



**PBPC**  
ISSN 2674-9432



Qualis A3  
CAPES 2021-2024



DOI - Crossref

Latindex



Indexado no  
Acadêmico

# COMPARAÇÃO DE TÉCNICAS DE EXTRAÇÃO DE TELHADOS UTILIZANDO ANÁLISE DE IMAGEM BASEADA EM OBJETO (OBIA) EM PRODUTOS OBTIDOS POR AERONAVE REMOTAMENTE PILOTADA

Fernando Alves Barros Firmino<sup>1</sup>; Sângela Cruz Morais<sup>2</sup>



<https://doi.org/10.36557/2674-9432.2026v5n4p134-157>

Artigo recebido em 3 de Abril e publicado em 3 de Junho de 2026

## ARTIGO ORIGINAL

### RESUMO

Este artigo compara duas estratégias de extração automática de telhados a partir de produtos obtidos por aeronave remotamente pilotada: a composição RGBZ, formada pelo ortomosaico RGB e pelo Modelo Digital de Superfície (MDS), e a composição PCA-RGBZ, obtida pela Análise de Componentes Principais. As duas abordagens foram processadas por análise de imagem baseada em objeto (OBIA), segmentação MeanShift, extração de atributos estatísticos e classificação supervisionada por SVM. A validação foi realizada por matriz de confusão, acurácia global, acurácia do produtor, acurácia do usuário, F1-score e Kappa. Os resultados indicaram desempenho superior da PCA-RGBZ, com acurácia global de 95,7% e Kappa de 0,949, enquanto a RGBZ obteve 84,1% e Kappa de 0,813. A PCA reduziu redundâncias entre bandas, melhorou a delimitação das bordas e diminuiu confusões entre telhados, vegetação e objetos elevados. Conclui-se que a integração entre MDS, PCA e OBIA é promissora para mapeamento de coberturas urbanas em escala local.

**Palavras-chave:** Extração de telhados. Drone. Modelo Digital de Superfície. Análise de Componentes Principais. Classificação orientada a objetos.



**COMPARAÇÃO DE TÉCNICAS DE EXTRAÇÃO DE TELHADOS UTILIZANDO ANÁLISE DE  
IMAGEM BASEADA EM OBJETO (OBIA) EM PRODUTOS OBTIDOS POR AERONAVE  
REMOTAMENTE PILOTADA**

*Firmino e Morais, 2026.*

**ABSTRACT**

This paper compares two automatic roof extraction strategies using products obtained from remotely piloted aircraft: the RGBZ composition, formed by the RGB orthomosaic and the Digital Surface Model (DSM), and the PCA-RGBZ composition, obtained through Principal Component Analysis. Both approaches were processed through object-based image analysis (OBIA), MeanShift segmentation, extraction of statistical attributes and supervised classification with SVM. Validation was performed using a confusion matrix, overall accuracy, producer's accuracy, user's accuracy, F1-score and Kappa coefficient. The results showed superior performance for PCA-RGBZ, with 95.7% overall accuracy and Kappa of 0.949, while RGBZ reached 84.1% and Kappa of 0.813. PCA reduced band redundancy, improved roof boundary delineation and decreased confusion among roofs, vegetation and elevated objects. The study concludes that integrating DSM, PCA and OBIA is a promising strategy for local-scale urban roof mapping.

**Keywords:** Roof extraction. Drone. Digital Surface Model. Principal Component Analysis. Object-based image classification.

Instituição afiliada - Instituto Federal de Educação, Ciência e Tecnologia do Pará (IFPA), Brasil.
--

Autor correspondente: Fernando Alves Barros Firmino.
--

This work is licensed under a [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/).





## **1 INTRODUÇÃO**

A produção de informações geográficas em áreas urbanas de pequeno e médio porte ainda enfrenta limitações relacionadas à disponibilidade de imagens recentes, à resolução espacial dos produtos gratuitos e ao custo de aerolevantamentos convencionais. Em muitos municípios brasileiros, esse vazio de geoinformação dificulta o planejamento urbano, a avaliação de infraestrutura, o cadastramento de edificações e a implementação de projetos que dependem da geometria dos telhados, como análises de potencial fotovoltaico, atualização cadastral, regularização urbana e estudos de drenagem.

Nesse contexto, as aeronaves remotamente pilotadas (ARPs), popularmente conhecidas como drones, tornaram-se uma alternativa técnica relevante por permitirem a aquisição de ortomosaicos e modelos digitais de superfície em escala compatível com objetos urbanos. A alta resolução espacial desses produtos permite distinguir feições que normalmente não são adequadamente representadas em imagens orbitais de média resolução, como pequenas coberturas, muros, veículos, árvores isoladas e diferenças de material de telhado. Entretanto, a alta resolução também aumenta a complexidade da classificação, pois amplia a variabilidade intraclasse e evidencia sombras, reflexos, mudanças de textura e descontinuidades construtivas.

A extração automática de telhados é uma tarefa desafiadora porque as edificações podem apresentar materiais, cores, formatos e alturas muito diferentes. Telhados cerâmicos, metálicos, de fibrocimento ou coberturas improvisadas podem assumir respostas espectrais semelhantes às de solo exposto, vias pavimentadas, calçadas e caixas d'água. Além disso, a presença de vegetação arbórea sobre as construções, sombras projetadas e variação de iluminação podem gerar mistura espectral e fragmentação dos objetos. Essa dificuldade justifica o uso de métodos capazes de combinar informação espectral, espacial, geométrica e altimétrica.

A análise de imagem baseada em objeto (Object-Based Image Analysis - OBIA) parte do princípio de que, em imagens de alta resolução, a unidade de análise não precisa ser o pixel isolado, mas sim segmentos que representam objetos ou partes de objetos. Essa abordagem permite explorar atributos como média, desvio padrão, área, perímetro, forma, compacidade, textura, relação de vizinhança e contexto espacial. Em estudos de sensoriamento remoto, a



OBIA tem sido indicada para situações em que a análise pixel a pixel tende a produzir ruído, especialmente em ambientes urbanos heterogêneos e com alvos de pequenas dimensões (BLASCHKE, 2010).

A integração do ortomosaico RGB com o Modelo Digital de Superfície (MDS) amplia a capacidade de diferenciação das classes porque agrega informação de altura. Enquanto o RGB descreve a resposta espectral e visual dos objetos, o MDS contribui para separar elementos elevados, como edificações e vegetação arbórea, de superfícies mais baixas, como vias, solo exposto e vegetação rasteira. Essa combinação é particularmente útil quando objetos diferentes possuem cores parecidas, mas ocupam posições altimétricas distintas.

Outra possibilidade metodológica é aplicar a Análise de Componentes Principais (PCA) ao conjunto de bandas utilizado na classificação. A PCA transforma variáveis correlacionadas em componentes não correlacionados, ordenados pela quantidade de variância explicada. Em imagens multibanda, esse procedimento pode reduzir redundâncias entre as bandas do visível e destacar gradientes relevantes para a separação de feições, preservando parte substancial da informação original em um número menor de componentes (JOLLIFFE; CADIMA, 2016). Em aplicações com ARP, a PCA pode favorecer a delimitação de bordas e a separação entre materiais urbanos quando as bandas originais apresentam alta correlação.

Diante disso, este artigo tem como objetivo comparar duas estratégias de extração de telhados utilizando produtos obtidos por ARP: a primeira baseada na composição RGBZ, formada pela união do ortomosaico RGB com o MDS; e a segunda baseada na composição PCA-RGBZ, gerada pela aplicação da PCA ao mesmo conjunto de dados. Ambas as estratégias foram classificadas por OBIA com o algoritmo SVM e avaliadas por matriz de confusão, métricas de acurácia e validação visual. O enfoque da revisão realizada neste artigo é tornar mais clara a metodologia, aprofundar a interpretação estatística dos resultados e discutir as razões técnicas dos erros e acertos observados.

## **2 METODOLOGIA**

### **2.1 Área de estudo e dados utilizados**



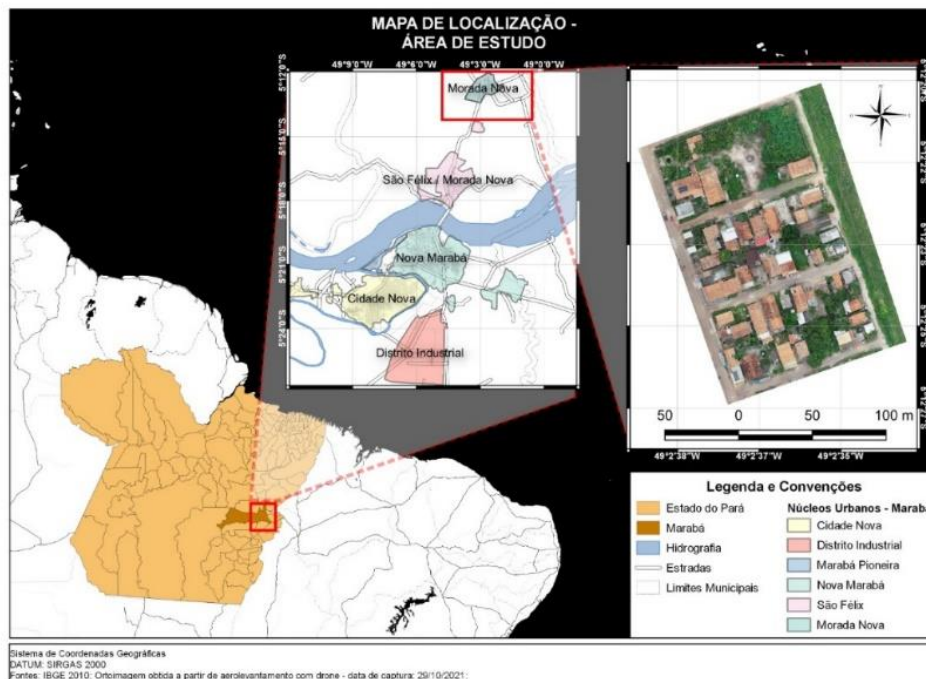
**COMPARAÇÃO DE TÉCNICAS DE EXTRAÇÃO DE TELHADOS UTILIZANDO ANÁLISE DE  
IMAGEM BASEADA EM OBJETO (OBIA) EM PRODUTOS OBTIDOS POR AERONAVE  
REMOTAMENTE PILOTADA**

*Firmino e Morais, 2026.*

A área de estudo corresponde a um recorte urbano de três quarteirões no bairro Morada Nova, município de Marabá, estado do Pará, conforme apresentado na Figura 1. O recorte foi escolhido por reunir diferentes alvos urbanos e periurbanos, incluindo edificações com telhados de materiais variados, vegetação rasteira, vegetação arbórea, vias, automóveis, solo exposto e caixas d'água. Essa diversidade de classes torna a área adequada para avaliar a capacidade dos métodos de separar telhados de objetos com respostas espectrais ou morfológicas semelhantes.

As imagens foram obtidas com sensor CMOS de 1 polegada, modelo FC6310, com resolução de 4864 x 3648 pixels, tamanho de pixel de 2,61 x 2,61 micrômetros e distância focal de 8,8 mm/24 mm equivalente, embarcado em uma ARP DJI Phantom 4 Pro. A partir do levantamento fotogramétrico, foram utilizados dois produtos principais: o ortomosaico RGB, responsável pela informação espectral no visível, e o Modelo Digital de Superfície, responsável por representar a elevação relativa dos objetos presentes na cena.

Figura 1 - Área de estudo no município de Marabá, Pará.




*Fonte: os autores (2021).*

## 2.2 Desenho metodológico geral

O procedimento metodológico foi organizado em seis etapas integradas: (i) preparação dos produtos derivados da ARP; (ii) construção dos conjuntos de dados RGBZ e PCA-RGBZ; (iii) segmentação orientada a objetos; (iv) extração de atributos estatísticos, radiométricos e geométricos; (v) treinamento e classificação supervisionada por SVM; e (vi) avaliação da acurácia por matriz de confusão, métricas derivadas e inspeção visual dos resultados. Essa sequência permite comparar os métodos em condições equivalentes, alterando-se principalmente a representação dos dados de entrada.

No primeiro conjunto de dados, denominado RGBZ, foram combinadas as três bandas do ortomosaico (vermelho, verde e azul) com a banda de elevação derivada do MDS. A lógica dessa composição é permitir que o classificador utilize simultaneamente informação de cor e altura. No segundo conjunto, denominado PCA-RGBZ, a PCA foi aplicada ao conjunto RGBZ, gerando componentes ordenados pela variância explicada. A Figura 2 mostra o resultado visual da transformação por PCA, na qual padrões espectrais e altimétricos são reorganizados em uma nova base vetorial.

Figura 2 - Imagem obtida por Análise de Componentes Principais aplicada ao conjunto RGBZ.



*Fonte: os autores (2021).*

### **2.3 Segmentação orientada a objetos**

A segmentação foi realizada pelo algoritmo MeanShift, disponível no Orfeo ToolBox (OTB), integrado ao QGIS. O MeanShift é um método não paramétrico de agrupamento que desloca iterativamente uma janela de busca em direção às regiões de maior densidade no espaço de atributos, formando segmentos a partir da similaridade entre pixels ou grupos de pixels. Em termos práticos, o algoritmo busca regiões homogêneas considerando parâmetros espaciais e espectrais, sendo adequado para segmentar imagens de alta resolução quando não se deseja pressupor uma distribuição paramétrica das classes (COMANICIU; MEER, 2002).

Foram utilizados os seguintes parâmetros de segmentação: raio espacial de 0 pixel, alcance do raio de 1 pixel, modelo de convergência de 0,1 pixel, 100 iterações e região mínima de cobertura de 500 pixels. A seleção desses parâmetros buscou preservar objetos urbanos de pequenas dimensões e, ao mesmo tempo, evitar segmentação excessivamente fragmentada. Entretanto, em áreas urbanas, a escolha dos parâmetros é um ponto sensível: valores muito baixos tendem a gerar supersegmentação, separando um mesmo telhado em várias partes; valores muito altos podem gerar subsegmentação, unindo telhados a sombras, vegetação ou vias.

A Figura 3 apresenta os testes de segmentação combinados às áreas amostradas. Observa-se que o conjunto RGBZ gerou 5.400 segmentos, enquanto o conjunto PCA-RGBZ gerou 5.419 segmentos. A diferença no número total de segmentos é pequena, mas relevante do ponto de vista morfológico, pois a PCA alterou a distribuição dos valores de entrada, favorecendo a separação de bordas e a distinção entre objetos com variações espectrais sutis.

Figura 3 - Testes de segmentação combinados com áreas amostradas: A) RGBZ; B) PCA-RGBZ.



*Fonte: os autores (2021).*



## **2.4 Extração de atributos, treinamento e classificação**

Após a segmentação, cada objeto recebeu atributos extraídos por meio da ferramenta ObjectRadiometricStatistics do OTB. Foram considerados atributos como média, desvio padrão, mediana, variância e medidas de forma, incluindo perímetro e agrupamentos derivados dos segmentos. A extração desses atributos é essencial em OBIA porque o classificador não decide apenas com base no valor de um pixel, mas com base no comportamento estatístico do objeto segmentado.

As classes temáticas consideradas foram: telhado cerâmico, telhado de outro material, vegetação arbórea, vegetação rasteira, solo exposto, asfalto, veículos e caixa d'água. Essa separação foi adotada porque a extração de telhados não depende apenas de distinguir edificação e não edificação; é necessário separar telhados de objetos que podem produzir respostas semelhantes. Por exemplo, solo exposto pode ser confundido com telhado cerâmico em razão da coloração avermelhada; asfalto pode se aproximar de coberturas escuras; e caixas d'água podem ser confundidas com telhados por estarem elevadas e localizadas sobre edificações.

O conjunto amostral foi composto por 228 amostras, divididas em 70% para treinamento e 30% para validação, totalizando 159 amostras de treinamento e 69 amostras independentes de verificação. A divisão entre treinamento e validação é importante para reduzir avaliação circular, isto é, evitar que o mesmo conjunto usado para ajustar o modelo seja usado para medir o seu desempenho. Ainda assim, por se tratar de um número limitado de amostras, a interpretação por classe deve considerar a sensibilidade dos percentuais a pequenas variações de acerto ou erro.

A classificação supervisionada foi realizada com Support Vector Machine (SVM). O SVM busca um hiperplano de separação que maximize a margem entre classes no espaço de atributos. Em cenários multiclasse e com dados de alta dimensionalidade, como os derivados de OBIA, o SVM é útil porque trabalha bem com conjuntos de treinamento relativamente pequenos e pode utilizar funções kernel para separar classes que não são linearmente separáveis no espaço original (CHANG; LIN, 2011; HSU; CHANG; LIN, 2016).



## **2.5 Critérios estatísticos de avaliação**

A validação foi realizada por matriz de confusão, também conhecida como matriz de erro ou tabela de contingência. Nesse tipo de matriz, as linhas representam as classes de referência e as colunas representam as classes atribuídas pelo classificador. Os valores da diagonal principal correspondem aos acertos, enquanto os valores fora da diagonal indicam confusões entre classes. A matriz de confusão é considerada uma das formas mais consolidadas de avaliar classificações em sensoriamento remoto, pois permite analisar tanto o desempenho global quanto os padrões de erro por classe (CONGALTON, 1991; FOODY, 2002).

A primeira métrica calculada foi a acurácia global, obtida pela razão entre o número de amostras corretamente classificadas e o total de amostras avaliadas. Embora seja uma medida simples e intuitiva, ela pode mascarar problemas em classes minoritárias. Por isso, a avaliação foi complementada por acurácia do produtor, acurácia do usuário, erro de omissão, erro de comissão e F1-score. A acurácia do produtor corresponde à proporção de amostras de referência de uma classe que foram corretamente classificadas, sendo equivalente ao conceito de sensibilidade ou recall. Já a acurácia do usuário corresponde à proporção de objetos classificados em uma classe que realmente pertencem a ela, sendo equivalente ao conceito de precisão.

O erro de omissão é o complemento da acurácia do produtor e indica quanto uma classe deixou de ser identificada pelo classificador. O erro de comissão é o complemento da acurácia do usuário e indica quanto uma classe recebeu objetos que pertenciam a outras categorias. O F1-score combina precisão e recall por meio de uma média harmônica, sendo útil quando se deseja avaliar simultaneamente omissão e comissão. Em classes como telhados, essa distinção é essencial: um método pode detectar quase todos os telhados existentes, mas incluir muitos objetos indevidos; outro pode ser muito conservador, evitando falsos telhados, mas omitindo parte das edificações.

Também foi calculado o coeficiente Kappa de Cohen, que compara a acurácia observada com a acurácia esperada ao acaso. O Kappa foi utilizado como métrica complementar, não como único critério de decisão, porque a literatura de avaliação temática recomenda interpretar diferentes indicadores em conjunto, já que cada medida expressa um aspecto distinto da



**COMPARAÇÃO DE TÉCNICAS DE EXTRAÇÃO DE TELHADOS UTILIZANDO ANÁLISE DE  
IMAGEM BASEADA EM OBJETO (OBIA) EM PRODUTOS OBTIDOS POR AERONAVE  
REMOTAMENTE PILOTADA**

*Firmino e Morais, 2026.*

concordância entre mapa e referência (STEHMAN, 1997). Assim, a interpretação final considerou a matriz de confusão, os indicadores por classe e a validação visual das bordas e formas dos telhados.



### 3 RESULTADOS E DISCUSSÃO

#### 3.1 Desempenho geral dos métodos

A comparação entre os dois métodos indicou melhor desempenho estatístico e visual para a composição PCA-RGBZ. A classificação RGBZ obteve 58 acertos em 69 amostras, resultando em acurácia global de 84,1% e coeficiente Kappa de 0,813. A classificação PCA-RGBZ obteve 66 acertos em 69 amostras, com acurácia global de 95,7% e Kappa de 0,949. Considerando a mesma base de validação, a melhoria observada sugere que a transformação por PCA contribuiu para reduzir redundâncias e melhorar a separação entre objetos urbanos com respostas semelhantes.

A leitura do Kappa também reforça essa interpretação. O valor de 0,813 para RGBZ indica concordância forte entre classificação e referência, mas ainda com erros relevantes em algumas classes. O valor de 0,949 para PCA-RGBZ indica concordância muito elevada, com pequena quantidade de discordâncias. Entretanto, como a validação possui 69 amostras, os resultados devem ser interpretados em conjunto com os erros por classe e com a inspeção visual, evitando a conclusão baseada apenas em um índice agregado.

A Tabela 1 apresenta a matriz de confusão do conjunto RGBZ. Observa-se que os principais erros ocorreram nas classes telhado cerâmico, vegetação arbórea, vegetação rasteira, veículos e caixa d'água. Esses erros são coerentes com a natureza da cena urbana: objetos pequenos e elevados, como caixas d'água, podem apresentar comportamento semelhante a partes de telhados; veículos possuem brilho, sombra e dimensões que variam conforme posição e material; e a vegetação pode encobrir ou sombrear coberturas.

Tabela 1 - Matriz de confusão da classificação RGBZ.

Ref.\Pred.	C1	C2	C3	C4	C5	C6	C7	C8	Total
C1	14	0	0	0	0	0	0	1	15
C2	0	6	0	0	0	0	0	0	6
C3	1	0	8	1	0	0	0	0	10
C4	0	0	0	9	0	0	2	1	12
C5	0	1	0	0	10	0	0	0	11
C6	0	0	0	0	0	5	0	0	5
C7	1	0	0	0	0	0	3	0	4
C8	1	0	0	0	1	0	1	3	6
Total	17	7	8	10	11	5	6	5	69

Fonte: os autores (2021), recalculado a partir da validação amostral.

Nota: C1 = telhado cerâmico; C2 = telhado de outro material; C3 = vegetação arbórea; C4 = vegetação rasteira; C5 = solo exposto; C6 = asfalto; C7 = veículos; C8 = caixa d'água.



**COMPARAÇÃO DE TÉCNICAS DE EXTRAÇÃO DE TELHADOS UTILIZANDO ANÁLISE DE IMAGEM BASEADA EM OBJETO (OBIA) EM PRODUTOS OBTIDOS POR AERONAVE REMOTAMENTE PILOTADA**

*Firmino e Morais, 2026.*

Na Tabela 2, referente à classificação PCA-RGBZ, a maior parte das classes apresentou concordância perfeita na diagonal principal. Os erros remanescentes concentraram-se em duas situações: solo exposto classificado como asfalto e caixa d'água classificada como telhado de outro material. A primeira confusão decorre da proximidade radiométrica e textural entre superfícies minerais, compactadas ou pavimentadas, principalmente quando a diferença de altura não é suficiente para separar as classes. A segunda ocorre porque caixas d'água estão associadas espacialmente a edificações e podem compartilhar características de elevação e contraste com coberturas artificiais.

A PCA-RGBZ apresentou desempenho superior porque reorganizou a informação das bandas em componentes que concentram variância e reduzem correlações redundantes. Em imagens RGB, as bandas do visível geralmente apresentam alta correlação, principalmente em cenas urbanas iluminadas de forma homogênea. Quando a banda Z é adicionada, há um ganho altimétrico, mas também surge a possibilidade de mistura entre objetos elevados. A PCA ajuda a separar os eixos de variação mais informativos, permitindo que o SVM opere em um espaço de atributos menos redundante e com melhor contrastação das bordas dos telhados.

Tabela 2 - Matriz de confusão da classificação PCA-RGBZ.

Ref.\Pred.	C1	C2	C3	C4	C5	C6	C7	C8	Total
C1	15	0	0	0	0	0	0	0	15
C2	0	6	0	0	0	0	0	0	6
C3	0	0	10	0	0	0	0	0	10
C4	0	0	0	12	0	0	0	0	12
C5	0	0	0	0	9	2	0	0	11
C6	0	0	0	0	0	5	0	0	5
C7	0	0	0	0	0	0	4	0	4
C8	0	1	0	0	0	0	0	5	6
Total	15	7	10	12	9	7	4	5	69

*Fonte: os autores (2021), recalculado a partir da validação amostral.*

Nota: a matriz evidencia que a maior parte dos erros foi eliminada após a transformação PCA, restando confusões pontuais entre solo exposto/asfalto e caixa d'água/telhado de outro material.

### 3.2 Métricas por classe e interpretação da matriz de confusão

A análise por classe, apresentada na Tabela 3, mostra que o ganho do método PCA-RGBZ não ocorreu apenas na acurácia global, mas principalmente na redução de erros de omissão e comissão em classes críticas para o objetivo do estudo. No conjunto RGBZ, o telhado cerâmico obteve acurácia do produtor de 93,3%, mas acurácia do usuário de 82,4%. Isso significa que poucos telhados cerâmicos foram omitidos, mas houve inclusão de objetos de outras classes



como telhado cerâmico, caracterizando erro de comissão. Em termos práticos, o mapeamento tenderia a superestimar parcialmente essa classe.

No PCA-RGBZ, o telhado cerâmico alcançou 100% tanto na acurácia do produtor quanto na acurácia do usuário. Esse resultado indica que todos os telhados cerâmicos da amostra foram identificados e que nenhum objeto de outra classe foi classificado indevidamente como telhado cerâmico. A melhora é explicada pela maior capacidade da PCA de preservar a geometria das coberturas e realçar contrastes entre bordas, alturas e respostas espectrais, reduzindo vazamentos de segmentos para áreas vizinhas.

A classe telhado de outro material apresentou 100% de acurácia do produtor nos dois métodos, indicando que todos os objetos de referência dessa classe foram detectados. Contudo, a acurácia do usuário foi de 85,7% em ambos, porque houve ao menos um objeto de outra classe classificado como telhado de outro material. Esse resultado revela que, embora a detecção dessa classe seja eficiente, ainda há risco de comissão quando objetos artificiais elevados apresentam textura ou altura semelhante, como caixas d'água.

As classes vegetação arbórea e vegetação rasteira apresentaram melhora expressiva com PCA-RGBZ. No RGBZ, a vegetação arbórea obteve acurácia do produtor de 80,0%, e a vegetação rasteira, 75,0%. No PCA-RGBZ, ambas alcançaram 100%. Isso indica que a transformação PCA contribuiu para separar melhor padrões de textura, cor e altura da vegetação em relação aos telhados e demais superfícies. Esse resultado é importante porque a vegetação é uma das principais fontes de erro na extração de telhados, especialmente quando projeta sombra ou encobre parcialmente as edificações.

Os veículos apresentaram uma das maiores limitações no RGBZ, com acurácia do usuário de 50,0% e F1-score de 60,0%. Isso indica que a classe recebeu objetos indevidos e teve baixa confiabilidade para o usuário do mapa. O resultado é compatível com a escala dos objetos: veículos são pequenos, possuem diferentes cores, refletem luz de modo variável e podem estar próximos de vias, telhados baixos ou sombras. No PCA-RGBZ, a classe veículos alcançou 100% nas métricas analisadas, sugerindo que a combinação entre componentes principais e atributos de objeto melhorou a separabilidade dessa classe.

A classe caixa d'água continuou sendo uma categoria sensível. No RGBZ, apresentou acurácia do produtor de 50,0%, acurácia do usuário de 60,0% e F1-score de 54,5%. No PCA-RGBZ, houve avanço para acurácia do produtor de 83,3%, acurácia do usuário de 100% e F1-score de 90,9%. A melhoria é relevante, mas a permanência de um erro indica que objetos pequenos, elevados e instalados sobre telhados ainda exigem cautela. Em aplicações operacionais, essa classe poderia ser agrupada a objetos artificiais elevados ou tratada por regras contextuais específicas, como posição sobre edificação e área mínima.

Tabela 3 - Métricas de acurácia por classe e por conjunto de dados.

Classe	Descrição	PA RGBZ	UA RGBZ	F1 RGBZ	PA PCA	UA PCA	F1 PCA
C1	Telhado cerâmico	93.3%	82.4%	87.5%	100.0%	100.0%	100.0%
C2	Telhado de outro material	100.0%	85.7%	92.3%	100.0%	85.7%	92.3%
C3	Vegetação arbórea	80.0%	100.0%	88.9%	100.0%	100.0%	100.0%
C4	Vegetação rasteira	75.0%	90.0%	81.8%	100.0%	100.0%	100.0%
C5	Solo exposto	90.9%	90.9%	90.9%	81.8%	100.0%	90.0%
C6	Asfalto	100.0%	100.0%	100.0%	100.0%	71.4%	83.3%
C7	Veículos	75.0%	50.0%	60.0%	100.0%	100.0%	100.0%
C8	Caixa d'água	50.0%	60.0%	54.5%	83.3%	100.0%	90.9%
<b>Geral</b>	<b>Acurácia global</b>	<b>84.1%</b>	<b>-</b>	<b>Kappa 0.813</b>	<b>95.7%</b>	<b>-</b>	<b>Kappa 0.949</b>
<b>Geral</b>	<b>F1 médio</b>	<b>-</b>	<b>-</b>	<b>82.0%</b>	<b>-</b>	<b>-</b>	<b>94.6%</b>

*Fonte: os autores (2021), com métricas estatísticas calculadas a partir da matriz de confusão.*

### 3.3 Interpretação visual dos resultados

A análise visual confirma a interpretação estatística. Na Figura 4, a segmentação RGBZ apresenta maior ocorrência de vazamento de segmentos para áreas vizinhas, principalmente em regiões de contato entre telhados, vegetação e superfícies pavimentadas. Esse vazamento ocorre quando o algoritmo agrupa pixels ou objetos que, apesar de pertencerem a classes distintas, apresentam valores próximos no espaço de atributos usado na segmentação. Em imagens urbanas de alta resolução, esse problema tende a ser frequente nas bordas das construções e nas áreas de sombra.

No resultado PCA-RGBZ, a delimitação das feições apresenta contornos mais estáveis e melhor separação entre cobertura e entorno imediato. A diferença não é apenas estética; ela afeta diretamente a qualidade do produto cartográfico final. Em aplicações como estimativa de área de telhado para energia fotovoltaica, cadastro técnico ou planejamento urbano, pequenas

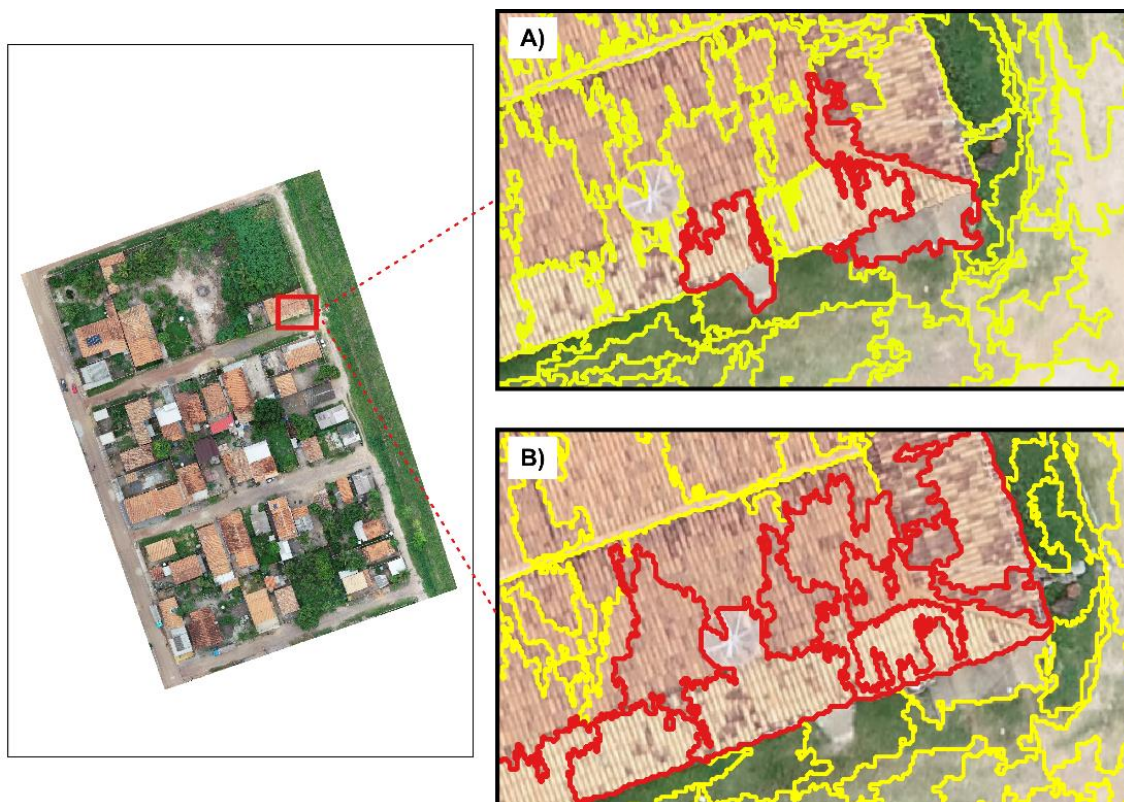


**COMPARAÇÃO DE TÉCNICAS DE EXTRAÇÃO DE TELHADOS UTILIZANDO ANÁLISE DE  
IMAGEM BASEADA EM OBJETO (OBIA) EM PRODUTOS OBTIDOS POR AERONAVE  
REMOTAMENTE PILOTADA**

*Firmino e Morais, 2026.*

falhas de contorno podem gerar erros acumulados de área, orientação ou sombreamento. Por isso, a avaliação visual foi utilizada como complemento às métricas numéricas.

Figura 4 - Comparação da segmentação: A) RGBZ com MeanShift; B) PCA-RGBZ com MeanShift.



Fonte: os autores (2021).

A Figura 5 destaca a comparação dos contornos dos telhados. No RGBZ, há maior irregularidade nas bordas, com linhas fragmentadas e ruídos associados a pequenas variações internas de textura. No PCA-RGBZ, os contornos tornam-se mais contínuos e compatíveis com a geometria das edificações. Esse resultado é coerente com a hipótese de que a PCA reduz redundâncias e reforça gradientes relevantes, permitindo ao segmentador e ao classificador trabalhar com objetos mais representativos.

Ainda assim, a suavização obtida pela PCA deve ser interpretada com cuidado. Um contorno mais suave pode melhorar a legibilidade e a coerência geométrica, mas também pode eliminar detalhes muito finos se os parâmetros de segmentação forem excessivamente generalizadores. Portanto, a vantagem observada neste estudo está associada ao equilíbrio entre preservação de forma e redução de ruído, e não à simples maximização do número de segmentos.

Figura 5 - Comparação do contorno dos telhados: A) RGBZ; B) PCA-RGBZ.



Fonte: os autores (2021).

### 3.4 Discussão metodológica e implicações

Os resultados obtidos indicam que a extração de telhados em produtos de ARP se beneficia da integração de dados espectrais e altimétricos, mas também demonstram que a simples adição do MDS ao RGB não elimina todos os problemas de separabilidade. A presença da banda Z melhora a distinção entre superfícies elevadas e não elevadas, porém objetos distintos podem compartilhar altura semelhante. Telhados, árvores, caixas d'água e partes de veículos podem ocupar intervalos altimétricos próximos, exigindo que a classificação considere atributos complementares de forma, textura e contexto.

A melhoria observada com PCA-RGBZ sugere que a transformação dos dados de entrada foi mais eficiente para reduzir correlação entre variáveis e destacar componentes que expressam diferenças úteis para a classificação. A PCA não cria informação nova, mas reorganiza a informação existente. Quando as bandas originais são redundantes, o classificador pode receber atributos repetitivos, o que nem sempre contribui para a separação das classes. Ao concentrar a variância em componentes ortogonais, a PCA tende a facilitar a leitura estatística dos padrões e pode reduzir ruídos internos nos objetos segmentados.



**COMPARAÇÃO DE TÉCNICAS DE EXTRAÇÃO DE TELHADOS UTILIZANDO ANÁLISE DE  
IMAGEM BASEADA EM OBJETO (OBIA) EM PRODUTOS OBTIDOS POR AERONAVE  
REMOTAMENTE PILOTADA**

*Firmino e Morais, 2026.*

Do ponto de vista estatístico, a diferença entre acurácia global de 84,1% e 95,7% é expressiva. Entretanto, a interpretação adequada depende da composição da matriz de confusão. Se os erros do RGBZ estivessem concentrados em classes secundárias, a aplicação para extração de telhados poderia continuar aceitável. Porém, os erros atingiram classes relacionadas ao objetivo central, como telhado cerâmico e caixa d'água, além de classes que interferem diretamente na extração, como vegetação e veículos. Isso indica que a melhoria da PCA-RGBZ não foi apenas global, mas também operacionalmente relevante.

A análise da matriz de confusão também evidencia a importância de distinguir erro de omissão e erro de comissão. Para aplicações cadastrais, erros de comissão podem gerar inclusão indevida de objetos como telhados, superestimando áreas edificadas. Para aplicações de planejamento energético, erros de omissão podem deixar de contabilizar coberturas aproveitáveis, subestimando potencial fotovoltaico. Assim, a escolha do melhor método pode depender do objetivo final: se a prioridade for evitar falsos positivos, a acurácia do usuário e a comissão devem receber maior peso; se a prioridade for não perder telhados existentes, a acurácia do produtor e a omissão tornam-se mais importantes.

No presente caso, a PCA-RGBZ foi superior tanto em termos de acertos globais quanto no equilíbrio entre precisão e recall. O F1-score médio aumentou de 82,0% no RGBZ para 94,6% no PCA-RGBZ, indicando desempenho mais equilibrado entre as classes. Esse resultado reforça que a melhoria não decorre apenas de uma classe dominante, mas de uma redução consistente dos erros em múltiplas categorias. Ainda assim, os percentuais por classe devem ser avaliados com prudência, pois algumas classes possuem poucos exemplos de validação, como veículos, asfalto e caixa d'água.

Uma limitação metodológica importante é o tamanho da amostra de validação. Embora a divisão 70/30 seja comum, o total de 69 amostras de verificação limita inferências estatísticas mais robustas, especialmente por classe. Uma mudança de apenas uma amostra em classes pequenas pode alterar significativamente a acurácia percentual. Em estudos futuros, recomenda-se ampliar o número de amostras, adotar amostragem estratificada por classe, registrar a independência espacial entre treino e validação e, quando possível, utilizar validação cruzada ou testes pareados para comparar classificadores.



Outra limitação refere-se à generalização espacial. O experimento foi realizado em uma área com três quarteirões e características urbanas específicas. O desempenho pode variar em bairros com telhados mais adensados, construções verticalizadas, ruas estreitas, maior sombreamento, telhados metálicos claros ou presença intensa de árvores. Portanto, antes de aplicar o método operacionalmente em toda uma cidade, recomenda-se realizar testes adicionais em diferentes padrões urbanos e ajustar parâmetros de segmentação, treinamento e validação.

### **3.5 Recomendações para aplicação operacional**

Apesar dessas limitações, o estudo demonstra potencial prático. A metodologia pode apoiar levantamentos cadastrais, atualização de mapas urbanos, diagnóstico de áreas construídas, estudos de energia solar e planejamento territorial em municípios com pouca disponibilidade de dados geoespaciais. A combinação entre ARP, OBIA, MDS, PCA e SVM oferece um fluxo replicável, de custo relativamente baixo e compatível com ambientes de software amplamente utilizados em geotecnologias.

Por fim, a matriz de confusão deve ser mantida como instrumento central de avaliação, mas não deve ser lida de forma isolada. Em produtos voltados ao cadastro urbano, a acurácia do usuário deve receber atenção especial, pois indica a confiabilidade dos objetos mapeados como telhado. Em aplicações de estimativa de área ou potencial fotovoltaico, a acurácia do produtor também é decisiva, pois mede a capacidade de não omitir coberturas existentes. Essa leitura orientada ao uso final torna a avaliação mais coerente com a finalidade técnica do mapeamento.

Também é recomendável documentar os parâmetros de voo, resolução espacial, data de aquisição, condições de iluminação e critérios de seleção das amostras. Esses metadados são fundamentais para reprodutibilidade, pois pequenas variações no GSD, na orientação solar ou no sombreamento podem alterar a resposta espectral das coberturas. Em estudos futuros, a inclusão de uma etapa de pós-processamento vetorial, com suavização controlada, eliminação de polígonos muito pequenos e validação topológica, pode melhorar a qualidade cartográfica final dos telhados extraídos.



**COMPARAÇÃO DE TÉCNICAS DE EXTRAÇÃO DE TELHADOS UTILIZANDO ANÁLISE DE  
IMAGEM BASEADA EM OBJETO (OBIA) EM PRODUTOS OBTIDOS POR AERONAVE  
REMOTAMENTE PILOTADA**

*Firmino e Morais, 2026.*

Para uso operacional da metodologia em áreas urbanas maiores, recomenda-se iniciar o processamento por uma etapa de calibração local. Essa calibração deve incluir a seleção de amostras representativas de diferentes materiais de cobertura, variações de iluminação, inclinação de telhados, sombras e objetos elevados. O desempenho observado no recorte de estudo indica que a PCA-RGBZ é mais robusta, mas a generalização para outros bairros depende da diversidade das amostras e da compatibilidade entre os parâmetros de segmentação e o padrão construtivo local.



#### **4 CONCLUSÃO**

O presente artigo permitiu demonstrar, com maior clareza metodológica e estatística, que a composição PCA-RGBZ apresentou melhor desempenho para a extração de telhados por OBIA em produtos de ARP. A acurácia global aumentou de 84,1% no RGBZ para 95,7% no PCA-RGBZ, enquanto o coeficiente Kappa passou de 0,813 para 0,949. O F1-score médio também apresentou melhoria expressiva, passando de 82,0% para 94,6%.

A superioridade da PCA-RGBZ está relacionada à redução de redundância entre bandas, à reorganização dos atributos espectrais e altimétricos e à melhoria da separação das bordas dos telhados. A PCA contribuiu para reduzir vazamentos de segmentação, diminuir confusões entre telhados, vegetação e objetos elevados e produzir contornos mais regulares. Os erros remanescentes concentraram-se principalmente entre solo exposto e asfalto, além de uma confusão pontual entre caixa d'água e telhado de outro material.

Conclui-se que a combinação entre ortomosaico RGB, MDS, PCA, segmentação MeanShift e classificação SVM é uma abordagem promissora para extração de telhados em áreas urbanas de pequena escala. Para aplicações futuras, recomenda-se ampliar a amostragem de validação, testar diferentes parâmetros de segmentação, comparar outros classificadores supervisionados e incorporar regras contextuais para objetos pequenos e elevados. Essas melhorias podem aumentar a robustez do método e favorecer sua aplicação em projetos de cadastro técnico, planejamento urbano e avaliação de potencial fotovoltaico.

#### **5 REFERÊNCIAS**

- ANTUNES, F. S.; NEVES, L. V.; SILVA, K. S.; GRAÇA, A. J. S. Análise da integração entre Sensoriamento Remoto e SIG na classificação da cobertura da terra em Duque de Caxias/RJ. *Revista Brasileira de Geomática*, v. 5, n. 1, p. 82-102, 2017.
- AWRANGJEB, M.; FRASER, C. S. Automatic segmentation of raw LIDAR data for extraction of building roofs. *Remote Sensing*, v. 6, n. 5, p. 3716-3751, 2014. DOI: 10.3390/rs6053716.
- BLASCHKE, T. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 65, n. 1, p. 2-16, 2010. DOI: 10.1016/j.isprsjprs.2009.06.004.



**COMPARAÇÃO DE TÉCNICAS DE EXTRAÇÃO DE TELHADOS UTILIZANDO ANÁLISE DE  
IMAGEM BASEADA EM OBJETO (OBIA) EM PRODUTOS OBTIDOS POR AERONAVE  
REMOTAMENTE PILOTADA**

*Firmino e Morais, 2026.*

- BORGES, T.; BRANFORD, S. Kalungas usam mapeamento digital para defender seu território. Mongabay - Notícias Ambientais, 2021. Disponível em: <https://brasil.mongabay.com/2021/03/comunidade-kalunga-mapeia-seu-territorio-digitalmente-para-sobreviver-no-cerrado/>. Acesso em: 23 nov. 2021.
- CAL, A. High-Resolution Object-Based Building Extraction Using PCA of LiDAR nDSM and Aerial Photos. In: TIEFENBACHER, J. P.; POREH, D. (org.). Spatial Variability in Environmental Science - Patterns, Processes, and Analyses. London: IntechOpen, 2020. DOI: 10.5772/intechopen.92640.
- CHANG, C. C.; LIN, C. J. LIBSVM: A library for support vector machines. ACM Transactions on Intelligent Systems and Technology, v. 2, n. 3, p. 1-27, 2011. DOI: 10.1145/1961189.1961199.
- COMANICIU, D.; MEER, P. Mean shift: a robust approach toward feature space analysis. IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 24, n. 5, p. 603-619, 2002. DOI: 10.1109/34.1000236.
- CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. Remote Sensing of Environment, v. 37, n. 1, p. 35-46, 1991. DOI: 10.1016/0034-4257(91)90048-B.
- FOODY, G. M. Status of land cover classification accuracy assessment. Remote Sensing of Environment, v. 80, n. 1, p. 185-201, 2002. DOI: 10.1016/S0034-4257(01)00295-4.
- HSU, C. W.; CHANG, C. C.; LIN, C. J. A Practical Guide to Support Vector Classification. Taipei: Department of Computer Science, National Taiwan University, 2016. Disponível em: <https://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>. Acesso em: 23 nov. 2021.
- HUANG, C.; WEI, H. L.; RAU, J. Y.; JHAN, J. P. Use of principal components of UAV-acquired narrow-band multispectral imagery to map the diverse low stature vegetation fAPAR. GIScience & Remote Sensing, v. 56, n. 4, p. 605-623, 2019. DOI: 10.1080/15481603.2018.1550873.
- JOLLIFFE, I. T.; CADIMA, J. Principal component analysis: a review and recent developments. Philosophical Transactions of the Royal Society A, v. 374, n. 2065, 2016. DOI: 10.1098/rsta.2015.0202.
- LOPES, T.; MELANDA, E. A.; STANGANINI, F. N. Avaliação dos produtos cartográficos gerados por RPA quadrimotor. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19., 2019, Santos. Anais [...]. São José dos Campos: INPE, 2019. p. 2438-2441.
- MARROQUIM, R. MeanShift Segmentation. Rio de Janeiro: Universidade Federal do Rio de Janeiro, 2016. Disponível em: <https://www.lcg.ufrj.br/marroquim/courses/cos756/assignments/assignment-meanshift-segmentation.pdf>. Acesso em: 23 nov. 2021.



**COMPARAÇÃO DE TÉCNICAS DE EXTRAÇÃO DE TELHADOS UTILIZANDO ANÁLISE DE  
IMAGEM BASEADA EM OBJETO (OBIA) EM PRODUTOS OBTIDOS POR AERONAVE  
REMOTAMENTE PILOTADA**

*Firmino e Morais, 2026.*

NOORI, R. et al. Assessment of input variables determination on the SVM model performance using PCA, Gamma test, and forward selection techniques for monthly stream flow prediction. *Journal of Hydrology*, v. 401, p. 177-189, 2011.

PORTELA, N. M. Modelo de mistura de Gaussiana Fuzzy contextual. 2015. Tese (Doutorado em Ciência da Computação) - Universidade Federal de Pernambuco, Recife, 2015.

SIMS, D. A.; GAMON, J. A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sensing of Environment*, v. 81, n. 2-3, p. 337-354, 2002. DOI: 10.1016/S0034-4257(02)00010-X.

STEHMAN, S. V. Selecting and interpreting measures of thematic classification accuracy. *Remote Sensing of Environment*, v. 62, n. 1, p. 77-89, 1997. DOI: 10.1016/S0034-4257(97)00083-7.