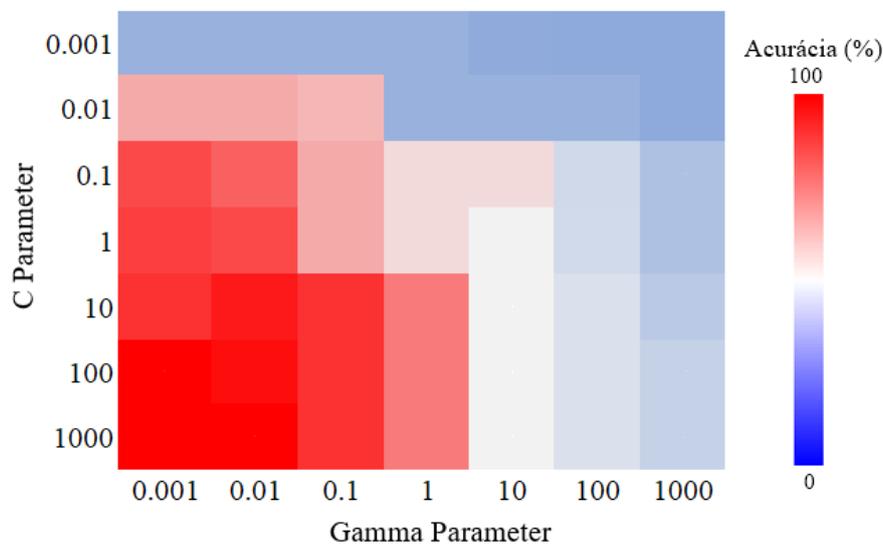


Figura 3. Combinação C e γ com a acurácia para o ajuste SVM

Os resultados obtidos na figura 3 mostram que a acurácia é fracamente influenciada pela variável C e muito sensível ao parâmetro gamma. Pois, como pode ser visto, com a diminuição do gamma (aumento da complexidade) a precisão do treinamento aumenta monotonamente até 100%, ou seja, até a modelo de precisão perfeita. Considerando as dependências apresentadas na figura 4, pode-se supor que a seleção de valores adequados e ótimos dos coeficientes gama e C consiste nas quais a acurácia de validação é a mais alta com o modelo de treinamento o mais eficaz possível. Nesse caso, entre as configurações de maior acurácia de aprendizado, o melhor valor de acerto foi obtido para o parâmetro gamma igual a 0,001 e parâmetro C igual a 1000, portanto esses valores dos parâmetros foram considerados ótimos e foram utilizados como parâmetros de entrada no processo de classificação.

Dessa forma, o comportamento do conjunto de dados demonstrado entra em conformidade com a teoria Mountrakis e Ogole Júnior, A. S.; Pacheco, A. P.

(2011), Bahari; Ahmad e Aboobaidar (2014), um gamma muito grande, o raio da área de influência dos vetores de suporte inclui apenas o próprio vetor de suporte e nenhuma regularização com C, será capaz de evitar o sobreajuste. Isso produz limites mais segmentados que são mais estreitos em torno dos vetores de suporte; o predictor é, portanto, mais provável de se ajustar a todos eles.

Análise de acurácia da Classificação SVM para os dados Landsat8-OLI e CBERS-4 MUX

Na Figura 4 mostram os Mapas de cobertura do solo no entorno do Reservatório Barra do Juá obtidos por meio da classificação SVM nas imagens em cores naturais dos sensores MUX e OLI. A classificação foi dividida para as classes de Caatinga arbórea, Caatinga arbustiva, Pastagem, Solo exposto, Área construída e Recursos hídricos. A análise detalhada da distribuição espacial dos componentes dessas matrizes pode oferecer uma visão sobre os prováveis processos que determinam

os padrões de uma paisagem, revelando permutas, ganhos, perdas e persistências (Braimoh, 2006).

Na região predomina-se a Caatinga arbustiva com e pequenos corpos d'água, correspondente à vegetação de baixa biomassa e solo com maior cobertura exposta, característico do bioma Caatinga no período de estiagem que desempenham por sua vez, importantes funções ecológicas, como fixação de vento e conservação

de água e a flora. A área de estudo apresenta diversidade florística, resultado de variadas condições fito-ecológicas. A paisagem natural quase perdeu suas características ecológicas primárias devido ao uso inadequado da atividade socioeconômica conseqüentemente, aumento em áreas suscetíveis à desertificação principalmente no setor sul (Batalha *et al.* 2001).

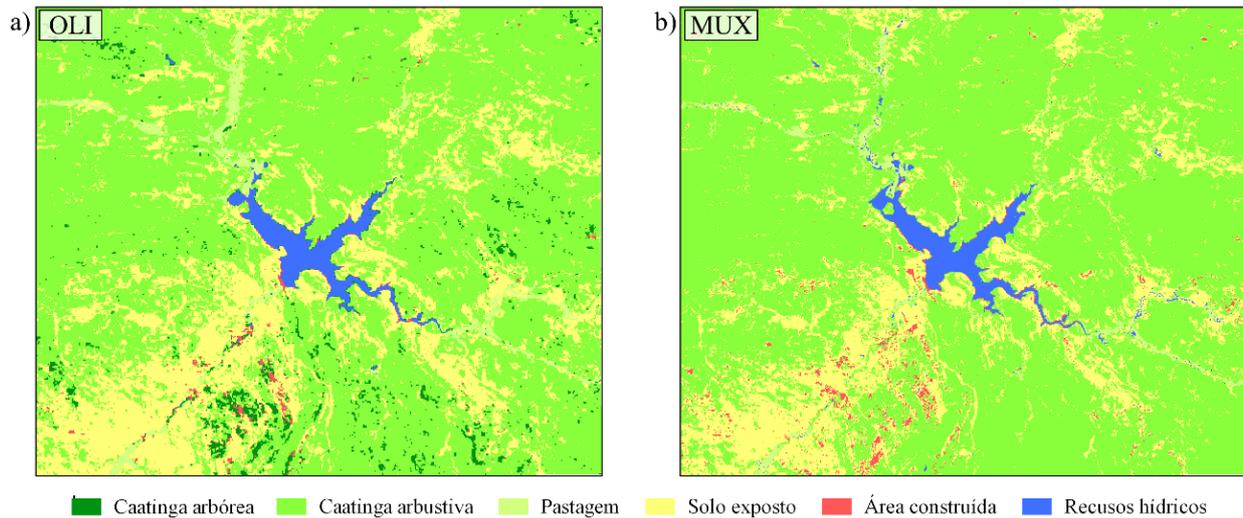


Figura 4. Mapa de Cobertura do Solo no entorno do Reservatório Barra do Juá-PE obtidos por uma cena Landsat8-OLI e CBERS-4 MUX

A classe de Caatinga arbórea, como mostrado visualmente nos mapas da figura (x e y) apresentaram as menores feições de área com destaque para o sensor MUX (1,62 Km²) enquanto o OLI (3,93Km²) e WorldCover (10,71Km²). A classe de Pastagem não apresentou significativas diferenças em relação ao WorldCover (L8:4,4Km² C4:3,83Km² e WC: 3,2Km²) enquanto a classe de Solo Exposto mostrou-se com diferenciação expressiva (L8: 41,81Km²; C4: 52,55Km² e WC: 28,66Km²) assim como a classe de Área Urbana (L8: 0,9 Km²; C4: 2,3 Km² e WC: 1,96 Km²). Para o Landsat-8 a classe Recursos hídricos apresentou maior aderência com os dados WorldCover em contrapartida o CBERS-4 mapeou quase o dobro (L8: 3,37 Km²; C4: 6,09 Km² e WC: 3,72 Km²).

Uma das etapas finais mais importantes no processo de classificação é a avaliação da precisão. O objetivo da avaliação da precisão é avaliar quantitativamente a eficácia com que os pixels foram amostrados nas classes corretas de cobertura do solo. Além disso, as ênfases principais para a seleção de pixels de avaliação de precisão estavam em áreas que podiam ser claramente identificadas em imagens WorldCover.

Para determinar a precisão de cada classificação, uma Matriz de Contingência foi criada com base nos produtos classificados (MUX e OLI) e de referência (WorldCover), onde foi possível determinar os coeficientes de Acurácia do Produtor (AP) e Acurácia do Usuário (AU) mostrados na Tabela 2.

Tabela 2. Acurácia do Usuário e do Produtor para as classes de cobertura do solo MUX e OLI

sendo	coef	Caat. Arbórea	Caat. Arbustiva	Pastagem	Solo exposto	Área urbana	Rec. Hídricos
MUX	AP%	10,32	91,86	70,12	78,08	31,84	92,4
	AU%	87,72	88,17	67,24	66,51	32,55	88,24
OLI	AP%	21,87	85,64	78,76	79,22	14,42	85,39
	AU%	65,57	89,63	39,9	54,68	31,31	93,19

Observa-se na Tabela 2, que a classe de Caatinga arbórea apresentou baixos de valores de (AP) e altos valores de (AU) para ambos os sensores. Já a classe de Caatinga arbustiva, de maior presença na área de estudo, apresentou altos valores de (AP) e (AU). A Classe de Pastagem apresentou altos valores de (AP) para ambos os sensores e um leve decréscimo de (AU) para o MUX e uma queda significativa para o OLI. Comportamento semelhante foi encontrado para a classe de Solo exposto, embora o OLI tenha se sobressaído com uma variação de aproximadamente 1% em relação ao MUX na (AP). A classe de Área urbana não apresentou

variações significativas nas estimativas de acurácia (31~32%) com exceção para o baixo rendimento de (AP) para o OLI (14,41%). A classe com os maiores valores de acurácia foi vista para o Recursos hídricos, com valores variando entre (80~90%) com destaque para o OLI na (AU) e o MUX na (AP). No geral, o OLI apresentou as maiores subestimações apresentando um erro de omissão variando entre (14~85%), principalmente para as classes de Caatinga arbórea e Área urbana, enquanto o C4 foram entre (8~69%). A Acurácia Global para o MUX foi de 83,24% e 79,64% para o OLI.

Tabela 3. Coeficientes DC e Kappa para as classes de cobertura do solo MUX e OLI

sendo	coef	Caat. Arbórea	Caat. Arbustiva	Pastagem	Solo exposto	Área urbana	Rec. Hídricos
MUX	DC	0,01	0,9	0,69	0,72	0,32	0,9
	Kappa	0,2	0,55	0,66	0,6	0,31	0,88
OLI	DC	0,33	0,88	0,53	0,65	0,2	0,89
	Kappa	0,63	0,61	0,39	0,46	0,3	0,93

A tabela 3 mostra os resultados obtidos pelo coeficiente Kappa e coeficiente de dados. O sensor MUX apresentou ligeiramente maiores estimativas de (CD) com destaque para as classes de Caatinga Arbórea e Recursos hídricos e uma exceção na classe de Caatinga arbórea com valor próximo a 0. Em relação ao Kappa, o OLI apresentou as melhores estimativas para as classes de vegetação Caatinga e Recursos hídricos, este com variação de aproximadamente 3% em relação ao MUX. Por fim o (CD) médio foi de 59 para o MUX e 58 para o OLI, o Kappa geral foi de 0,59 para o MUX e 0,54 para o OLI.

Análise de Regressão

Fig. 5 e fig. 6 mostram os gráficos de dispersão obtidos pela combinação de todas as células da grade 2km entre o mapa de referência e o mapa classificado por SVM. Resumidamente, a proporção de células de grade de resolução de 2 km detectadas como presença de classe pelos produtos OLI e MUX é comparada à proporção de área detectada pelos dados de referência; a inclinação e o deslocamento da linha de regressão são uma indicação da precisão da detecção da área queimada, enquanto o coeficiente de determinação (R²) é uma indicação da precisão (GLIGIO *et al.* 2018). A análise mostra que o produto MUX possui um R² e coeficiente angular com melhor rendimento em relação ao OLI para as classes de pastagem, solo exposto e área urbana e água.

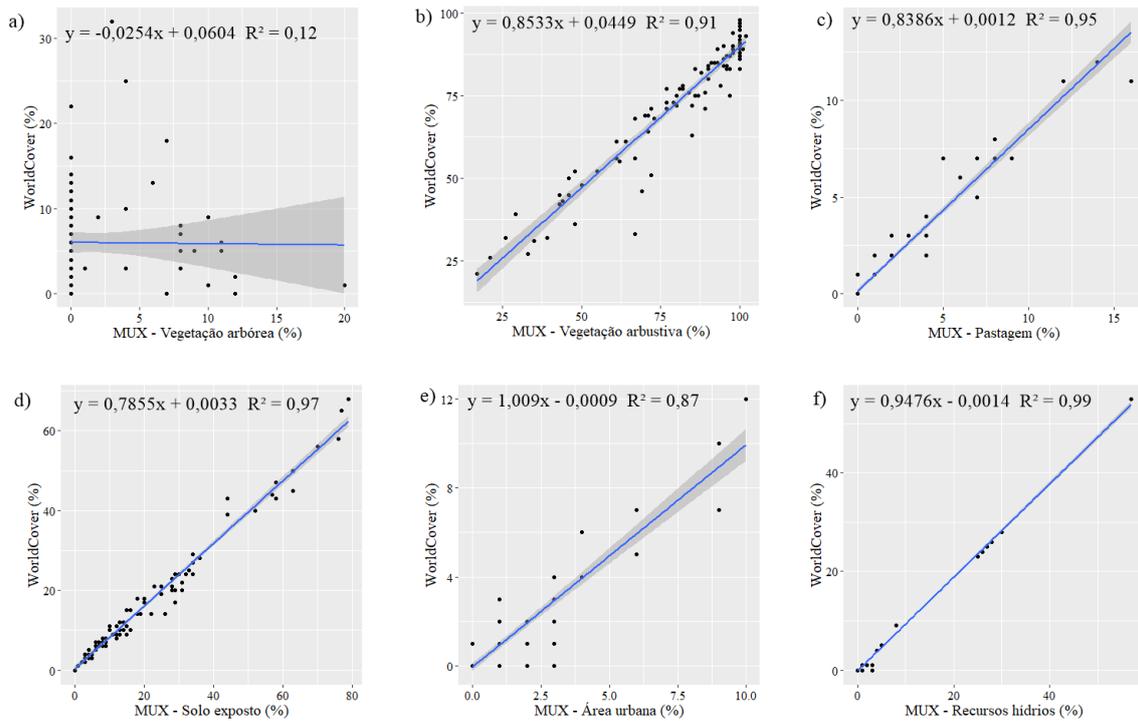


Figura 5. Gráficos de dispersão das proporções de células de grade de 2km rotuladas como classe de presença pelo produto MUX em relação à proporção rotulada como mapa de referência WorldCover.

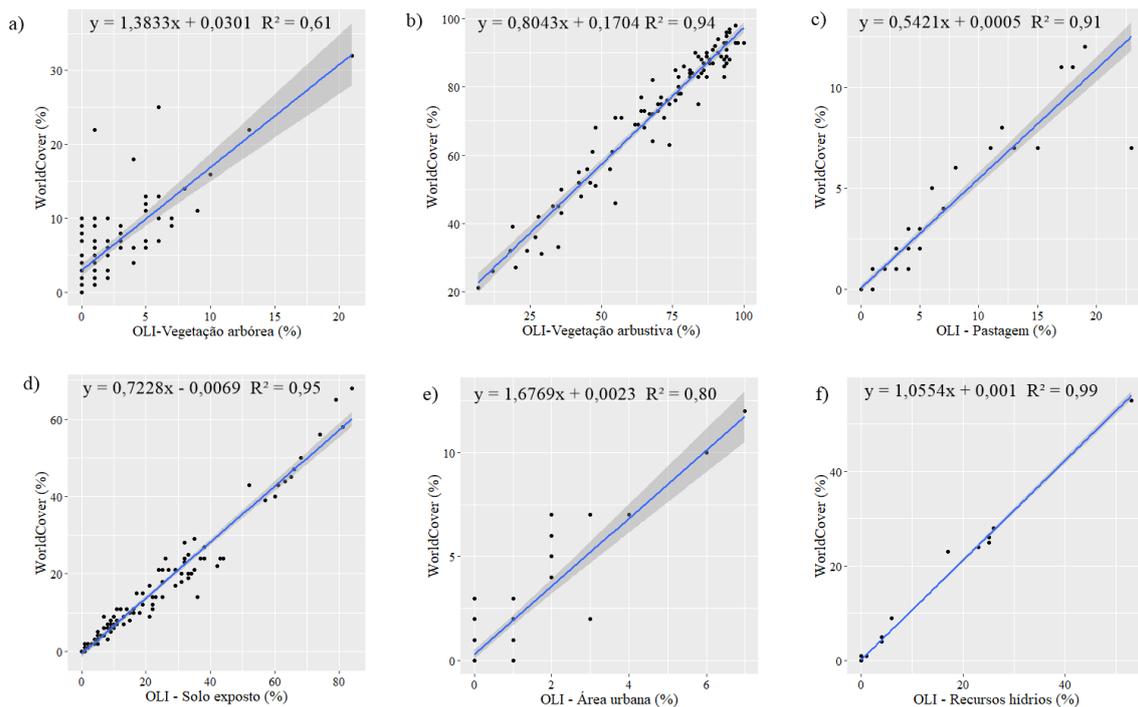


Figura 6. Gráficos de dispersão das proporções de células de grade de 2km rotuladas como classe de presença pelo produto OLI em relação à proporção rotulada como mapa de referência WorldCover.

O R^2 médio geral para cada sensor variou entre 81-86%, sendo melhor desempenho para o OLI com uma melhoria de aproximadamente 5%, o que é uma diferença insignificante, sem levar em consideração os *outliers* encontrados na classe de Caatinga arbórea, o que elevaria o R^2 médio para

aproximadamente 94% para o MUX. No geral, os R^2 obtidos nas regressões lineares entre os mapas classificados e o mapa de referência também são semelhantes nos dois satélites usando o classificador SVM. Embora ainda é possível observar uma concordância significativa com as

estimativas de acurácia do produtor. Por exemplo, a baixa Acurácia do produtor obtida na classe de Caatinga arbórea do MUX e OLI (10 e 21%) resultaram num R^2 de 0,12 e 0,61 respectivamente, além da classe de Recursos hídricos que apresentou Acurácia do produtor acima de 80% correspondente ao R^2 de 0,99 para ambos os sensores.

Os coeficientes lineares resultantes das regressões variam entre 0,0009 e 0,06 para o MUX, 0,0005 e 0,0301 para o OLI e elas passam no teste de significância, portanto, há uma boa concordância com os dados de referência e ambas as classificações são significativamente melhores do que um resultado aleatório. Já os menores desempenhos de classificação com base no coeficiente angular foram encontrados para as classes de Caatinga arbórea do MUX definida por coeficiente angular negativo e Área urbana, Caatinga arbórea e Pastagem para o OLI definida por incompatibilidades espaciais de aproximadamente de 30% comparado aos dados de referência. Em concordância com os resultados de acurácia, a classe de Recursos hídricos apresentou as melhores estimativas de coeficiente angular e linear com aderência espacial de aproximadamente 95% para ambos os sensores.

Parâmetros de ajuste do Classificador SVM

Neste estudo, foi usado a mesma condição de processamento do algoritmo para comparar os dados multiespectrais dos satélites CBERS-4 e do Landsat 8 para o mapeamento da cobertura da terra com base em parâmetros no efeito do ajuste ideais do classificador SVM. A acurácia geral resultante mostrou que o algoritmo não paramétrico SVM ofereceu uma boa classificação para ambos os conjuntos de dados, e método Kernel RBF oferece a saída ideal. A robustez do SVM na classificação da cobertura da terra pode ser explicada pela capacidade do algoritmo de operar eficientemente com conjuntos de dados multicolineares e multiespectrais. Resumidamente, o classificador SVM emprega a transformação implicitamente o espaço de entrada em outro espaço de recursos de alta dimensão. Esse recurso permite maior estabilidade do classificador, pois o algoritmo consegue discriminar pequenas variações nos dados de entrada, aumentando a precisão da classificação.

Implicação do mapa de cobertura do solo no entorno da Barragem Barra do Juú

As informações de seis classes de cobertura da terra geradas pelas imagens OLI e MUX são essenciais para uma melhor

compreensão de muitos dos processos na paisagem na área de estudo. Por exemplo, as informações sobre a classe "área urbana" permitem o monitoramento das tendências na urbanização e fornece uma camada de base em grande escala para um mapeamento mais detalhado da zona climática local de áreas urbanas, que está no foco de interesse de muitos estudos (KRANJĀLĀ *et al.* 2019). A informação dos tipos de vegetação (Arbórea e arbustiva), que desempenham um papel crítico na melhoria do ecossistema, portanto, é benéfica para investigar o ciclo do carbono e possíveis devastações ao meio ambiente. Nesse sentido, a classe "água" fornece informações para a tomada de decisões sobre a gestão de recursos hídricos. A transição da vegetação para as classes de "solo exposto" e "pastagem" são uteis para entender o status e o rastreamento da agricultura e desertificação (LI *et al.* 2020; HUANG *et al.* 2018).

A comparação dos mapas gerados por classificadores e dados orbitais com o mapa de referência é imprescindível, uma vez que imagem de satélite utilizada afeta os resultados e, portanto, esta é uma das etapas principais na produção de mapas de cobertura da terra. Diante disso, outros estudos trouxeram resultados semelhantes e métodos variados de se obter mapas cobertura do solo, como por exemplo, Rudrapal *et al.* (2015) que usou o (SVM) para gerar a cobertura do solo com 6 classes utilizando uma imagem hyperespectral e obteve uma precisão geral de 93,23 % enquanto Ghayour *et al.* (2021) encontrou uma precisão geral de 94% na classificação do uso do solo da cidade de Saqqez na província do Curdistão, oeste do Irã. Em outro estudo, Jia *et al.* (2014) tentou classificar a cobertura do solo em Pequim, China, comparando as imagens do Landsat 7 e Landsat 8 e usando algoritmos supervisionados MLC e SVM. Eles descobriram que o algoritmo SVM com uma precisão geral de 91,03% e o coeficiente Kappa de 0,89 é mais preciso em comparação com o algoritmo MLC com a precisão geral de 90,4% e o coeficiente Kappa de 0,88. Din *et al.* (2021) obteve acurácias do produtor e do usuário acima de 90% na classificação espaço temporal nos mapas de mudança de cobertura do solo e dinâmica de expansão urbana de Hyderabad, Paquistão e obteve uma precisão de 98,3% para o ano de 2020, já Deilmai *et al.* (2014) apresentou acurácia do produtor e do usuário acima de 80% na classificação do uso do solo na Malásia como acurácia geral de 91,67 (%) por meio do classificador SVM. Mei *et al.* (2015) comparou Floresta Aleatória (RF), Árvore de Decisão (DT) e Máquina de Vetores de Suporte (SVM) em

abordagens baseadas em pixels e baseadas em objetos para classificar a mudança da cobertura da terra de 1990 a 2010 usando imagem Landsat-8. Eles concluíram que o classificador SVM baseado em objeto tem um desempenho melhor do que RF e DT (precisão geral = 93,54%). Seus resultados indicaram que a expansão das áreas construídas (com aumento anual de 4,53%) causou a variação mais significativa (com queda anual em torno de 0,81% em terrenos naturais).

Análise de configurações espectrais de entrada

Como a primeira configuração de entrada, as bandas espectrais do Landsat-8 fornecem uma variedade de informações espectrais, que contribuem para toda a classificação. É compreensível que um conjunto de dados com diferentes atributos tenha maior capacidade no reconhecimento das classes de cobertura do solo, o que facilita a melhoria da precisão geral da classificação.

A faixa de comprimento de onda das bandas espectrais do OLI e o MUX é ligeiramente diferente e, como mostrado na Tabela 1, o Landsat-8 fornece informações espectrais alternativas que podem discriminar melhor a variabilidade entre as classes de cobertura do solo. Por exemplo, como mostrado na Tabela 3, a maior acurácia do produtor para a classe de caatinga arbórea e pastagem foram provavelmente resultantes da maior sensibilidade espectral do Landsat-8 em caracterizar diferentes

tipos de cobertura vegetal. Ou seja, o bom desempenho na classificação obtidas para o OLI na classe de caatinga arbórea, pode ser atribuída sua estrutura físico-química de arbusto perene caracterizado por alta densidade foliar quando comparado a outras vegetações (Gonçalves *et al.* 2021). A alta concentração de pigmento de clorofila produzida por meio da fotossíntese e a alta densidade da folhagem a distinguem de outras espécies vegetais e classes de uso do solo, principalmente na região do infravermelho próximo e médio do espectro eletromagnético (GlasS, 2019).

Resumidamente, há muitas fitofisionomias na área de estudo, para um bom desempenho na classificação por imagens orbitais, é importante que a configuração de entrada seja espectralmente preciso, para identificar a variabilidade da faixa de valores das classes de cobertura da terra com maior dessemelhança entre classes possível. A informação espectral de 4 bandas do MUX, podem ser reduzidas quando comparadas com as 6 bandas fornecidas pelo OLI utilizada neste trabalho, indicando que os modelos de banda mais estreita exploram regiões espectrais específicas sensíveis às características das classes de uso do solo e reduzem as regiões espectrais redundantes ou insignificantes, enquanto os modelos de banda larga fazem a média das informações em regiões espectrais maiores (Fig.7).

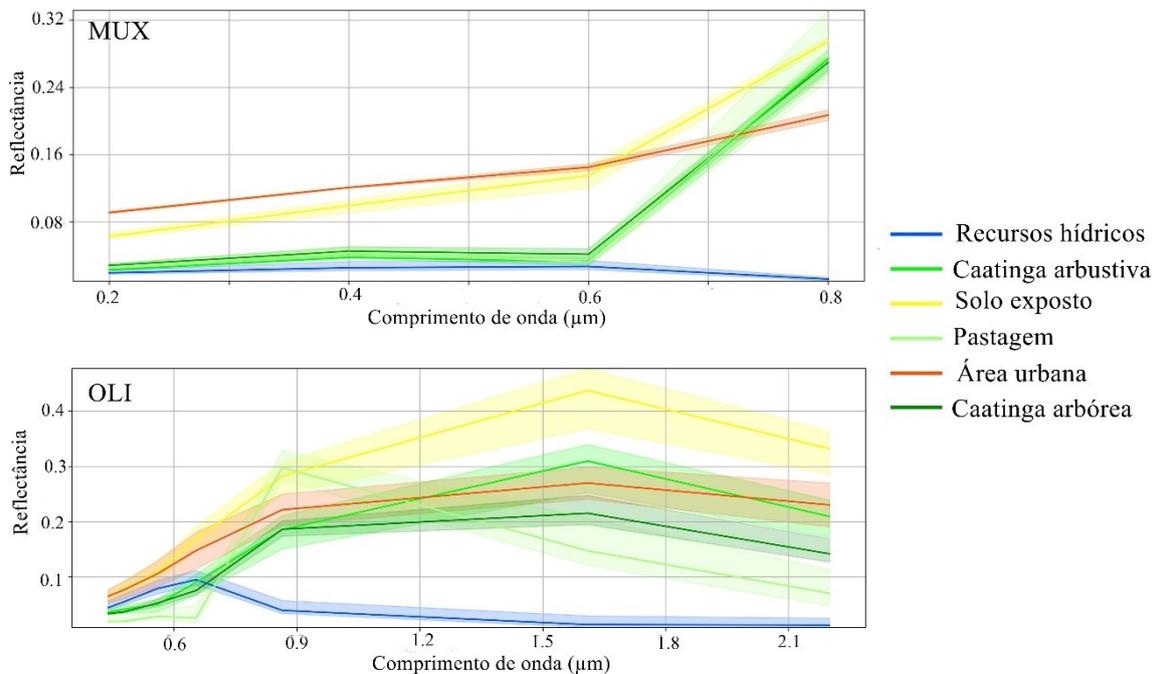


Figura 7. A assinatura espectral das cinco coberturas do solo com base em MUX e OLI na área de estudo.

Muitos objetos terrestres com espectros semelhantes não podem ser diferenciados apenas com base na informação espectral. No entanto, a classificação usando recursos espaciais pode resolver efetivamente os problemas de pixels espectralmente misturado aumentando assim a precisão da extração dos objetos. Ou seja, o tipo de pixel a ser classificado não depende apenas das características espectrais da própria célula, mas também dos tipos de pixels circundantes. A influência desses pixels se potencializa quando a sua resolução espacial possibilita a generalização dos sinais espectrais gerados pelos diferentes tipos de cobertura do solo dentro da área do pixel, ocasionando problemas de mistura espectral e conseqüentemente má previsão de classes. Nas análises de acurácia da classificação e regressão linear, a resolução espacial de 20 m do MUX se sobressaiu ligeiramente em relação ao OLI, o que provavelmente foi o causador das melhores estimativas de acurácia e previsão. Alvos facilmente identificados pelo MUX podem ter sido superestimado ou omitidos pelo sensor OLI, principalmente para as classes de feições de menor extensão, heterogêneas e pontuais. Apesar da melhor resolução espectral do OLI, essa característica não foi capaz de potencializar, por exemplo, as estimativas de acurácia nas classes de solo exposto e área urbana. É hipotetizado que essas classes têm assinaturas espectrais semelhantes devido às suas proximidades nos parâmetros de textura, cores e morfologias, o que podem causar confusões até nos mais robustos classificadores. Dessa forma, o mosaico de pixels com maior detalhamento encontrado no MUX, contribui para a diminuição dessas confissões além de conseguir detectar pequenas feições de classes de área urbana, que são bem comuns na caatinga nordestina.

Considerações finais de acurácia por classe

As precisões para a classe de recursos hídricos foram altas. As áreas úmidas são facilmente classificadas por conta de suas características espectrais peculiares, caracterizadas por baixo albedo, além de sua formação homogênea do polígono do espelho d'água que causa diminuição de problemas com mistura espectral e erros de omissão e comissão. Assim como a classe de recursos hídricos, as classes de caatinga arbustiva apresentaram altas estimativas de acurácia e aderência espacial ($R^2 > 0,9$) com os dados WC. Este resultado pode estar relacionado à forma homogênea em que está classe está distribuída. Classe de feições mais compactas possibilita ao classificador alocar corretamente

com os dados de referência, sobressaindo-se a aos erros relacionados a pixels isolados de outras classes, aliviando o problema de classificação colocado por pixels espectralmente misturados.

Por ser uma região rural, grande parte da superfície é composta por casas dispersas no campo e elementos lineares, como estradas e ferrovias, que são muito pequenos para serem detectados corretamente por ambos os satélites. Dessa forma, como mostrado na Tabelas 2 e 3 e as regressões das figuras 6 e 7, a classe de área urbana apresentou resultados moderadamente baixos. Além disso, é possível notar, principalmente nas assinaturas espectrais dos dados MUX (figura 5) que a classe de cobertura urbana são espectralmente muito semelhantes com a classe de solo exposto. Áreas em construção ou terrenos associados a estradas são como áreas sem vegetação, em termos de superfície, possui grande relevância, e por isso, é uma fonte de erro e incerteza na comparação entre os mapas de referência. Com acurácia do produtor acima de 70% para ambos os sensores, as classes de pastagem e solo exposto, dependem do regime de precipitação/crescimento da vegetação e colheita agrícola na área de estudo. Por se tratar de cenas no período seco do semiárido, porções de vegetação aparecem em menor quantidade na área de estudo, diminuindo problemas de mistura espectral, e conseqüentemente não apresentaram variações importantes com os dados WC que também são do período seco.

Conclusões

Os resultados obtidos para a classificação de imagens MUX e OLI foram consistentes e ofereceram uma boa precisão e confiabilidade para uso geral no monitoramento da cobertura do solo no semiárido pernambucano. Espera-se que o método seja aplicável a uma ampla gama de imagens de sensoriamento remoto de diferentes fontes de dados, com boas perspectivas para o estudo da cobertura do solo em uma ampla gama de situações e a extração de informações detalhadas para análise. Diferentes parâmetros de ajuste foram aplicados ao classificador SVM a fim de determinar seu efeito na precisão da classificação cobertura da terra.

Como resultado da avaliação da precisão, acurácia Global para o MUX foi de 83,24% e 79,64% para o OLI. Embora pareça que o MUX represente a melhor classificação do que o OLI em geral, essa situação pode mudar se diferentes métodos de classificação e estatísticas forem usados. Ou seja, se algumas das partes das imagens

de cobertura do solo forem consideradas, o OLI ou na sua forma fusionada, podem oferecer melhores resultados para algumas áreas de vegetação do que o MUX, como fica claro nas Tabelas 2 e 3. O MUX apresentou algumas melhorias graças à sua melhor resolução espacial, mas não é uma diferença notável para ignorar ou substituir o uso de OLI. Portanto, ambos os satélites podem e devem coexistir e ser usados em conjunto para aumentar a disponibilidade de dados proporcionando um a falta de imagens do outro para que se tenha os melhores resultados possíveis em pesquisas de sensoriamento remoto.

Referências

- Antonio da Silva Júnior, J., Joaquim da Silva Júnior, U., & Da Penha Pacheco, A. (2021). Análise de acurácia para o mapeamento de áreas queimadas utilizando uma cena VIIRS 1Km e classificação por Random Forest. *Revista Brasileira de Geografia Física*, 14(6), 3225. <https://doi.org/10.26848/rbgf.v14.6.p3225-3240>
- APAC. (2019). APAC - Agência Pernambucana de Águas e Climas - Início. APAC - Agência Pernambucana de Águas E Climas. <https://www.apac.pe.gov.br/>
- Batalha, M. A., Mantovani, W., & Mesquita Júnior, H. N. de. (2001). Vegetation structure in cerrado physiognomies in South-eastern Brazil. *Brazilian Journal of Biology*, 61(11), 475–483. <https://doi.org/10.1590/S1519-69842001000300018>
- Benbriqa, H., Abnane, I., Idri, A., & Tabiti, K. (2021). Deep and Ensemble Learning Based Land Use and Land Cover Classification. *Computational Science and Its Applications – ICCSA 2021*, 21(01), 588–604. https://doi.org/10.1007/978-3-030-86970-0_41
- Bolton, D. K., Gray, J. M., Melaas, E. K., Moon, M., Eklundh, L., & Friedl, M. A. (2020). Continental-scale land surface phenology from harmonized Landsat 8 and Sentinel-2 imagery. *Remote Sensing of Environment*, 240(45), 111685. <https://doi.org/10.1016/j.rse.2020.111685>
- Braimoh, A. K. (2006). Random and systematic land-cover transitions in northern Ghana. *Agriculture, Ecosystems & Environment*, 113(1-4), 254–263. <https://doi.org/10.1016/j.agee.2005.10.019>
- Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1), 35–46. [https://doi.org/10.1016/0034-4257\(91\)90048-b](https://doi.org/10.1016/0034-4257(91)90048-b)
- Deilmai, B. R., Ahmad, B. B., & Zabihi, H. (2014). Comparison of two Classification methods (MLC and SVM) to extract land use and land cover in Johor Malaysia. *IOP Conference Series: Earth and Environmental Science*, 20(91), 012052. <https://doi.org/10.1088/1755-1315/20/1/012052>
- Dragozi, E., Gitas, I., Stavrakoudis, D., & Theocharis, J. (2014). Burned Area Mapping Using Support Vector Machines and the FuzCoC Feature Selection Method on VHR IKONOS Imagery. *Remote Sensing*, 6(12), 12005–12036. <https://doi.org/10.3390/rs61212005>
- ESA. (2021). Sentinel-2 - Missions - Resolution and Swath - Sentinel Handbook. <https://sentinel.esa.int/web/sentinel/missions/sentinel-2/instrument-payload/resolution-and-swath>
- Eva, H., & Lambin, E. F. (1998). Remote Sensing of Biomass Burning in Tropical Regions. *Remote Sensing of Environment*, 64(3), 292–315. [https://doi.org/10.1016/s0034-4257\(98\)00006-6](https://doi.org/10.1016/s0034-4257(98)00006-6)
- Fichera, C. R., Modica, G., & Pollino, M. (2012). Land Cover classification and change-detection analysis using multi-temporal remote sensed imagery and landscape metrics. *European Journal of Remote Sensing*, 45(1), 1–18. <https://doi.org/10.5721/eujrs20124501>
- Foody, G. M. (2020). Explaining the unsuitability of the kappa coefficient in the assessment and comparison of the accuracy of thematic maps obtained by image classification. *Remote Sensing of Environment*, 239(01), 111630. <https://doi.org/10.1016/j.rse.2019.111630>
- Giannini, M. F. C., Harari, J., & Ciotti, A. M. (2017). The use of CBERS (China-Brazil Earth Resources Satellite) to trace the dynamics of total suspended matter at an urbanized coastal area. *Brazilian Journal of Oceanography*, 65(2),

- 309–323. <https://doi.org/10.1590/s1679-87592017135006502>
- Gibril, M. B. A., Bakar, S. A., Yao, K., Idrees, M. O., & Pradhan, B. (2016). Fusion of RADARSAT-2 and multispectral optical remote sensing data for LULC extraction in a tropical agricultural area. *Geocarto International*, 32(7), 735–748. <https://doi.org/10.1080/10106049.2016.1170893>
- Giglio, L., Boschetti, L., Roy, D. P., Humber, M. L., & Justice, C. O. (2018). The Collection 6 MODIS burned area mapping algorithm and product. *Remote Sensing of Environment*, 217(06), 72–85. <https://doi.org/10.1016/j.rse.2018.08.005>
- GLASS. (2013). *Interpreting Aerial Photographs to Identify Natural Hazards*. Elsevier. <https://doi.org/10.1016/c2012-0-06726-9>
- Gonçalves, R. V. S., Cardoso, J. C. F., Oliveira, P. E., & Oliveira, D. C. (2021). Changes in the Cerrado vegetation structure: insights from more than three decades of ecological succession. *Web Ecology*, 21(08), 55–64. <https://doi.org/10.5194/we-21-55-2021>
- Hosseini, M., McNairn, H., Mitchell, S., Robertson, L. D., Davidson, A., Ahmadian, N., Bhattacharya, A., Borg, E., Conrad, C., Dabrowska-Zielinska, K., de Abelleira, D., Gurdak, R., Kumar, V., Kussul, N., Mandal, D., Rao, Y. S., Saliendra, N., Shelestov, A., Spengler, D., & Verón, S. R. (2021). A Comparison between Support Vector Machine and Water Cloud Model for Estimating Crop Leaf Area Index. *Remote Sensing*, 13(7), 1348. <https://doi.org/10.3390/rs13071348>
- Hu, B., Xu, Y., Huang, X., Cheng, Q., Ding, Q., Bai, L., & Li, Y. (2021). Improving Urban Land Cover Classification with Combined Use of Sentinel-2 and Sentinel-1 Imagery. *ISPRS International Journal of Geo-Information*, 10(8), 533. <https://doi.org/10.3390/ijgi10080533>
- Huang, C., Yang, J., & Jiang, P. (2018). Assessing Impacts of Urban Form on Landscape Structure of Urban Green Spaces in China Using Landsat Images Based on Google Earth Engine. *Remote Sensing*, 10(10), 1569. <https://doi.org/10.3390/rs10101569>
- Jia, K., Wei, X., Gu, X., Yao, Y., Xie, X., & Li, B. (2014). Land cover classification using Landsat 8 Operational Land Imager data in Beijing, China. *Geocarto International*, 29(8), 941–951. <https://doi.org/10.1080/10106049.2014.894586>
- Kranjčić, N., Medak, D., Župan, R., & Rezo, M. (2019). Support Vector Machine Accuracy Assessment for Extracting Green Urban Areas in Towns. *Remote Sensing*, 11(6), 655. <https://doi.org/10.3390/rs11060655>
- Lagbas, A. J. (2019). Social valuation of regulating and cultural ecosystem services of Arroceros Forest Park: A man-made forest in the city of Manila, Philippines. *Journal of Urban Management*, 8(1), 159–177. <https://doi.org/10.1016/j.jum.2018.09.002>
- Lamine, S., Petropoulos, G. P., Singh, S. K., Szabó, S., Bachari, N. E. I., Srivastava, P. K., & Suman, S. (2017). Quantifying land use/land cover spatio-temporal landscape pattern dynamics from Hyperion using SVMs classifier and FRAGSTATS®. *Geocarto International*, 33(8), 862–878. <https://doi.org/10.1080/10106049.2017.1307460>
- Li, C., Wang, J., Wang, L., Hu, L., & Gong, P. (2014). Comparison of Classification Algorithms and Training Sample Sizes in Urban Land Classification with Landsat Thematic Mapper Imagery. *Remote Sensing*, 6(2), 964–983. <https://doi.org/10.3390/rs6020964>
- Li, Q., Qiu, C., Ma, L., Schmitt, M., & Zhu, X. (2020). Mapping the Land Cover of Africa at 10 m Resolution from Multi-Source Remote Sensing Data with Google Earth Engine. *Remote Sensing*, 12(4), 602. <https://doi.org/10.3390/rs12040602>
- Liu, Q., Song, H., Liu, G., Huang, C., & Li, H. (2019). Evaluating the Potential of Multi-Seasonal CBERS-04 Imagery for Mapping the Quasi-Circular Vegetation Patches in the Yellow River Delta Using Random Forest. *Remote Sensing*, 11(10), 1216. <https://doi.org/10.3390/rs11101216>
- Mei, J., Liu, M., Wang, Y.-F., & Gao, H. (2016). Learning a Mahalanobis Distance-Based Dynamic Time Warping Measure for Multivariate Time Series Classification. *IEEE Transactions on Cybernetics*, 46(6), 1363–1374. <https://doi.org/10.1109/tcyb.2015.2426723>
- Meyer, D., Dimitriadou, E., Hornik, K., Weingessel, A., Leisch, F., C++-code), C.-C. C. (libsvm, & C++-code), C.-C. L. (libsvm. (2022, June 7). e1071: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien. R-Packages. <https://cran.r-project.org/web/packages/e1071/index.html>
- Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), 247–259. <https://doi.org/10.1016/j.isprsjprs.2010.11.001>

- Naikoo, M. W., Rihan, M., Ishtiaque, M., & Shahfahad. (2020). Analyses of land use land cover (LULC) change and built-up expansion in the suburb of a metropolitan city: Spatio-temporal analysis of Delhi NCR using landsat datasets. *Journal of Urban Management*, 9(01). <https://doi.org/10.1016/j.jum.2020.05.004>
- NASA. (2013, June 28). Spectral Response of the Operational Land Imager In-Band, Band-Average Relative Spectral Response | Landsat Science. Spectral Response of the Operational Land Imager In-Band, Band-Average Relative Spectral Response. <https://landsat.gsfc.nasa.gov/article/preliminary-spectral-response-of-the-operational-land-imager-in-band-band-average-relative-spectral-response/>
- Pal, M., & Mather, P. M. (2005). Support vector machines for classification in remote sensing. *International Journal of Remote Sensing*, 26(5), 1007–1011. <https://doi.org/10.1080/01431160512331314083>
- Parida, B. R., & Mandal, S. P. (2020). Polarimetric decomposition methods for LULC mapping using ALOS L-band PolSAR data in Western parts of Mizoram, Northeast India. *SN Applied Sciences*, 2(6). <https://doi.org/10.1007/s42452-020-2866-1>
- Pereira, A., Pereira, J., Libonati, R., Oom, D., Setzer, A., Morelli, F., Machado-Silva, F., & de Carvalho, L. (2017). Burned Area Mapping in the Brazilian Savanna Using a One-Class Support Vector Machine Trained by Active Fires. *Remote Sensing*, 9(11), 1161. <https://doi.org/10.3390/rs9111161>
- Pinto, C., Ponzoni, F., Castro, R., Leigh, L., Mishra, N., Aaron, D., & Helder, D. (2016). First in-Flight Radiometric Calibration of MUX and WFI on-Board CBERS-4. *Remote Sensing*, 8(5), 405. <https://doi.org/10.3390/rs8050405>
- Roy, A., & Inamdar, A. B. (2019). Multi-temporal Land Use Land Cover (LULC) change analysis of a dry semi-arid river basin in western India following a robust multi-sensor satellite image calibration strategy. *Heliyon*, 5(4), e01478. <https://doi.org/10.1016/j.heliyon.2019.e01478>
- Sheykhmousa, M., Mahdianpari, M., Ghanbari, H., Mohammadimanesh, F., Ghamisi, P., & Homayouni, S. (2020). Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13(04), 6308–6325. <https://doi.org/10.1109/jstars.2020.3026724>
- Silva Junior, J. A. da, & Pacheco, A. D. P. (2020). Análise do Modelo Linear de Mistura Espectral na Avaliação de Incêndios Florestais no Parque Nacional do Araguaia, Tocantins, Brasil: Imagens EO-1/Hyperion e Landsat-7/ETM+. *Anuário Do Instituto de Geociências*, 43(4). https://doi.org/10.11137/2020_4_440_450
- Simões, J. M., Almeida, F. T. de, Uliana, E. M., & Vendrusculo, L. G. (2021). Uso de sensoriamento remoto no monitoramento de sólidos em suspensão do reservatório de uma usina hidrelétrica na transição Cerrado-Amazônia. *Gaia Scientia*, 15(3). <https://doi.org/10.22478/ufpb.1981-1268.2021v15n3.57559>
- Smith, D. M., Tabrett, S. J., Glencross, B. D., Irvin, S. J., & Barclay, M. C. (2007). Digestibility of lupin kernel meals in feeds for the black tiger shrimp, *Penaeus monodon*. *Aquaculture*, 264(1-4), 353–362. <https://doi.org/10.1016/j.aquaculture.2006.12.002>
- Thanh Noi, P., & Kappas, M. (2017). Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. *Sensors (Basel, Switzerland)*, 18(1), 18. <https://doi.org/10.3390/s18010018>
- Tharwat, A. (2018). Classification assessment methods. *Applied Computing and Informatics*, 01(06). <https://doi.org/10.1016/j.aci.2018.08.003>
- Ul Din, S., & Mak, H. W. L. (2021). Retrieval of Land-Use/Land Cover Change (LUCC) Maps and Urban Expansion Dynamics of Hyderabad, Pakistan via Landsat Datasets and Support Vector Machine Framework. *Remote Sensing*, 13(16), 3337. <https://doi.org/10.3390/rs13163337>
- Vapnik, V. The support vector method of function estimation. In *Nonlinear Modeling*; Springer: Berlin/Heidelberg, Germany, 1998; pp. 55–85.
- Wulder, M. A., Loveland, T. R., Roy, D. P., Crawford, C. J., Masek, J. G., Woodcock, C. E., Allen, R. G., Anderson, M. C., Belward, A. S., Cohen, W. B., Dwyer, J., Erb, A., Gao, F., Griffiths, P., Helder, D., Hermosilla, T., Hipple, J. D., Hostert, P., Hughes, M. J., & Huntington, J. (2019). Current status of Landsat program, science, and applications. *Remote Sensing of Environment*, 225(06), 127–147. <https://doi.org/10.1016/j.rse.2019.02.015>
- Yan, J., Wang, L., Song, W., Chen, Y., Chen, X., & Deng, Z. (2019). A time-series classification approach based on change detection for rapid land cover mapping. *ISPRS Journal of*

Photogrammetry and Remote Sensing, 158(10), 249–262.

<https://doi.org/10.1016/j.isprsjprs.2019.10.003>

Zanaga, D., Van De Kerchove, R., De Keersmaecker, W., Souverijns, N., Brockmann, C., Quast, R., Wevers, J., Grosu, A., Paccini, A., Vergnaud, S., Cartus, O., Santoro, M., Fritz, S., Georgieva, I., Lesiv, M., Carter, S., Herold, M., Li, L., Tsundbazar, N.-E., & Ramoino, F. (2021, October 20). ESA WorldCover 10 m 2020 v100.

Zenodo;

Zenodo.

<https://zenodo.org/record/5571936#.ZD3jzHbMLIU>

Zeng, L., Wardlow, B. D., Xiang, D., Hu, S., & Li, D. (2020). A review of vegetation phenological metrics extraction using time-series, multispectral satellite data. *Remote Sensing of Environment*, 237(04), 111511. <https://doi.org/10.1016/j.rse.2019.111511>