

SENSORIAMENTO REMOTO PARA ESTIMATIVAS POPULACIONAIS EM CIDADES DE PEQUENO PORTE

Remote sensing for population estimates in small towns

Teledetección para estimaciones poblacionales en ciudades pequeñas



Analissa Haga 

Centro Universitário de Adamantina (FAI)
E-mail: analissahaga@hotmail.com

Paulo Roberto da Silva Ruiz 

Faculdade de Tecnologia do Estado de São Paulo (FATEC)
E-mail: paulo.ruiz@cps.sp.gov.br

RESUMO

Estudos sobre a dinâmica da ocupação e expansão urbana impactam no planejamento de políticas públicas, bem como na alocação de recursos para sua implementação e ganham relevância especialmente porque um dos Objetivos de Desenvolvimento Sustentável (ODS) da ONU é desenvolver cidades e comunidades sustentáveis. A atualização da população urbana é importante para a obtenção de recursos financeiros para gerir e planejar as cidades, porém, devido à complexidade desses levantamentos, a obtenção de dados atualizados não é trivial para auxiliar na tomada de decisão dos gestores urbanos. Nesse sentido este trabalho estuda o Sensoriamento Remoto como uma alternativa para estimar a população urbana em períodos intercensitários. O objetivo foi verificar a correlação linear entre população urbana e área urbanizada em municípios da Nova Alta Paulista - Adamantina, Dracena, Junqueirópolis, Lucélia e Osvaldo Cruz - nos anos de 2000, 2010 e 2022. A metodologia envolveu coleta de dados populacionais do IBGE e levantamento da área urbanizada por meio de imagens do satélite Landsat, sendo desenvolvidos modelos de regressão linear cuja acurácia foi avaliada por métricas de erro médio absoluto. Os resultados indicaram forte correlação entre crescimento da área urbanizada e aumento da população; contudo o erro médio indicou que o modelo apresenta limitações para estimativa populacional, recomendando-se testar variáveis adicionais. Por fim, foi possível projetar a população dessas cidades para o ano de 2030. O desenvolvimento desta pesquisa conclui que o Sensoriamento Remoto é uma ferramenta auxiliar para estimativas populacionais, colaborando com o planejamento e a formulação de políticas públicas urbanas.

Palavras-chave: Censo demográfico; Ciência de dados espaciais; Regressão linear; Urbanização.

Histórico do artigo

Recebido: 03 abril, 2026
Aceito: 31 maio, 2026
Publicado: 15 junho 2026

<https://doi.org/10.33237/2236-255X.2026.7936>



ABSTRACT

Studies on the dynamics of occupation and urban expansion impact the planning of public policies, as well as the allocation of resources for their implementation, and they gain relevance especially because one of the UN's Sustainable Development Goals (SDGs) is to develop sustainable cities and communities. Updating urban population data is important for securing financial resources to manage and plan cities; however, due to the complexity of such surveys, obtaining updated data is not trivial to support decision-making by urban managers. In this context, this study investigates Remote Sensing as an alternative for estimating urban population during inter-census periods. The objective was to verify the linear correlation between urban population and urbanized area in municipalities of the Nova Alta Paulista region - Adamantina, Dracena, Junqueirópolis, Lucélia, and Osvaldo Cruz - for the years 2000, 2010, and 2022. The methodology involved collecting population data from IBGE and surveying the urbanized area using images from the Landsat satellite, with linear regression models being developed, whose accuracy was assessed using mean absolute error metrics. The results indicated a strong correlation between the growth of urbanized area and population increase; however, the mean error indicated that the model has limitations for population estimation, and testing additional variables is recommended. Finally, it was possible to project the population of these cities for the year 2030. The development of this research concludes that Remote Sensing is a supportive tool for population estimates, contributing to the planning and the formulation of urban public policies.

Keywords: Demographic census; Spatial data science; Linear regression; Urbanization.

RESUMEN

Estudios sobre la dinámica de la ocupación y expansión urbana impactan en la planificación de políticas públicas y en la asignación de recursos para su implementación. Dado que uno de los Objetivos de Desarrollo Sostenible (ODS) de la ONU es desarrollar ciudades y comunidades sostenibles, estos estudios cobran relevancia. La actualización de la población urbana es importante para obtener recursos financieros para gestionar las ciudades, pero debido a la complejidad de estos levantamientos, la obtención de datos actualizados no es trivial para apoyar la toma de decisiones de los gestores urbanos. Este trabajo estudia la Teledetección como alternativa para estimar la población urbana en períodos intercensales, con el objetivo de verificar la correlación lineal entre población urbana y área urbanizada en municipios de la Nova Alta Paulista (Adamantina, Dracena, Junqueirópolis, Lucélia y Osvaldo Cruz) en los años 2000, 2010 y 2022. La metodología implicó la recolección de datos poblacionales del IBGE y el levantamiento del área urbanizada mediante imágenes del satélite Landsat, desarrollando modelos de regresión lineal cuya precisión fue evaluada con error absoluto medio. Los resultados indicaron fuerte correlación entre crecimiento del área urbanizada y aumento poblacional; sin embargo, el error medio señaló limitaciones para la estimación, recomendándose probar variables adicionales. Finalmente, se proyectó la población para 2030, concluyendo que la Teledetección es una herramienta auxiliar para estimaciones poblacionales que colabora con la planificación y formulación de políticas públicas urbanas.

Palabras clave: Censo demográfico; Ciencia de datos espaciales; Regresión lineal; Urbanización.

1 INTRODUÇÃO

Os Objetivos de Desenvolvimento Sustentável (ODS) da Organização das Nações Unidas (ONU, 2025), buscam atender às expectativas das cidades e comunidades sustentáveis. Nesse sentido, a ocupação e a expansão das áreas urbanas são fatores



importantes para o planejamento territorial e a formulação de políticas públicas eficazes, uma vez que a compreensão da dinâmica desses fenômenos é fundamental para a elaboração de estratégias, alocação de recursos governamentais, o desenvolvimento de infraestruturas e a promoção do bem-estar social (Rosa, 2018). A ausência de dados atualizados sobre a população urbana pode resultar em decisões não tão eficientes, as quais podem dificultar o desenvolvimento socioeconômico dos municípios e a qualidade de vida de seus habitantes.

No Brasil, segundo a Confederação Nacional de Municípios (2025), o critério para o repasse de verbas a municípios varia conforme o tipo de recurso, mas geralmente incluem população, renda per capita, perfil demográfico e epidemiológico, e a participação do município no orçamento local. Para repasses federais, como o Fundo de Participação dos Municípios (FPM), a população é um fator chave: quanto maior a população, maior o coeficiente de participação e, conseqüentemente, maior o valor recebido, refletindo a necessidade de mais serviços públicos (Mesquita, 2025).

O Instituto Brasileiro de Geografia e Estatística (IBGE) é o órgão responsável pela realização dos Censos Demográficos, que fornece informações detalhadas da população e de suas características. Contudo, a periodicidade decenal desses levantamentos, aliada à sua complexidade logística e financeira, gera lacunas significativas de informação entre um censo e outro (IBGE, 2022). Essa defasagem pode levar à desatualização dos indicadores e prejudicar a distribuição adequada de investimentos e serviços públicos, afetando a capacidade dos municípios de atender às necessidades de sua população (Guiarra; Yallouz; Silva, 2019).

Essa atualização é particularmente relevante para municípios de pequeno porte, cujas receitas dependem de fontes limitadas de arrecadação. Santos (1982) identifica três categorias de cidade, sendo elas: as grandes, as quais são marcadas pela seletividade da atividade produtora moderna; as médias ou intermediárias e as pequenas. Segundo o REGIC - Regiões de Influência das Cidades (IBGE, 2018), cidades com até 20 mil habitantes são classificados como pequenas - categoria que abrange mais de 80% dos municípios – e são também denominadas Centros Locais. Apesar da fraca centralidade em atividades empresariais e de gestão pública, esses municípios têm peso relevante no contexto nacional por sua quantidade e capilaridade territorial. Embora constituam a maioria, boa parte delas não apresenta plano diretor, pois o Estatuto da Cidade (EC) estabelece a obrigatoriedade de sua elaboração apenas para municípios com população superior a 20 mil habitantes, ficando as cidades pequenas com até esse limite desobrigadas



legalmente. Esses centros locais têm outros centros urbanos de maior hierarquia como referência (IBGE, 2018; Ramos, 2011).

Diante desse cenário, o Sensoriamento Remoto (SR) surge como alternativa para o monitoramento e atualização de dados territoriais, complementando os esforços dos censos tradicionais. Essa tecnologia permite a obtenção de informações sobre a superfície terrestre a partir da radiação eletromagnética refletida pelos objetos, captada por sensores a bordo de satélites (Jensen, 2009). A capacidade dos sensores orbitais de transformar essa energia em imagens possibilita o mapeamento das dinâmicas territoriais e da expansão urbana, fornecendo subsídios valiosos para o planejamento do uso e cobertura do solo (Ruiz, 2017). Guiarra, Yallouz e Silva (2019) destacam que essa tecnologia resulta em economia de tempo e recursos para os tomadores de decisão no planejamento de políticas públicas regionais, tais como prefeitos, secretários municipais de planejamento e meio ambiente, conselheiros de desenvolvimento regional e técnicos de órgãos estaduais de gestão territorial.

Partindo dessa premissa, este trabalho busca responder à seguinte questão: é possível utilizar imagens de satélite da área urbanizada para estimar a população em períodos intercensitários em municípios de pequeno porte? A investigação contribui para o desenvolvimento de ferramentas complementares aos censos tradicionais, permitindo estimativas populacionais mais frequentes e menos dispendiosas. Tais estimativas são importantes para um planejamento urbano e regional mais eficiente no contexto brasileiro, auxiliando gestores públicos e pesquisadores na tomada de decisões e na otimização de recursos, promovendo um desenvolvimento mais sustentável das cidades.

Assim, o presente trabalho teve como objetivo verificar a correlação linear entre a população urbana e a área urbanizada de municípios selecionados da Nova Alta Paulista – Adamantina, Dracena, Junqueirópolis, Lucélia e Osvaldo Cruz – nos anos de 2000, 2010 e 2022, utilizando imagens de satélite e modelos de regressão linear. Busca-se, com isso, gerar subsídios para o planejamento urbano e regional por meio de projeções populacionais intercensitárias.

2 SENSORIAMENTO REMOTO NA ANÁLISE URBANA

O Sensoriamento Remoto consiste no conjunto de atividades que permite a obtenção de informações dos objetos que compõem a superfície terrestre sem a necessidade de contato direto com os mesmos (Novo, 2010), funcionando a partir de



sensores, instalados em satélites artificiais, que captam a radiação solar refletida pelos objetos presentes na superfície terrestre. Os diferentes materiais absorvem ou refletem a radiação incidente, onde parte dela fica presa na atmosfera e outra parte chega ao espaço. Os sensores acoplados aos satélites captam essa radiação, a qual é chamada de reflectância e a transforma na propriedade física nomeada radiância. Cada objeto reflete de forma diferente a radiação solar ao longo do espectro eletromagnético, dessa forma é possível diferenciá-los através de sua radiância transformada em imagem (Jensen, 2009).

Conforme Jensen (2009), os sensores ópticos são classificados de acordo com suas resoluções, sendo: (a) espacial - refere-se ao tamanho do menor objeto detectável, relacionado ao tamanho de pixel produzido; (b) espectral - corresponde ao número de bandas que o sensor possui, com isso melhor será a distinção espectral dos objetos; (c) radiométrica - capacidade de detectar variações sutis na intensidade da radiação através da quantização do nível de cinza em cada banda espectral e (d) temporal – é o tempo de revisita do sensor, ou seja, a periodicidade em gerar novas imagens do mesmo local.

Uma das principais vantagens do SR é a capacidade dos sensores multiespectrais de capturar informações em diversas faixas do espectro eletromagnético, indo além da luz visível. Enquanto uma imagem colorida convencional (RGB) é composta pela combinação das bandas de vermelho, verde e azul — reproduzindo a cor como o olho humano a percebe — os sensores multiespectrais registram dados em bandas adicionais, como o infravermelho,

permitindo análises muito mais aprofundadas da superfície terrestre (Richardson, Wiegand, 1977; Ponzoni, Shimabukuru, 2010). Satélites comerciais como *WorldView-3* obtém imagens em 16 bandas, outros como o *Geoeye* em 8 bandas, sendo considerados multiespectrais. Já os sensores hiperspectrais utilizam estreitas bandas, as quais permitem identificar detalhes de materiais e diferenciar superfícies, um deles é o AVIRIS da NASA com 224 bandas espectrais (Ruiz, 2017).

O precursor dos satélites atuais é o ERTS-1 ou Landsat-1, lançado em 1972, o qual foi desenvolvido para atuar diretamente em pesquisas de recursos naturais com câmeras *Return Beam Vidicon* (RBV) e *Multispectral Scanner System* (MSS), presentes no Landsat 2 (1975) e no Landsat 3 (1978), já o Landsat 4 (1982) incluiu o sensor *Thematic Mapper* (TM), que permanece no Landsat-5 (1984). O Landsat 6 foi projetado com o sensor *Enhanced Thematic Mapper* (ETM), com configurações semelhantes ao seu antecessor, adicionando a banda 8 pancromática com 15 metros de resolução espacial. O sensor ETM evoluiu para o sensor ETM+ (*Enhanced Thematic*



Mapper Plus) no Landsat 7 de 1999, permitindo melhorar a acurácia do sistema nos mesmos intervalos espectrais, ampliando a resolução espacial da banda 6 (infravermelho termal) para 60 metros, e a banda pancromática permitiu a geração de composições coloridas com 15 metros de resolução. O Landsat 8 de 2013 opera com os instrumentos *Operational Land Imager* (OLI) e *Thermal Infrared Sensor* (TIRS) e incluiu duas novas bandas espectrais, uma projetada para estudos de áreas costeiras e outra para detecção de nuvens do tipo cirrus (EMBRAPA, 2018).

Em 2021, foi lançado o Landsat 9, sendo o mais recente avanço no programa de observação terrestre da agência espacial norte-americana (NASA), dando continuidade a uma série de mais de 50 anos de monitoramento orbital. Herdando a órbita polar e a passagem equatorial de seu antecessor, o satélite opera com dois instrumentos principais: o *Operational Land Imager 2* (OLI-2), que captura dados em nove bandas espectrais com resolução espacial de 30 metros (15 metros para a banda pancromática), e o *Thermal Infrared Sensor 2* (TIRS-2), que monitora a temperatura da superfície em duas bandas termais com resolução de 100 metros. Essa combinação de resoluções espacial, espectral e radiométrica permite a detecção de mudanças sutis na superfície terrestre, sendo vastas suas aplicações, incluindo o monitoramento do desmatamento da agricultura, a gestão de recursos hídricos, o acompanhamento do crescimento urbano, o mapeamento de desastres naturais e o estudo dos impactos das mudanças climáticas (Xu; Ren; Lin, 2024).

2.1 Aplicações em expansão urbana

Mazroa *et al.* (2024) examinam a expansão urbana na aglomeração de Vila Velha utilizando imagens Landsat. Foram analisados os padrões de crescimento urbano por meio da Entropia de *Shannon*, indicando alta taxa de expansão. Foram utilizados os Módulos para Simulações de Mudanças no Uso do Solo (Molusce) e Redes Neurais *Perceptron* Multicamadas para prever a expansão da malha urbana para 2034, projetando um aumento de 51,64 km² em 2024 e 62,31 km² em 2034. Campos (2020) estima a densidade populacional da região metropolitana de Belo Horizonte usando imagens Landsat 7 ETM de média resolução espacial e dados de setores censitários do Censo do IBGE entre 2000 e 2010, com modelos de regressão. Foram utilizadas como variáveis explicativas as médias das reflectâncias das bandas espectrais das imagens, observadas no nível dos setores censitários e das grades estatísticas. A densidade populacional dos setores censitários foi utilizada como variável dependente. Em um segundo momento, observaram-se as



reflectâncias e a população distribuída no nível dos pixels das imagens, a partir de um procedimento de regressão iterada. O método em nível de pixel apresentou resultados consistentes para municípios com alta densidade populacional (0,7%), enquanto o método em nível dos setores mostrou resultados satisfatórios para municípios com baixa densidade populacional.

Aguiar e Baptista (2023) avaliaram o crescimento da mancha urbana em bairros do Distrito Federal (DF) por meio da classificação pixel a pixel de imagens Landsat 5 e, submetidas à conversão para reflectância de superfície e correção geométrica para gerar mapas com menor mistura espectral e identificar as classes. A classificação da cobertura do solo foi realizada com o algoritmo *K-Nearest Neighbor* (KNN), construindo-se a matriz de confusão para verificar a acurácia e o índice *Kappa* para validação e análise. Foi estimada a curva de tendência de crescimento urbano, na qual Ceilândia apresenta expansão acelerada e fragmentada, com ocupação de áreas periféricas e redução da vegetação. Já Sol Nascente/Pôr do Sol apresenta crescimento mais controlado, com menor avanço sobre áreas naturais, devido a políticas de zoneamento. Os autores destacam que a utilização de métodos híbridos, combinados com o algoritmo *Random Forest*, pode melhorar os resultados em áreas urbanas complexas.

Em estudos que integram dados geoespaciais diversos, Huang *et al.* (2021) aplicaram redes neurais profundas, como *DenseNet* e VGG, para correlacionar imagens Sentinel-2 com dados populacionais do *LandScan*, demonstrando a capacidade de captar variações demográficas em alta resolução, ainda que com tendência a superestimar áreas pouco povoadas e subestimar as densamente ocupadas. De forma complementar, Luo *et al.* (2019) combinaram imagens de alta resolução do satélite GaoFen-2 com dados do *Open Street Map*, utilizando atributos morfológicos e uma estratégia de hierarquia viária no classificador *Random Forest* para distinguir classes de cobertura do solo com características espectrais similares, alcançando uma classificação mais precisa em ambientes urbanos complexos.

3 METODOLOGIA

3.1 Área de estudo

Para este trabalho foram consideradas as cidades de Adamantina, Dracena, Junqueirópolis, Lucélia e Osvaldo Cruz, municípios do interior do Estado de São Paulo,




localizados na região da Nova Alta Paulista, os quais possuem população superior a 20 mil habitantes no censo de 2022. A Nova Alta Paulista, que faz parte do extremo oeste do estado, é uma região de formação geográfica e ocupação humana relativamente recente, cujo povoamento se intensificou sobretudo a partir do século XX com a expansão da frente cafeeira e, posteriormente, de culturas como o algodão e a cana-de-açúcar, que moldaram sua economia. Caracterizada por uma matriz urbana em que cidades médias e pequenas exercem papel central na organização do território, a região apresenta uma dinâmica populacional e de uso do solo marcada pela forte interação entre o urbano e o rural (Gil, 2004).

A Figura 01 apresenta a localização dessa região e uma imagem do satélite Landsat 9 em falsa-cor, indicando as áreas urbanas em tom roxo. Essas cidades foram selecionadas por exemplificarem a expansão urbana característica de regiões onde a urbanização interage diretamente com o agronegócio. Segundo o último Censo Populacional (IBGE, 2022), Dracena é o município que possui a maior população, sendo de 45.474 habitantes. Já Adamantina figura como o segundo município em termos de população, perfazendo um total de 34.687 habitantes. A terceira posição cabe a Osvaldo Cruz, com 31.272 habitantes. Por fim, Junqueirópolis e Lucélia possuem, respectivamente, 20.448 e 20.372 habitantes.

Este trabalho está dividido nas etapas de obtenção dos dados, seguida da classificação da imagem para a extração da área das cidades selecionadas, paralelamente coletou-se os dados da população urbana dos censos para a criação do modelo de inferência populacional, finalizando com a verificação da acurácia deste modelo. Essas etapas são apresentadas na Figura 02.



Figura 01 – Região da Nova Alta Paulista e imagem Landsat-9 com as cidades selecionadas.



Fonte: Adaptado de Gil (2004).

Figura 02 – Fluxograma metodológico



Fonte: Elaborado pelos autores (2025).

Os tópicos seguintes abordam cada uma das etapas apresentadas no fluxograma metodológico.

3.2 Dados e extração das áreas urbanas

Para este trabalho, foram utilizadas imagens provenientes da série de satélites Landsat, sendo priorizadas imagens do mês de junho dos anos do recenseamento do IBGE,

objetivando minimizar a interferência de nuvens e garantir condições de iluminação e ângulo solar semelhantes entre os anos. A imagem do ano 2000 foi obtida do Landsat 5, datada de 05 de junho. Já para o ano de 2010 foi obtida imagem de 11 de junho proveniente do Landsat 7. E para 2022, foi utilizada uma imagem de 29 de junho do Landsat 8.

Após o download, as imagens são submetidas ao pré-processamento, que inclui a correção atmosférica, utilizando o algoritmo *Dark Object Subtraction* (DOS), para converter os valores digitais em reflectância de superfície, um passo fundamental para a comparabilidade temporal dos dados (Chander; Markham; Helder, 2009). A partir da seleção das cidades, foram definidas as classes de cobertura do solo, sendo binária: urbana e não urbana. A classe urbana compreende áreas construídas, asfalto e outras superfícies impermeáveis, que geralmente apresentam alta reflectância no infravermelho médio e baixa no infravermelho próximo. A classe não urbana agrega todas as outras coberturas, como vegetação, solo exposto e corpos d'água.

A coleta de amostras de treinamento consiste em selecionar pixels que representem adequadamente cada classe de cobertura. Essas amostras são coletadas considerando os atributos espectrais das bandas da imagem, garantindo que sejam representativas daquela classe. Com um conjunto expressivo de amostras de treinamento, o algoritmo *Support Vector Machine* (SVM) foi treinado para reconhecer o padrão espectral associado a cada classe e, em seguida, aplicado a toda a cena para classificar cada pixel individualmente.

O SVM busca encontrar um hiperplano ótimo para maximizar a separação entre diferentes classes no espaço de características (Vapnik, 1999). Ele trabalha identificando a fronteira de decisão que melhor separa os pontos de diferentes classes, utilizando um conceito chamado de margem máxima. Quando os dados não são linearmente separáveis, ele pode usar funções *kernel*, como o *radial basis function* (RBF) e o polinomial, para projetar os dados em um espaço de dimensão superior, onde a separação se torna viável. Esse método tem demonstrado alta precisão em classificações complexas, sendo aplicado em estudos de uso e cobertura do solo devido à sua capacidade de generalização e robustez em diferentes condições ambientais (Mountrakis; Im; Ogole, 2011). Por fim, é realizada a validação e avaliação da qualidade da classificação. Essa etapa foi realizada por meio de inspeção visual, comparando o mapa gerado e as imagens de satélites por meio de sobreposição das áreas.

A partir do mapa temático, salvo em formato *shapefile* foi calculada a área da classe “urbano”. Esse procedimento foi realizado no software QGIS, por meio da calculadora de



campo. Para isso foi necessário transformar o sistema de coordenadas para métrico, utilizando a projeção *Universe Transverse Mercator* (UTM). Esse sistema permite a extração de medidas a partir de um arquivo vetorial, pois suas coordenadas são dadas em metros, não em graus.

3.3 Modelo de inferência populacional

(Um espaço em branco, simples, com letra tamanho 12)

Para cada ano censitário, foi calculado o coeficiente de correlação linear de Pearson entre a área urbanizada (variável independente) e a população urbana (variável dependente), conforme a fórmula da Eq. 1, estabelecida na literatura estatística (Callegari-Jacques, 2009).

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}} \quad (1),$$

onde x_i representa a área urbanizada do município i ; y_i sua população urbana; $\bar{x}$ e $\bar{y}$ as respectivas médias. A significância estatística foi avaliada através do teste t de *Student*, considerando $p < 0,05$ como limiar de significância. Posteriormente, foram desenvolvidos modelos de regressão linear simples para cada período, conforme a Eq. 2.

$$P = a * A + b \quad (2),$$

onde P representa a população estimada; A a área urbana; a é o coeficiente angular (inclinação da reta), indicando a variação esperada na população urbana para cada unidade de aumento na área urbana; e b é o coeficiente linear (intercepto), representando a população urbana estimada quando a área urbana é zero, conforme metodologia descrita por Fávero e Belfiore (2017).

A validação do modelo foi realizada através de teste de previsão intercensitária, utilizando os coeficientes de um período para estimar a população do período subsequente. Especificamente, o modelo de 2000 foi aplicado para prever 2010 e 2022, e o modelo de 2010 para prever 2022. A acurácia foi mensurada através das métricas: Erro Absoluto Médio (*Mean Absolute Error* – MAE) e Erro Percentual Absoluto Médio (*Mean Absolute Percentage Error* - MAPE). Sendo que o MAPE foi



classificado em <10% (excelente), 10-20% (bom), 20-50% (razoável), >50% (inaceitável).

O MAE mede a magnitude média dos erros em um conjunto de previsões, sem considerar a direção dos erros. É a média da diferença absoluta entre os valores previstos e os valores reais (Eq. 3).

$$AE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3),$$

onde n é o número de observações, y_i é o valor real da observação i e $\hat{y}_i$ é o valor previsto para a observação i .

O MAPE mede a magnitude do erro em relação ao tamanho do valor real, expressa a precisão como uma porcentagem, conforme a Eq. 4.

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (4),$$

onde n é o número de observações, y_i é o valor real da observação i e $\hat{y}_i$ é o valor previsto para a observação i .

A partir do modelo validado de 2022, foram desenvolvidas projeções populacionais para 2030, considerando dois cenários de expansão urbana: Cenário 1 - Manutenção da taxa histórica de crescimento da área e Cenário 2 - Crescimento moderado (metade da taxa histórica).

No Cenário 1, a taxa média anual de crescimento da área (TMA) urbana foi calculada utilizando o conceito de crescimento exponencial, que é análoga ao cálculo de juros compostos em matemática financeira (Eq. 5). A fórmula determina qual taxa constante, quando aplicada repetidamente ano a ano durante 22 períodos, produz o crescimento total observado entre 2000 e 2022.

$$TMA = \left[\left(\frac{\text{área}_{2022}}{\text{área}_{2000}} \right)^{\left(\frac{1}{22} \right)} - 1 \right] * 100 \quad (5),$$

onde $\left(\frac{\text{área}_{2022}}{\text{área}_{2000}}\right)$ representa o fator de crescimento total no período; e $\frac{1}{22}$ distribui este crescimento uniformemente ao longo de cada ano.

Essa taxa foi então projetada para os 8 anos seguintes através da Eq. 6, que expande a área urbana mantendo o ritmo histórico de crescimento.

$$\text{Área}_{2030} = \text{área}_{2022} * (1 + TMA/100)^8 \quad (6),$$

Por fim, a população correspondente no Cenário 1 foi estimada aplicando os coeficientes do modelo de 2022 na Eq. 7.

$$\text{Pop}_{2030} = a_{2022} * \text{Área}_{2030} + b_{2022} \quad (7),$$

onde a_{2022} representa o coeficiente angular (habitantes por unidade de área) e b_{2022} , o intercepto da reta de regressão.

No Cenário 2, modificou-se apenas a premissa de expansão territorial, utilizando metade da taxa histórica calculada na mesma fórmula de projeção de área (Eq. 8). Além disso, manteve-se inalterada a aplicação do modelo de regressão para a estimativa populacional.

$$\text{Área}_{2030} = a_{2022} * \left(1 + \frac{\left(\frac{TMA}{2}\right)}{100}\right)^8 \quad (8),$$

A abordagem de múltiplos cenários segue metodologia de projeção populacional para o Brasil, desenvolvido pelo Ministério do Desenvolvimento Social e Combate à Fome para projeções populacionais municipais (Brasil, 2013).

4 RESULTADOS

Os dados populacionais e as áreas dos municípios estimadas por meio do satélite são apresentados no Tabela 01.



Tabela 01 – Dados populacionais e área estimada dos municípios

Município	2000			2010			2022		
	Pop. Total	Pop. Urbana	Área Est. (Km ²)	Pop. Total	Pop. Urbana	Área Est. (Km ²)	Pop. Total	Pop. Urbana	Área Est. (Km ²)
Adamantina	33.497	30.368	7,415	33.797	31.948	10,658	34.687	33.536	13,241
Dracena	40.500	37.153	7,351	43.258	39.946	11,893	45.474	42.064	17,343
Junqueirópolis	17.005	13.420	3,047	18.726	15.399	4,711	20.448	18.958	6,807
Lucélia	18.316	15.698	3,561	19.882	17.219	4,182	20.061	16.654	5,856
Osvaldo Cruz	29.648	26.141	5,406	30.917	27.782	7,561	31.272	28.953	9,664

Fonte: Adaptado do IBGE (2025).

A Tabela 02 apresenta o resumo das correlações. Em todos os anos avaliados, as correlações foram muito fortes, muito significativas e bem representados pelo modelo linear.

Tabela 02 – Resumo dos resultados das correlações


Ano	Correlação	p-valor	R ²
2000	0,9649	0,0078	0,9311
2010	0,9754	0,0046	0,9514
2022	0,9874	0,0017	0,9750

Fonte: Elaborado pelos autores (2025)

A Figura 03 apresenta as regressões lineares, sendo que em 2000, embora o modelo linear represente 96% dos dados, Dracena e Adamantina apresentam maior distância do intercepto linear indicando um padrão de crescimento diferente das demais cidades. Em 2010, Adamantina e Dracena ficam mais próximas do intercepto, aumentando a correlação e tornando o modelo mais equilibrado, embora as demais se afastem levemente da linha. Por fim, em 2022, Dracena, Adamantina, Junqueirópolis e Lucélia ficam bem próximas do intercepto apresentando a maior correlação.



Figura 03 – Regressão Linear para os anos de 2000, 2010 e 2022




Fonte: Elaborado pelos autores (2025).

A forte correlação positiva (r), a significância (valor- p) e a representação do modelo (R^2) observadas corroboram com a literatura utilizada neste estudo apontando que o SR pode ser uma alternativa complementar e eficaz para o monitoramento da dinâmica urbana (Saberifar, 2013; Campos, 2020; Huang *et al.*, 2021). Este achado indica que a mancha urbana é um indicador relevante para o crescimento populacional.

A Figura 04 apresenta as projeções de população a partir dos modelos gerados pela equação da correlação para cada cidade. As linhas tracejadas correspondem à projeção populacional para o ano do próximo censo, sendo o modelo do ano 2000 projetando as populações de 2010 e 2022 e o modelo de 2010 projetando a população de 2022.



Figura 04 – Projeções populacionais por município – cenários de modelagem




Fonte: Elaborado pelos autores (2025)

A Figura 05 apresenta a acurácia das previsões dos modelos para cada uma das cidades, revelando por meio do MAE (em barras - habitantes) e o MAPE (em linha - porcentagem) padrões temporais das projeções populacionais. O modelo 2000 → 2010 já



apresentava erros significativos, variando de 10,6% em Lucélia a 54,8% em Adamantina, indicando mudanças nos padrões de densidade urbana na primeira década. O modelo atualizado 2010 → 2022 demonstrou substancial melhoria, com erros entre 10,1% e 28,7%, confirmando que modelos recentes produzem previsões mais confiáveis. Já o modelo 2000 → 2022 evidenciou a limitada vida útil dessas relações área-população, com enormes erros entre 54,7% e 92,2%, destacando que projeções de longo prazo exigem recalibração periódica dos parâmetros.

Figura 05 – Acurácia dos modelos por cidade




Fonte: Elaborado pelos autores (2025)

A Figura 06 apresenta a acurácia geral dos modelos a partir da média das cinco cidades. Evidencia-se claramente a superioridade do modelo 2010 → 2022, que apresenta o melhor equilíbrio entre as métricas de erro: um erro em termos absolutos

de 6.497 habitantes, significando 22,8% de erro em relação a realidade. Em contraste, o modelo 2000 → 2022 demonstra a degradação temporal dos parâmetros, com um grande erro de 21.069 habitantes, superando em mais de três vezes o erro do melhor modelo.


Figura 06 – Acurácia dos modelos – média das cidades



Fonte: Elaborado pelos autores (2025)

O gráfico de projeções populacionais para 2030 apresenta três conjuntos de barras comparativas para cada município, onde as barras azuis representam a população real de 2022, as verdes indicam as projeções do Cenário 1 (manutenção das taxas históricas de expansão territorial) e as de cor vinho mostram as estimativas do Cenário 2 (crescimento moderado da área urbana) (Figura 07). Analisando as projeções, observa-se que Dracena apresenta o maior crescimento absoluto, saltando de 42.064 habitantes em 2022 para mais de 54.000 no Cenário 1 em 2030, refletindo sua elevada taxa de expansão territorial histórica de 3,82% ao ano. Junqueirópolis destaca-se com o maior crescimento percentual, projetando aumento de 25-35% devido à sua intensa expansão urbana (3,49% a.a.), enquanto Adamantina e Osvaldo Cruz mantêm crescimentos moderados entre 10-20%, consistentes com suas taxas de expansão de 2,58% e 2,50% respectivamente. Lucélia, apesar da taxa de crescimento territorial de 2,25% a.a., apresenta a menor expansão populacional, indicando possíveis mudanças nos padrões de densidade demográfica.

Figura 07 – Projeções populacionais para 2030 a partir do modelo de 2022



Fonte: Elaborado pelos autores (2025)

Apesar do modelo linear apresentar bons parâmetros, devido a sua simplicidade, ele não pode explicar totalmente o crescimento da população urbana por meio da expansão da mancha urbana, pois há algumas limitações considerando as dinâmicas heterogêneas de urbanização. As métricas sugerem que fatores específicos locais podem influenciar a relação entre área e população de maneiras distintas. Fatores como a verticalização das cidades, a presença de grandes áreas não residenciais ou a distribuição socioeconômica da população influenciam diretamente a densidade e não foram contemplados neste trabalho.

Ressalta-se que este estudo visa complementar e apoiar a utilização de ferramentas que facilitem estudos demográficos, entretanto, não substitui a necessidade do levantamento censitário.

5 CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo principal verificar a correlação linear entre a população urbana e a área urbanizada em cinco municípios da região da Nova Alta Paulista (Adamantina, Dracena, Junqueirópolis, Lucélia e Osvaldo Cruz) para os anos de 2000, 2010 e 2022, no intuito de avaliar a viabilidade do uso de imagens de satélite



para estimar a população em períodos intercensitários. Para isso, realizou-se a coleta e organização de dados, o desenvolvimento e validação de modelos de regressão linear, a análise da evolução temporal dos padrões de ocupação urbana e a elaboração de projeções populacionais.

Os resultados indicam uma forte e significativa correlação positiva entre a expansão da área urbanizada, detectada por SR, e o crescimento populacional nos municípios estudados. Estes achados respondem positivamente à pergunta de pesquisa "É possível utilizar imagens de satélites da área urbanizada para estimar a população entre censos em municípios de médio e pequeno porte?" apontando a aplicabilidade do SR como um indicador da dinâmica demográfica e territorial e o monitoramento do desenvolvimento urbano que ao longo do tempo apresentam convergência nos padrões de ocupação.

Contudo, apesar da alta correlação (r) e do poder explicativo dos modelos (R^2), as métricas de acurácia indicaram que os modelos de regressão linear, apresentam limitações para a geração de estimativas populacionais. O erro percentual absoluto médio sugere que a complexidade da dinâmica populacional dentro das áreas urbanas não é totalmente capturada quando se utiliza uma única variável preditora, necessitando de variáveis adicionais como a verticalização das cidades, sugerida em trabalhos futuros com outras amostras e em maiores números.

Esta pesquisa pretende contribuir com o monitoramento da expansão urbana e a inferência de tendências populacionais entre os censos demográficos para o planejamento territorial, a alocação de recursos e a formulação de políticas públicas mais eficientes e sustentáveis e reforçar a viabilidade do SR como ferramenta complementar aos métodos tradicionais de coleta de dados demográficos.

As limitações deste trabalho incluem a simplicidade do modelo de regressão linear que, embora identifique tendências, não garante precisão para estimativas populacionais em todas as situações, a relação entre área urbanizada e população pode não identificar a heterogeneidade da expansão populacional. Ainda, o estudo foi restrito a cinco municípios da Nova Alta Paulista que embora ofereçam suportes urbanos para análises, a generalização para outras regiões ou tipos de municípios deve ser feita com cautela, pois as dinâmicas de crescimento urbano podem variar. Recomenda-se estudar outras variáveis e modelos, como dados de iluminação noturna, consumo de energia, tipo de uso do solo (residencial, comercial, industrial), ou índices de verticalização, densidade, fatores socioeconômicos em modelos não lineares



e em diferentes regiões para testar a robustez e a adaptabilidade dos modelos construídos por meio de dados orbitais.

REFERÊNCIAS

AGUIAR, B. S.; BAPTISTA, G. M. M. Aplicação de aprendizado de máquina para análise do crescimento urbano: o caso das regiões administrativas Ceilândia e Pôr do Sol no Distrito Federal. **Revista Brasileira de Geomática**, v. 11, n. 2, p. 465-487, 2023.

BRASIL. Ministério do Desenvolvimento Social e Combate à Fome. **Projeções populacionais para o Brasil**. Brasília, DF: MDS, 2013. 45 p. Disponível em: https://acervodigital.mds.gov.br/xmlui/bitstream/handle/123456789/320/ETEC_23_2013%20Proje%C3%A7%C3%B5es%20populacionais%20para%20o%20Brasil.pdf?sequence=1. Acesso em: 18 out. 2025.

CALLEGARI-JACQUES, Sidia M. **Bioestatística: princípios e aplicações**. Artmed Editora, 2009.

CAMPOS, J.; RIGOTTI, J. I. R.; BAPTISTA, E. A.; MONTEIRO, A. M. V.; REIS, I. A. Population Estimates from Orbital Data of Medium Spatial Resolution: Applications for a Brazilian Municipality. **Sustainability**, v. 12, n. 9, p. 3565, 2020. DOI: 10.3390/su12093565.

CHANDER, G.; MARKHAM, B. L.; HELDER, D. L. Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. **Remote Sensing of Environment**, v. 113, n. 5, p. 893-903, 2009.

CONFEDERAÇÃO NACIONAL DE MUNICÍPIOS. **Transferências constitucionais**. Brasília, [S.d]. Disponível em: <https://cnm.org.br/>. Acesso em: 16 out. 2025.

EMBRAPA. **Satélites de Monitoramento**. Campinas, 2018. Disponível em: < <https://www.embrapa.br/satelites-de-monitoramento> >. Acesso em: 20 mai. 2025.

FÁVERO, L. P.; BELFIORE, P. **Manual de análise de dados: estatística e modelagem multivariada com Excel®, SPSS® e Stata®**. Elsevier Brasil, 2017.

FLORENZANO, T. G. **Imagens de satélite para estudos ambientais**. São Paulo: Oficina de Textos, 2002.

GIL, I. C. Territorialidade e desenvolvimento contemporâneo. **Revista Nera**, n. 4, p. 5-19, 2004.

GUIARRA, A. P. M.; YALLOUZ, G. A. N.; SILVA, I. T. Estudo bibliométrico sobre o uso de geotecnologias aplicadas ao planejamento de cidades médias. **Terr@ Plural**, v. 14, p. 1-14, 2019.

HUANG, X.; ZHU, D.; ZHANG, F.; LIU, T.; LI, X.; ZOU, L. **Sensing population distribution from satellite imagery via deep learning**: Model selection, neighboring effects, and systematic biases. *IEEE Journal of Selected Topics in Applied Earth*



Observations and Remote Sensing, v. 14, p. 5137–5151, 2021. DOI: 10.1109/JSTARS.2021.3076630.

IBGE. **A rede urbana brasileira**. Rio de Janeiro: IBGE, 2018. Disponível em: https://www.ibge.gov.br/apps/regic/pdf/03_rede_urbana.htm. Acesso em: 30 jan. 2026.

IBGE. **Censo 2022**. 2022. Disponível em: <https://censo2022.ibge.gov.br/panorama/>. Acesso em: 13 ago. 2025.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: uma perspectiva em Recursos Terrestres**. Tradução de JCN Epiphanyo. São José dos Campos, SP: Parênteses, 2009. 598 p.

LUO, N.; WAN, T.; HAO, H.; LU, Q. Fusing High-Spatial-Resolution Remotely Sensed Imagery and OpenStreetMap Data for Land Cover Classification Over Urban Areas. **Remote Sensing**, v. 11, n. 1, p. 88, 7 jan. 2019. DOI: 10.3390/rs11010088.

MAZROA, A.; MAASHI, M.; KOUKI, F.; OTHMAN, K. M.; SALIH, N.; ELFAKI, M. A.; BEGUM S, S. An analysis of urban sprawl growth and prediction using remote sensing and machine learning techniques. **Journal of South American Earth Sciences**, v. 142, p. 104988, 2024. ISSN 0895-9811. DOI: 10.1016/j.jsames.2024.104988.

MESQUITA, J. M. **Análise crítica do regime de distribuição do fundo de participação dos municípios: uma avaliação ex-post e ex-ante das propostas de inovação legislativa**. 2024. 78 f. Dissertação (Mestrado em Administração Pública) – Instituto Brasileiro de Ensino, Desenvolvimento e Pesquisa, Brasília, 2024. Disponível em: <https://repositorio.idp.edu.br/handle/123456789/5487>. Acesso em: 30 jan. 2026.

MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: A review. **ISPRS journal of photogrammetry and remote sensing**, v. 66, n. 3, p. 247-259, 2011.

NOVO, E. M. L. **Sensoriamento Remoto: princípios e aplicações**. Editora Blucher, 2010.

ONU - Organização das Nações Unidas (Brasil). **Objetivos de Desenvolvimento Sustentável no Brasil**. [s.l.], [s.d.]. Disponível em: <https://brasil.un.org/pt-br/sdgs>. Acesso em: 17 out. 2025.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação**. São José dos Campos: Parêntese, 2010, 127p.

RAMOS, E. F. **As cidades médias em perspectiva: uma análise dos papéis e tendências de um grupo de cidades médias brasileiras**. 2011. Dissertação (Mestrado em Geografia) – Universidade Federal de Minas Gerais, Belo Horizonte, 2011.

RICHARDSON, A. J.; WIEGAND, C. L. Distinguishing vegetation from soil background information. **Photogrammetric engineering and remote sensing**, v. 43, n. 12, p. 1541-1552, 1977.



ROSA, M. R. Classificação do padrão de ocupação urbana de São Paulo utilizando aprendizagem de máquina e Sentinel 2. **Revista do Departamento de Geografia**, p. 15-21, 2018.

RUIZ, P. R. S. **Classificação da cobertura do solo urbano usando árvores de decisão a partir de cenas WorldView-2 e WorldView-3 para diferentes níveis de legenda**. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2017, 181 p.

SABERIFAR, R. Estimation of urban population by remote sensing data. **J Emerg Trends Econ Manag Sci**, v. 4, n. 6, p. 565, 2013.

SANTOS, M. **Espaço e sociedade: ensaios**. 2. ed. Petrópolis: Vozes, 1982.

XU, H.; REN, M.; LIN, M. Cross-comparison of Landsat-8 and Landsat-9 data: A threelevel approach based on underfly images. **GIScience & Remote Sensing**, v. 61, n. 1, p. 2318071, 2024.

VAPNIK, V. **The nature of statistical learning theory**. Springer Science & Business Media, 1999.

