

Emprego de classificação orientada a objeto para atualização de área de imóveis urbanos no recadastramento imobiliário

Thiago A. S. S. Cortez¹, Vanessa C. O. Souza¹, Rafael M. D. Frinhani¹, Melise M. V. Paula¹

¹Instituto de Matemática e Computação – Universidade Federal de Itajubá (IMC-UNIFEI)
Caixa Postal 50 – 37500-903 – Itajubá – MG – Brasil

Abstract. *Real estate re-registration gives municipalities fiscal justice and land use updating. However, performing the re-registration is expensive, even with geotechnologies. This work studied automatic classification methods of orthophotos obtained by UAVs, aiming to identify roofs in urban areas for real estate re-registration purposes. The best result occurred using the GEOBIA technique with Random Forest classification with an accuracy of 84.58% using spectral and texture data. Despite the promising results, the method is still unsuitable for updating real estate data.*

Resumo. *O recadastramento imobiliário confere aos municípios justiça fiscal e atualização do uso da terra. Porém, é um processo custoso e manual, mesmo com o uso de geotecnologias. Este trabalho avaliou o uso da classificação orientada a objetos (GEOBIA) para identificar edificações em área urbana a partir de ortofotos geradas com VANTs, para fins de recadastramento imobiliário. Os melhores resultados foram obtidos com o classificador Random Forest, cuja acurácia balanceada foi de 84,58%. Apesar dos bons resultados, o método ainda não é indicado para atualizar dados imobiliários.*

1. Introdução

O recadastramento imobiliário objetiva atualizar a base de dados municipal. Em especial, informações relativas aos contribuintes, logradouros e imóveis [Brasil 2009]. Este processo confere justiça fiscal aos munícipes, uma vez que não se limita a fazer com que todos paguem seus impostos, mas que paguem um valor justo. Ademais, impacta as receitas fiscais do município, apoia o planejamento urbano, influencia os valores imobiliários e afeta os procedimentos de gestão do solo e ordenamento do território [Cienciała et al. 2021].

A Lei de Responsabilidade Fiscal [Brasil 2000] estabelece, de forma indireta, que os municípios realizem o recadastramento imobiliário para não ter a arrecadação fiscal do município diminuída por omissão na atualização do cadastro imobiliário, o que constitui renúncia de receita. Já a Portaria 511/09 [Brasil 2009] estabelece que o recadastramento gere (ou atualize) uma base georreferenciada.

A metodologia tradicional de recadastramento considera a medição *in loco* dos imóveis para atualizar sua área, podendo levar meses para que mapas atualizados sejam produzidos. Por isso, técnicas fotogramétricas podem ser utilizadas como alternativa, uma vez que permitem alta precisão de localização e rápida produção de dados [Karataş and Altınışık 2020]. Independente da técnica utilizada, os limites legais dos imóveis devem ser obtidos com precisão adequada para garantir corretude na localização do imóvel e na respectiva área [Brasil 2009].

Nos projetos de recadastramento subsidiados por imagens¹, o processo principal é chamado de vetorização, onde analistas utilizam *softwares* especializados para contornar manualmente os telhados identificados nas imagens de forma a gerar geometrias (polígonos) que representam as edificações. Nesse caso, a área do imóvel é a área de projeção do telhado. Esse processo pode ser o gargalo dos projetos de recadastramento por ser manual e depender da experiência do analista.

A classificação automática de imagens apresenta-se como uma alternativa à vetorização manual. Por isso, diversos autores têm aplicado essa técnica para identificar coberturas em área urbana (telhados) [Chen et al. 2018, Kim et al. 2011, Jia et al. 2022, Pulinja Subrahmanya et al. 2021, Trevisiol et al. 2021]. A classificação automática tende a minimizar o esforço da vetorização manual e encurtar o prazo para obtenção dos resultados.

Para fins de recadastramento imobiliário, é necessário o uso de imagens de altíssima resolução espacial² (*Very High Resolution* - VHR). Neste caso, cada pixel equivale a uma área entre 0.3 e 1m no solo [Shao et al. 2021]. Segundo [Myint and Stow 2011], as classificações de imagens que utilizam abordagens baseadas em objetos são mais aplicáveis a dados de alta resolução espacial, onde os objetos de interesse são maiores do que o elemento de resolução do solo. Dessa forma, neste trabalho a metodologia de classificação orientada a objetos GEOBIA - *Geographic Object-Based Image Analysis* foi utilizada [Blaschke 2010]. Diferente das classificações por *pixel*, a GEOBIA explora grupos de *pixels* semelhantes para identificar objetos em uma imagem a partir de um processo de segmentação. Posteriormente há uma extração de atributos desses segmentos e a classificação automática dos mesmos [Chen et al. 2018, Myint and Stow 2011].

O objetivo deste trabalho foi avaliar o uso de classificação semi-automática na atualização da área de imóveis em processos de recadastramento imobiliário. Para tanto, a partir de imagens de alta resolução espacial e geométrica (ortofotos) obtidas por VANTs (Veículos Aéreos Não Tripulados) foram realizadas classificações supervisionadas de edificações utilizando a metodologia GEOBIA em conjunto com algoritmos de aprendizado de máquina.

O restante do trabalho está dividido da seguinte forma : Na seção 2, é apresentada a revisão de literatura e trabalhos correlatos. Na seção 3, é apresentada a metodologia. Na seção 4, os resultados e discussões; e na seção 5 as considerações finais.

2. Revisão da Literatura

2.1. GEOBIA - *Geographic Object-Based Image Analysis*

Ao contrário da classificação *pixel-pixel*, a GEOBIA usa regiões ou objetos de uma imagem como unidades básicas de classificação [Blaschke 2010]. Dessa forma, é possível avaliar o contexto no qual o pixel está inserido, estabelecendo uma relação próxima entre objetos do mundo real e da imagem. Para isso, atributos como cor, forma, textura, tamanho e contexto semântico do objeto são utilizados para caracterizá-los. A obtenção desses objetos a partir de uma imagem é realizada por meio da segmentação. Um segmento é um conjunto de pixels que representa um objeto, como por exemplo uma rua, um telhado ou vegetação [Chen et al. 2018, Myint and Stow 2011].

¹Em geral, imagens de alta resolução espacial e geométrica, como as ortofotos.

²A resolução espacial refere-se a área que um pixel da imagem representa no solo.

A seguinte definição formal de GEOBIA é apresentada por [Hay and Castilla 2008]: “é uma subdisciplina da Ciência da Informação Geográfica (GIScience) dedicada ao desenvolvimento de métodos automatizados para particionar imagens de sensoriamento remoto em objetos semânticos, e avaliar suas características através de escalas espaciais, espectrais e temporais, de modo a gerar novas informações geográficas.” O termo GEOBIA refere-se à metodologia OBIA - *Object-Based Image Analysis*, quando aplicada a estudos envolvendo sensoriamento remoto.

A metodologia GEOBIA contempla as etapas de Segmentação, Extração de Atributos, Classificação e Avaliação. Na etapa de **Segmentação**, a imagem é dividida em regiões não sobrepostas (segmentos), de modo que cada região seja a mais homogênea e as vizinhas tão diferentes quanto possível. A criação de um segmento se dá pela similaridade dos *pixels* de acordo com algum critério de homogeneidade, como textura, intensidade e cor. A segmentação pode ser realizada por diferentes algoritmos, tais como SLIC, *Denoised Watershed*, Felzenszwalb e *Multiresolution Segmentation* [Gonzalez and Woods 2008].

Após a segmentação, há a etapa de **extração de atributos**, que tem como objetivo caracterizar os segmentos, evidenciando as diferenças e similaridades entre eles. As características extraídas do segmento podem incluir o brilho, textura, amplitude do histograma, forma, tamanho, entre outros.

Uma vez que os atributos de cada segmento são extraídos, acontece a etapa de **classificação**. Como cada segmento é um objeto, é necessário classificar cada objeto individualmente, de forma que todos os *pixels* que compõem o segmento terão uma mesma classe [Chen et al. 2018]. Para isso, o método não determina qual algoritmo de classificação deve ser usado, uma vez que cada projeto possui características diferentes que podem aderir melhor a um ou outro algoritmo. Portanto, diferentes algoritmos de aprendizado de máquina têm sido utilizados nesta tarefa, dentre os quais destaca-se: *Random Forest* (RF), *Support Vector Machine* (SVM) e Redes Neurais Artificiais (RNA).

Em termos de solução proprietária, o *software* eCognition®³ é líder no mercado de GEOBIA e baseia-se na construção de uma rede semântica hierárquica de objetos extraídos da imagem em diferentes escalas simultaneamente.

2.2. Trabalhos Correlatos

[Chen et al. 2018] apresentam uma revisão sobre algumas metodologias utilizadas para extração automática de edificações a partir de uma imagem. Os autores utilizaram imagens de alta resolução espacial do *Google Earth*, GEOBIA e os classificadores AdaBoost, RF e SVM para classificar construções residenciais e comerciais no Canadá. O SVM obteve o melhor resultado com acurácia de 91%. Foram utilizados atributos espectrais, textuais, geométricos, de forma, sombra e alguns índices de regularidade de borda.

O trabalho desenvolvido por [Pilinja Subrahmanya et al. 2021] utilizou RNA, RF, Naive Bayes e SVM para classificar construções em uma ortofoto gerada com VANT. A RNA obteve acurácia de 93% utilizando a imagem RGB e o modelo numérico do terreno.

No trabalho de [Kim et al. 2011] foram utilizadas imagens aéreas, modelo digital de elevação, GEOBIA e SVM para identificar construções. Em [Trevisiol et al. 2021] os

³<https://www.geospatial.trimble.com/products-and-solutions/trimble-ecognition>

autores obtiveram 94% de acurácia global na identificação de construções na cidade de Bologna, Itália, utilizando GEOBIA (eCognition®) e imagem de alta resolução espacial. De forma análoga, os autores [Jia et al. 2022] utilizaram imagem de VANT e GEOBIA (eCognition®) para classificar diferentes usos no campus de uma universidade chinesa. Os classificadores testados foram *fuzzy*, *k-Nearest Neighbors* (KNN), Bayes, SVM e RF, sendo este último o que apresentou a melhor acurácia global (84,9%).

Os autores [Chen and Li 2019] apresentam uma abordagem para detecção de telhados em área urbana, usando rede neural convolucional e imagens VANTs. A acurácia deste método ficou em 75%. O uso de redes convolucionais (aprendizado profundo) aparece como uma tendência na detecção de construções urbanas. Outras aplicações comuns envolvendo classificação automática de telhados ocorrem na identificação de locais adequados para instalação de painéis solares e também dos chamados telhados verdes [Jia et al. 2022, Shao et al. 2021].

[Arantes et al. 2018] estudaram a viabilidade de usar imagens de VANT para atualização de área construída dos imóveis urbanos. Segundo esses autores, com ortofotos de até 10cm de resolução espacial, o contorno do imóvel pode ser identificado sem dificuldades, permitindo uma vetorização precisa de toda área construída. Comparando valores da área construída obtidos por meio da imagem aérea e área real do imóvel em diferentes escalas, os autores concluíram que a área obtida a partir da ortofoto foi menor do que o real valor do imóvel, ficando essa diferença em, no máximo, em 4,94%. Nesse estudo, os imóveis foram vetorizados manualmente.

3. Metodologia

Este trabalho tem natureza aplicada, com abordagem quantitativa e objetivo descritivo, que busca analisar a viabilidade do uso de métodos de classificação automática supervisionada em ortofotos para atualização de área de imóveis em processos de recadastramento imobiliário.

3.1. Materiais

Os dados utilizados nesse trabalho são oriundos do projeto intitulado “Sistema de recadastramento imobiliário multifinalitário georreferenciado de Elói Mendes/MG”, executado pela Universidade Federal de Itajubá (UNIFEI) por meio do Núcleo Estratégico Interdisciplinar em Resiliência Urbana (NEIRU). Neste projeto, ortofotos obtidas com uso de VANT foram utilizadas como base para atualizar a área das edificações do município. A vetorização dos telhados foi realizada manualmente por especialistas em fotointerpretação apoiados por sistemas CAD - *Computer Aided Design*.

A área de estudo é composta por treze quadras do município de Elói Mendes, que está localizado no Sul de Minas Gerais (Figura 1C). As quadras localizam-se na região norte do município (Figura 1B), totalizando 0,20 km². O detalhe das quadras selecionadas e a ortofoto utilizada podem ser vistos na Figura 1A. A ortofoto possui resolução espacial de cerca de 5 cm e contém as bandas RGB. Antes da classificação as ruas foram mascaradas, de forma que apenas as informações das quadras ficassem disponíveis.

Para treinar e avaliar os classificadores, as edificações detectadas na vetorização manual foram utilizadas. Na Figura 2A, todas as edificações da área de estudo vetorizadas manualmente aparecem em cinza. Na Figura 2B, detalhes dos telhados vetorizados

sob a ortofoto. Utilizando a ortofoto e os dados da Figura 2A, foram gerados pontos aleatórios classificados como “telhado” e “não telhado”. Para tanto foi utilizado o sistema de informação geográfica QGis e foram geradas três amostras com pontos diferentes entre si. O primeiro conjunto continha 879 pontos. O segundo 395, e o terceiro 883 pontos. A quantidade de pontos variou de acordo com a randomicidade do método.

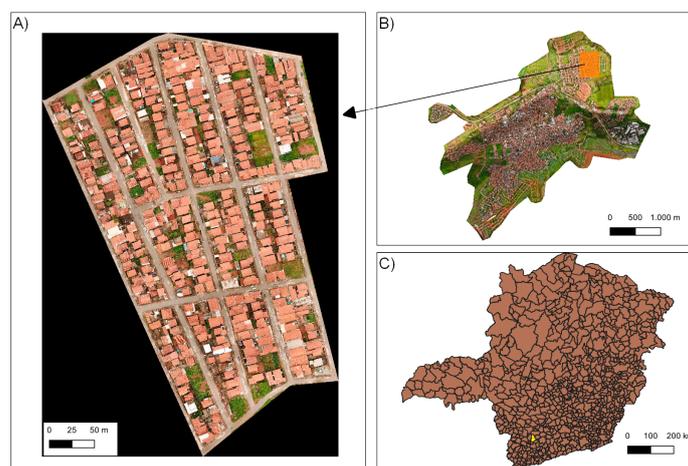


Figura 1. Área de estudo. A) Ortofoto das quadras selecionadas. B) Localização das quadras no município. C) Localização do município em Minas Gerais.



Figura 2. Dados de referência obtidos por interpretação visual. A) Todas as edificações da área de estudo (cinza). B) Detalhe da vetorização (amarelo) sobreposta à ortofoto.

Para o desenvolvimento foi utilizado Python 3.7.10, com suporte da plataforma de *Data Science Anaconda*. O ambiente de teste foi executado em um computador com sistema Operacional MacOS Catalina (10.15.4), processador Intel®Core i7 7500U, placa de vídeo Nvidia®Geforce 940MX (4GB VRam) e 12GB de memória RAM 2133 MHz.

3.2. Métodos

A Figura 3 ilustra a metodologia utilizada. A ortofoto foi segmentada utilizando o algoritmo Felzenszwalb [Felzenszwalb and Huttenlocher 2004], pois obteve melhores resultados que *SLIC* e *Denoised Watershed*, gerando segmentos mais precisos no contexto dos

telhados e em tempo menor. Os segmentos foram gerados a partir da homogeneidade de cor (nível de cinza) considerando as três bandas visíveis (RGB) da ortofoto e com a seguinte parametrização: escala 100, sigma 0,5 e tamanho mínimo 500. Tais valores foram determinados empiricamente. A escala controla indiretamente o número de segmentos produzidos, bem como seu tamanho; sigma é o diâmetro de um kernel gaussiano, usado para suavizar a imagem antes da segmentação; e tamanho mínimo determina o tamanho mínimo de um segmento em *pixels*. A implementação do algoritmo Felzenszwalb em Python⁴ utiliza apenas a similaridade espectral (cor) para gerar os segmentos.

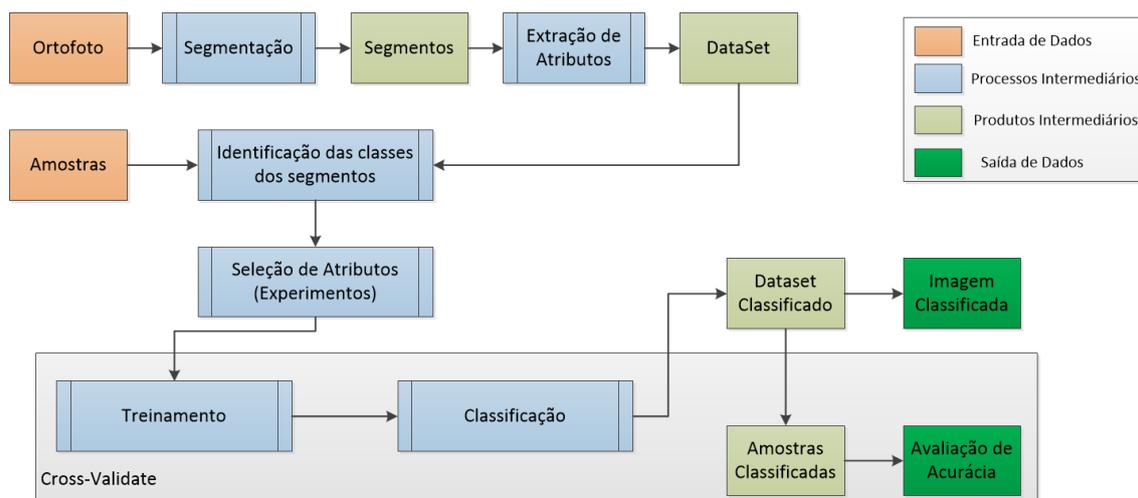


Figura 3. Fluxograma de atividades realizadas no trabalho.

Para cada segmento foi realizada a extração de atributos, sendo sete atributos espectrais e quatro texturais. Os atributos espectrais referem-se aos valores encontrados no pixel da imagem: número de observações (*pixels*), valor mínimo, valor máximo, média, variância, distorção e curtose. Os atributos texturais foram obtidos pela matriz de co-ocorrência de [Haralick et al. 1973]: segundo momento angular, entropia, variância e momento inverso de diferenças. Esses atributos foram computados para cada banda da ortofoto (RGB). O resultado dessa etapa é o *Dataset*, ou seja, um arquivo contendo a lista de segmentos com seus respectivos valores calculados para cada atributo (vetor de atributos). O arquivo gerado foi formado por 53.262 segmentos, compreendendo toda extensão da imagem. A segmentação e extração de atributos foi realizada uma única vez.

Para definir a classe dos segmentos em telhado ou não-telhado, foram utilizadas as amostras geradas no QGIS. Dessa forma, para cada ponto contido nas amostras, verificava-se o segmento a que ele pertencia e associava o segmento inteiro a essa classe. Essa etapa foi realizada para os três conjuntos amostrais.

Para avaliar a melhor combinação de atributos texturais e espectrais houve uma etapa de seleção de atributos, que consistiu de seis experimentos com combinações de métodos e tipo de atributo:

- **GEOBIA_ESPECTRAL:** *Random Forest* com atributos espectrais.
- **GEOBIA_HARALICK:** *Random Forest* com atributos espectrais e texturais.

⁴<https://scikit-image.org/docs/stable/api/skimage.segmentation.html#skimage.segmentation.felzenszwalb>

- **GEOBIA_HARALICK_LISURA:** *Random Forest* com atributos espectrais e as medidas texturais apropriadas para superfícies lisas: segundo momento angular e momento inverso da diferença.
- **GEOBIA_HARALICK_RUGOSIDADE:** *Random Forest* com atributos espectrais e as medidas texturais apropriadas para superfícies rugosas: Entropia e Variância.
- **GEOBIA_SVM:** *Support Vector Machine* com atributos espectrais e texturais. Foi utilizado o *kernel* linear.
- **GEOBIA_RNA:** Rede Neural Artificial (*MLPClassifier*) com atributos espectrais e texturais. Foi utilizado o *solver* *lbfgs*, rodando com 100 camadas.

Os seis experimentos foram executados para cada conjunto de amostras, totalizando 18 classificações binárias telhado ou não-telhado. Para os testes com *Random Forest*, foram utilizadas 10 árvores aleatórias.

O treinamento e validação foram executados com *Cross-Validate* com 5 pastas. O método *KFold* separa o conjunto de dados de entrada em treinamento e teste. Portanto, após a classificação, os conjuntos amostrais de teste foram utilizados para avaliação de acurácia. A partir da matriz de confusão foram computadas as métricas Acurácia Global, Acurácia Balanceada, Precisão, Sensitividade, Especificidade, F1 Score e AUC. Detalhes dessas métricas podem ser encontradas em [Bramer 2016]. Além das métricas foi obtido o tempo de processamento para avaliação do desempenho dos métodos.

4. Resultados e Discussões

A Figura 4A apresenta o resultado da segmentação realizada pelo algoritmo de Felzenszwalb sobre a ortofoto de entrada. A cor cinza representa “sem dados” e as demais cores, cada um dos segmentos localizados. A Figura 4B detalha a segmentação em um único telhado, comparando com a vetorização manual.

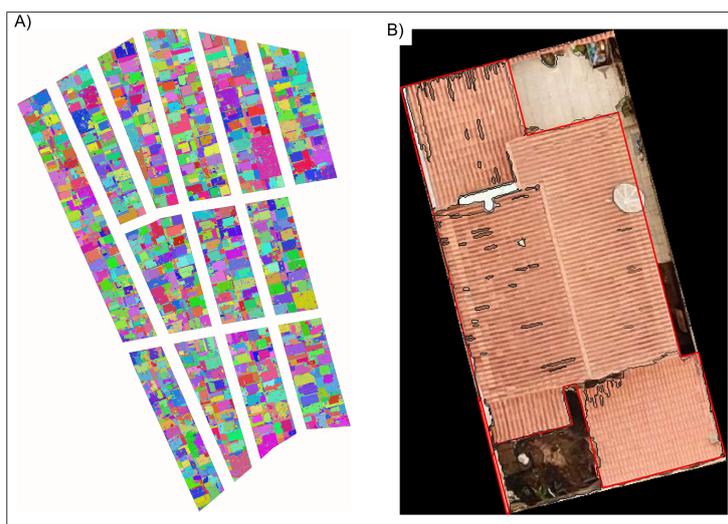


Figura 4. Segmentação obtida com o método Felzenszwalb. A) todos os segmentos. B) detalhe do contorno dos segmentos sob a ortofoto (preto) e da vetorização manual (vermelho).

Na Tabela 1, são apresentados os resultados dos experimentos para cada conjunto de amostras. Em verde, está destacado o melhor resultado, obtido no experimento

GEOBIA_Haralick; e em amarelo, o conjunto que obteve o pior resultado, obtido pelo GEOBIA_SVM. Os melhores valores para cada métrica estão destacados em negro.

Tabela 1. Desempenho das classificações realizadas a partir da ortofoto.

MÉTODOS	Instâncias	MÉTRICAS DE ACURÁCIA					Curva ROC - AUC	F1-Score	Tempo (horas)
		Acurácia Global	Acurácia Balanceada	Precisão	Sensibilidade	Especificidade			
GEOBIA Espectral	1	88.71%	80.77%	90.44%	89.92%	87.68%	88.80%	90.50%	5h (1/h pasta)
	2	71.14%	78.35%	60.17%	97.65%	51.11%	75.11%	74.46%	5h (1/h pasta)
	3	71.41%	78.85%	61.94%	97.28%	49.58%	78.91%	75.68%	5h (1/h pasta)
	Desvio Padrão	10.07%	1.28%	16.99%	4.36%	21.57%	7.07%	8.93%	-
Média	77.09%	79.32%	70.85%	94.95%	62.79%	80.94%	80.21%	5h (1/h pasta)	
GEOBIA Haralick	1	96.46%	96.36%	97.32%	96.29%	96.04%	96.04%	96.80%	5h (1/h pasta)
	2	71.65%	78.68%	60.57%	97.65%	52.00%	78.76%	74.76%	5h (1/h pasta)
	3	71.41%	78.69%	61.98%	97.04%	49.79%	75.91%	75.64%	5h (1/h pasta)
	Desvio Padrão	14.39%	10.21%	20.82%	0.68%	26.45%	10.90%	12.48%	-
Média	79.84%	84.58%	73.29%	96.99%	66.15%	83.57%	82.40%	5h (1/h pasta)	
GEOBIA Haralick Lisura	1	96.11%	96.02%	96.94%	96.08%	96.15%	96.59%	96.51%	5h (1/h pasta)
	2	71.14%	78.10%	60.20%	97.06%	51.56%	76.16%	74.31%	5h (1/h pasta)
	3	71.75%	78.54%	62.36%	96.79%	50.63%	78.30%	75.85%	5h (1/h pasta)
	Desvio Padrão	14.25%	10.22%	20.62%	0.50%	26.02%	11.23%	12.40%	-
Média	79.67%	84.22%	73.17%	96.64%	66.11%	83.68%	82.22%	5h (1/h pasta)	
GEOBIA Haralick Rugosidade	1	96.00%	95.98%	96.26%	96.70%	95.13%	94.19%	96.47%	5h (1/h pasta)
	2	71.39%	78.52%	60.36%	97.65%	51.56%	78.59%	74.61%	5h (1/h pasta)
	3	71.64%	78.51%	62.25%	96.79%	50.42%	77.71%	75.77%	5h (1/h pasta)
	Desvio Padrão	14.14%	10.09%	20.20%	0.52%	25.49%	9.27%	12.30%	-
Média	79.68%	84.34%	72.96%	97.05%	65.70%	83.49%	82.28%	5h (1/h pasta)	
GEOBIA SVM	1	73.14%	81.20%	62.13%	51.55%	57.76%	82.11%	68.03%	6h (1.2/h pasta)
	2	63.28%	81.20%	61.48%	51.55%	56.22%	62.11%	58.03%	6h (1.2/h pasta)
	3	65.84%	76.20%	61.28%	50.46%	55.15%	62.05%	52.11%	6h (1.2/h pasta)
	Desvio Padrão	5.12%	2.89%	0.44%	0.63%	1.31%	11.56%	8.05%	-
Média	67.42%	79.53%	61.63%	51.18%	56.38%	68.76%	59.39%	6h (1.2/h pasta)	
GEOBIA RNA	1	75.43%	77.25%	87.50%	64.95%	88.46%	77.83%	74.56%	6,5h (1.3/h pasta)
	2	63.28%	77.25%	60.56%	61.55%	56.15%	72.55%	65.15%	6,5h (1.3/h pasta)
	3	65.84%	77.00%	61.28%	59.15%	47.51%	69.63%	65.06%	6,5h (1.3/h pasta)
	Desvio Padrão	6.40%	0.14%	15.35%	2.91%	21.58%	4.16%	5.46%	-
Média	68.18%	77.16%	69.78%	61.88%	64.04%	73.33%	68.25%	6,5h (1.3/h pasta)	

Ao comparar os métodos, GEOBIA_HARALICK, GEOBIA_SVM e GEOBIA_RNA que utilizaram o mesmo conjunto de atributos, fica evidente a superioridade do *Random Forest* (RF) na classificação dos dados utilizados. Isso porque o SVM e RNA apresentaram resultados piores em todas as medidas em comparação a RF.

No geral, os experimentos utilizando *Random Forest* tiveram performance semelhantes. Contudo, foi possível observar que a inclusão de medidas texturais contribuíram positivamente para a classificação, obtendo as melhores medidas de acurácia, entre as quais podemos destacar os valores de acurácia global e balanceada, com 79,84% e 84,58% respectivamente, na média dos três conjuntos de amostras para o experimento GEOBIA_Haralick. Já o caso onde foram apenas considerados recursos espectrais (GEOBIA_Espectral), o algoritmo teve menor percentual de acurácia global e balanceada, com 77,09% e 79,32% respectivamente. Na média, a curva ROC ficou acima de 80% em todas as classificações com RF, deixando claro que o classificador não se comporta de forma aleatória. O F1-Score também ficou acima de 80% na média, indicando uma boa relação entre falsos positivos e falsos negativos. A Figura 5 apresenta as classificações do RF obtidas com o experimento GEOBIA_Haralick para os três conjuntos amostrais.

Em todos os experimentos com RF, a pior métrica foi a especificidade, que avalia a taxa com que uma instância verdadeiramente negativa é classificada como tal, ou seja, classificar corretamente um segmento como não-telhado. Um ponto crítico foi o tempo necessário para execução das classificações, conforme destacado na Tabela 1. Esse resultado foi impulsionado pelas etapas de identificação dos segmentos e classificação.

Ao comparar os resultados obtidos com a literatura, verifica-se que o RF obteve resultados superiores no trabalho de [Kim et al. 2011]. Já em [Chen et al. 2018], a melhor classificação foi obtida com SVM. E em [Pilinja Subrahmanya et al. 2021], a rede neural apresentou melhor resultado. O que corrobora que, em trabalhos de *machine learning*, o desempenho do classificador é definido prioritariamente pelo conjunto de dados e sempre

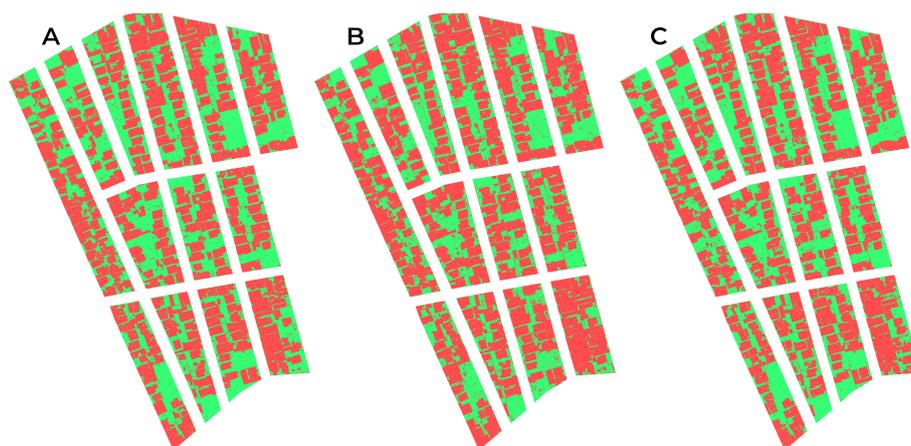


Figura 5. Classificações *Random Forest* obtidas com o experimento GEOBIA_Haralick. Em vermelho a classe telhado. Em verde a classe não-telhado. A) Amostra 1; B) Amostra 2; C) Amostra 3.

deve ser testado. Também é possível notar na Tabela 1, que o conjunto de entrada (amostra) influencia consideravelmente os resultados das classificações, salientando a importância da média amostral em trabalhos deste tipo.

Para [Chen et al. 2018], a precisão na identificação de objetos na imagem utilizando GEOBIA é altamente impactada pela segmentação. Os autores relatam em seu trabalho que, como alguns telhados não foram corretamente delimitados na etapa de segmentação, causaram erros na classificação. Esse entendimento é reforçado por [Kim et al. 2011], que ressaltam que a precisão da segmentação afeta o resultado geral da classificação, uma vez que é ela quem tem a capacidade de dividir a imagem, identificando os alvos. Corroborando com os autores citados, neste trabalho a segmentação teve papel fundamental para o sucesso da classificação. Na Figura 4B é possível perceber que o limite dos telhados não ficou exatamente como esperado, quando comparado à vetorização manual.

Um dos motivos para as falhas na segmentação são objetos da mesma classe com cores diferentes e o contrário, objetos de classes diferentes com cores iguais. [Kim et al. 2011] argumentam que é difícil classificar um tipo de objeto com cores diferentes na mesma classe usando apenas dados ópticos, como uma imagem aérea. Além disso, conforme ressaltam [Shao et al. 2021], embora o levantamento de drones possa gerar imagens de cores reais que melhoram os detalhes dos objetos capturados, essas imagens contêm faixas de luz visível muito limitadas, reduzindo bastante a precisão da classificação automática e semi-automática. Esse aspecto pôde ser observado neste trabalho. A Figura 6 compara a classificação obtida com o experimento OBIA_HARALICK com as áreas vetorizadas. Verifica-se que em alguns telhados, com marcadores amarelos na imagem, a classificação acerta. Por outro lado, o classificador erra quando o piso da casa tem cor muito parecida com a do telhado (setas na Figura 6). Na Figura 4B, verifica-se também que telhados com coloração diferente nas telhas (mesmo material) acabam gerando segmentos diferentes. Esse achado pode justificar a baixa especificidade da classificação, conforme Tabela 1.

Em projetos de cadastramento imobiliário, a exatidão dos limites do imóvel e respectiva área são de importância crucial. Não há na literatura discussões assertivas sobre essa questão. É fato que atualmente o custo das imagens obtidas por VANTs está



Figura 6. Avaliação da exatidão da classificação obtida a partir do experimento GEOBIA HARALICK. A) limites dos telhados vetorizados: setas amarelas indicam piso das casas e Os círculos amarelos indicam telhados cuja classificação foi precisa. B) cor vermelha indica telhado e a verde não-telhado. As setas indicam alguns erros de classificação.

diminuindo. No entanto, conforme afirma [Jia et al. 2022], ainda não há algoritmos bem estabelecidos e eficientes para trabalhar nessas imagens, especialmente no contexto urbano. Soma-se a isso o fato das ortofotos obtidas por VANTs apresentarem diversas distorções, como edificações inclinadas e rodovias tortas ou deformadas [Schickier and Thorpe 1998]. Na Figura 7, as setas indicam distorções na ortofoto utilizada. Verifica-se deformações no limite dos telhados, nos muros e em relação às calçadas. Por esse motivo, durante a vetorização, os analistas precisam considerar esses fatores na delimitação das edificações.



Figura 7. Distorções observadas em muros, telhados e calçadas em parte da área de estudo, destacadas pelas setas.

Todas essas questões discutidas impactam diretamente o classificador e, portanto, a qualidade da delimitação dos telhados para fins de recadastramento imobiliário. Por inspeção manual, verificou-se que houve uma variação significativa na área dos objetos classificados em comparação com a área vetorizada manualmente. Em alguns casos, as áreas apresentam menos de 1m^2 de diferença, sendo que em outros o erro chega a ser o dobro da área vetorizada manualmente.

5. Considerações Finais

Este artigo apresenta um estudo exploratório sobre o uso de classificação automática baseada em objetos e aprendizado de máquina na detecção de telhados para fins de recadastramento imobiliário. O classificador que melhor se adequou ao estudo de caso foi

o *Random Forest*, apresentando as melhores acurácias quando comparado ao SVM e RNA. A inclusão de medidas texturais melhorou a classificação, alcançando acurácia global de 84,58%.

A segmentação é um ponto crítico nesta metodologia. Portanto, em tese, uma segmentação que utilize não apenas o padrão espectral pode ser mais eficiente para trabalhos envolvendo recadastramento imobiliário. Neste trabalho as imagens não passaram por nenhum pré-processamento, que poderia beneficiar a segmentação. Assim como técnicas de pós-processamento na imagem segmentada. Trabalhos futuros podem realizar investigações nesse sentido.

Embora a classificação automática tenha alcançado boa acurácia, em relação ao recadastramento imobiliário, os resultados deste trabalho apontam que a metodologia testada não é eficiente para substituir a vetorização manual. Entretanto, estudos futuros podem avaliar se a combinação entre classificação automática e vetorização manual diminui o gargalo da etapa de vetorização nos projetos de recadastramento.

Um diferencial deste trabalho foi a utilização de 100% de *software* livre em seu desenvolvimento, não dependendo de nenhuma solução proprietária. Considerando os aspectos econômicos e sociais, a análise dessa metodologia, sem a utilização de softwares proprietários de alto custo, pode ser um primeiro passo para viabilizar a realização desse tipo de projeto em pequenas e médias cidades que, normalmente, possuem uma limitação de recurso significativa. Um ponto crítico foi o tempo de processamento muito alto, considerando a área pequena (0,20 km²). O método, portanto, pode ser inviável para áreas maiores.

Considera-se que o objetivo do trabalho foi alcançado, tendo sido possível avaliar a eficiência dos métodos de classificação e a utilidade da classificação no auxílio da vetorização dos telhados em área urbana para fins de recadastramento imobiliário.

Agradecimentos

Os autores agradecem à *Prefeitura Municipal de Elói Mendes* por ceder os dados utilizados nessa pesquisa.

Referências

- Arantes, B. H. T., Arantes, L. T., Ventura, M. V. A., Costa, E. M., Bessa, M. M., Baliza, L. M., and Moraes, V. H. (2018). Uso de drones na atualização de área construída de imóveis urbanos. *Scientia Plena*, 14(10).
- Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1):2–16.
- Bramer, M. (2016). *Principles of Data Mining*. Springer London.
- Brasil (2000). Lei nº 101, de 4 de maio de 2000. estabelece normas de finanças públicas voltadas para a responsabilidade na gestão fiscal e dá outras providências. *Diário Oficial da República Federativa do Brasil*.
- Brasil (2009). Portaria nº 511, de 7 de dezembro de 2009. estabelece diretrizes para a criação, instituição e atualização do cadastro territorial multifinalitário (ctm) nos municípios brasileiros. *Diário Oficial da República Federativa do Brasil*.

- Chen, M. and Li, J. (2019). Deep convolutional neural network application on rooftop detection for aerial image. *CoRR*, abs/1910.13509.
- Chen, R., Li, X., and Li, J. (2018). Object-based features for house detection from rgb high-resolution images. *Remote Sensing*, 10(3).
- Cienciata, A., Sobolewska-Mikulska, K., and Sobura, S. (2021). Credibility of the cadastral data on land use and the methodology for their verification and update. *Land Use Policy*, 102:105204.
- Felzenszwalb, P. F. and Huttenlocher, D. P. (2004). Efficient graph-based image segmentation. *International journal of computer vision*, 59(2):167–181.
- Gonzalez, R. and Woods, R. (2008). *Digital image processing*. Prentice Hall, Upper Saddle River, N.J.
- Haralick, R. M., Shanmugam, K., and Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6):610–621.
- Hay, G. J. and Castilla, G. (2008). Geographic object-based image analysis (geobia): A new name for a new discipline. In *Object-based image analysis*, pages 75–89. Springer.
- Jia, J., Cui, W., and Liu, J. (2022). Urban catchment-scale blue-green-gray infrastructure classification with unmanned aerial vehicle images and machine learning algorithms. *Frontiers in Environmental Science*, 9.
- Karataş, K. and Altınışık, N. S. (2020). The effect of uav usage on detail points in cadastre update studies: Çorum-karaköy case study. *International Journal of Environment and Geoinformatics*, 7:140 – 146.
- Kim, Y., Han, Y., Byun, Y., Choi, J., Han, D., and Kim, Y. (2011). Object-based classification of an urban area through a combination of aerial image and airborne lidar data. In *American Society for Photogrammetry and Remote Sensing Annual Conference 2011*, pages 265–270.
- Myint, S. and Stow, D. (2011). An object-oriented pattern recognition approach for urban classification. In *Urban Remote Sensing: Monitoring, Synthesis and Modeling in the Urban Environment*, pages 129–140. Wiley-Blackwell.
- Pilinja Subrahmanya, P., Haridas Aithal, B., and Mitra, S. (2021). Automatic extraction of buildings from uav-based imagery using artificial neural networks. *Journal of the Indian Society of Remote Sensing*, 49(3):681–687.
- Schickier, W. and Thorpe, A. (1998). Operational procedure for automatic true orthophoto generation. *International Archives of Photogrammetry and Remote Sensing*, 32:527–532.
- Shao, H., Song, P., Mu, B., Tian, G., Chen, Q., He, R., and Kim, G. (2021). Assessing city-scale green roof development potential using unmanned aerial vehicle (uav) imagery. *Urban Forestry & Urban Greening*, 57:126954.
- Trevisiol, F., Lambertini, A., Franci, F., and Mandanici, E. (2021). An object-oriented approach to the classification of roofing materials using very high-resolution satellite stereo-pairs. *Remote Sensing*, 14(4).