



**ANA ISABELLA GUIMARÃES FERREIRA**

**MODELAGEM DA DENSIDADE DE ÁRVORES UTILIZANDO  
MEDIDAS TEXTURAIS: UM ESTUDO COMPARATIVO ENTRE  
IMAGENS LANDSAT 8 E SENTINEL-2.**

**LAVRAS - MG**

**2021**

**ANA ISABELLA GUIMARÃES FERREIRA**

**MODELAGEM DA DENSIDADE DE ÁRVORES UTILIZANDO MEDIDAS  
TEXTURAIS: UM ESTUDO COMPARATIVO ENTRE IMAGENS LANDSAT 8 E  
SENTINEL-2.**

Monografia apresentada à Universidade Federal de Lavras, como parte das exigências do Curso de Engenharia Florestal, para a obtenção do título de Bacharel.

Prof. Fausto Weimar Acerbi Júnior

Orientador

Iago Mendes de Oliveira

Coorientador

**LAVRAS – MG**

**2021**

**ANA ISABELLA GUIMARÃES FERREIRA**

**MODELAGEM DA DENSIDADE DE ÁRVORES UTILIZANDO MEDIDAS  
TEXTURAIS: UM ESTUDO COMPARATIVO ENTRE IMAGENS LANDSAT 8 E  
SENTINEL-2.**

**MODELING TREE DENSITY USING TEXTURE MEASURES: A COMPARATIVE  
STUDY BETWEEN LANDSAT 8 AND SENTINEL-2 IMAGES.**

Monografia apresentada à Universidade Federal de Lavras, como parte das exigências do Curso de Engenharia Florestal, para a obtenção do título de Bacharel.

APROVADA em 18 de março de 2021.

Dr. Fausto Weimar Acerbi Junior – UFLA

Me. Inácio Thomas Bueno – UFLA

Dr. Aliny Aparecida dos Reis – FEAGRI

Prof. Fausto Weimar Acerbi Junior

Orientador

Iago Mendes de Oliveira

Coorientador

**LAVRAS – MG**

**2021**

## AGRADECIMENTOS

À vida.

À minha mãe Roseli e ao meu pai Marco Aurélio (*in memoriam*). Agradeço por todo apoio, paciência e motivação, vocês foram excepcionais para realização desta conquista.

Ao meu filho Bento, minha maior motivação e alegria.

À minha família e amigos, que sempre estiveram presentes compartilhando os melhores e piores momentos dessa jornada.

Ao Prof. Fausto e ao Iago, por acreditarem em mim, pela orientação e todo apoio.

À UFLA, por todo acolhimento, oportunidades e amizades feitas.

E a todas as pessoas que fizeram parte dessa caminhada. Sou grata!

## RESUMO

As medidas de texturas como variáveis preditoras, têm sido empregadas com sucesso em estudos de modelagem, na obtenção de estimativas rápidas e confiáveis da biomassa e da diversidade de árvores. Entretanto, a exploração da textura das imagens é amplamente usada em imagens cuja resolução espacial é alta (1-3m). Dessa forma, este estudo testou a capacidade de imagens de média resolução espacial (10m e 30m) de estimar a densidade de árvores (DI) em fragmentos florestais. Para isso, optou-se pela modelagem da DI pela regressão linear múltipla *stepwise*, usando como dados de entrada medidas texturais extraídas do Índice de Vegetação Melhorado (Enhanced Vegetation Index, EVI) de imagens Landsat 8 e Sentinel-2. Os resultados mostraram que existe correlação significativa entre a DI e as medidas de textura. Além disso, observou-se que os maiores erros foram observados em fragmentos com DI superior a 2000 n/ha. Os modelos tiveram  $R^2_{aj}$  de 0,20 para Landsat 8 e 0,15 para Sentinel-2. Dessa forma, é importante ressaltar que os dados obtidos neste trabalho não representam a potencialidade das medidas de textura na modelagem, já que o método de regressão linear múltipla não é suficiente para deduzir se existe alguma relação entre as variáveis com melhor capacidade preditiva.

**Palavras-chave:** Sensoriamento Remoto. *Grey Level Co-occurrence Matrix*. Modelagem.

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>6</b>
<b>2</b>	<b>REFERENCIAL TEÓRICO .....</b>	<b>7</b>
2.1	<b>Medidas de textura .....</b>	<b>7</b>
2.2	<b>Enhanced Vegetation Index (EVI) .....</b>	<b>7</b>
<b>3</b>	<b>MATERIAIS E MÉTODOS.....</b>	<b>9</b>
3.1	<b>Inventário florestal .....</b>	<b>9</b>
3.2	<b>Seleção e processamento das imagens .....</b>	<b>10</b>
3.3	<b>Extração das medidas texturais .....</b>	<b>11</b>
3.4	<b>Métodos estatísticos: correlação e modelagem.....</b>	<b>11</b>
<b>4</b>	<b>RESULTADOS.....</b>	<b>13</b>
4.1	<b>Análise da correlação.....</b>	<b>13</b>
4.2	<b>Predição da densidade de indivíduos .....</b>	<b>16</b>
<b>5</b>	<b>DISCUSSÃO .....</b>	<b>18</b>
<b>6</b>	<b>CONCLUSÃO .....</b>	<b>19</b>
	<b>REFERÊNCIAS .....</b>	<b>20</b>

## 1 INTRODUÇÃO

O uso de sensoriamento remoto para a aquisição de informações relevantes que contribuem com predições relacionadas à vegetação é possível pois, as imagens de SR fornecem uma visão da superfície da Terra de tal forma que permite que os recursos nela sejam identificados, localizados e caracterizados (LECHNER, FOODY E BOYD, 2020).

Os métodos de processamento e sistemas de sensoriamento remoto estão evoluindo rapidamente com o avanço da tecnologia computacional e com a disponibilização gratuita de dados de satélites em diversas plataformas, como no Google Earth Engine (GEE). Dentro da ecologia e manejo florestal, existe uma diversificada gama de aplicações de SR, incluindo mensuração florestal, estrutura da vegetação, química e umidade da vegetação, biodiversidade e características do solo (LECHNER, FOODY E BOYD, 2020).

Ao longo dos anos, diversas técnicas foram elaboradas para a obtenção de dados que aproximam a verdade de campo ao que é obtido com dados de SR. Uma dessas técnicas foi desenvolvida por Haralick, Shanmugam e Dinstein (1973): o método da matriz de coocorrência de níveis de cinza (GLCM, do inglês *Grey Level Co-occurrence Matrix*). As aplicações deste método variam desde o uso na classificação de imagens digitais (e.g. FRANKLIN, MAUDIE E LAVLGNE, 2001) até a modelagem de parâmetros estruturais da floresta (KAYITAKIRE, HAMEL E DEFOURNY, 2006; OZDEMIR E KARNIELI, 2011).

Entretanto, a exploração da textura das imagens é amplamente usada em imagens cuja resolução espacial é alta (1 a 3 metros). Os objetivos deste estudo foram: (i) testar e comparar a capacidade de imagens de média resolução Landsat OLI (*Operational Land Imager*) e Sentinel-2 na estimativa da densidade de indivíduos por hectare (n/ha) em fragmentos florestais no sul de MG, utilizando especificamente, medidas de textura derivadas de índices de vegetação; (ii) verificar a correlação entre DI e as medidas de textura; e (iii) modelar DI com base nas medidas de textura.

## 2 REFERENCIAL TEÓRICO

### 2.1 Medidas de textura

A textura quantifica as variações espectrais e espaciais nos valores dos pixels de uma imagem e, portanto, transmite informações sobre a heterogeneidade espectral e espacial das características dessa imagem (HARALICK, SHANMUGAM E DINSTEIN, 1973). Muitos estudos apresentam diferentes abordagens (semivariogramas, dimensão fractal, *wavelet* e outras) para caracterização da textura das imagens de sensoriamento remoto, porém as mais utilizadas são derivadas da GLCM (HALL-BEYER, 2017).

As medidas de textura são classificadas como de primeira ordem ou de segunda ordem. As medidas de primeira ordem são estatísticas descritivas calculadas a partir dos pixels da imagem original. Já as medidas de segunda ordem consideram a relação entre grupos de dois pixels na imagem original.

Segundo Hall-Beyer (2017), a GLCM é uma matriz que contém as frequências de ocorrência de diferentes combinações de níveis de cinza em uma imagem. A normalização desta matriz, permite o cálculo das medidas de textura de segunda ordem propostas por Haralick, Shanmugam e Dinstein (1973) como contraste, entropia, correlação, dentre outros.

Resultados de pesquisas anteriores apontam que texturas de imagens de satélite têm a capacidade de capturar diferentes aspectos da diversidade estrutural da vegetação (MENG et al., 2016; WOOD et al., 2012). Como variáveis preditoras, têm sido empregadas com sucesso em estudos de modelagem, para obtenção de estimativas rápidas e confiáveis da diversidade de árvores (AKBARI E KALBI, 2017). Além disso, também possuem maior valor de importância e elevada capacidade de aumentar a performance preditiva de modelos de predição da biomassa, em relação a utilização apenas de variáveis derivadas diretamente de respostas espectrais (DUBE E MUTANGA, 2015).

### 2.2 Enhanced Vegetation Index (EVI)

Os índices de vegetação são, provavelmente, a maneira mais simples e eficiente de se realçar o sinal refletido pelas áreas vegetadas ao mesmo tempo que minimizam as variações na irradiância solar e os efeitos do substrato do dossel vegetal (JACKSON E HUETE, 1991). As



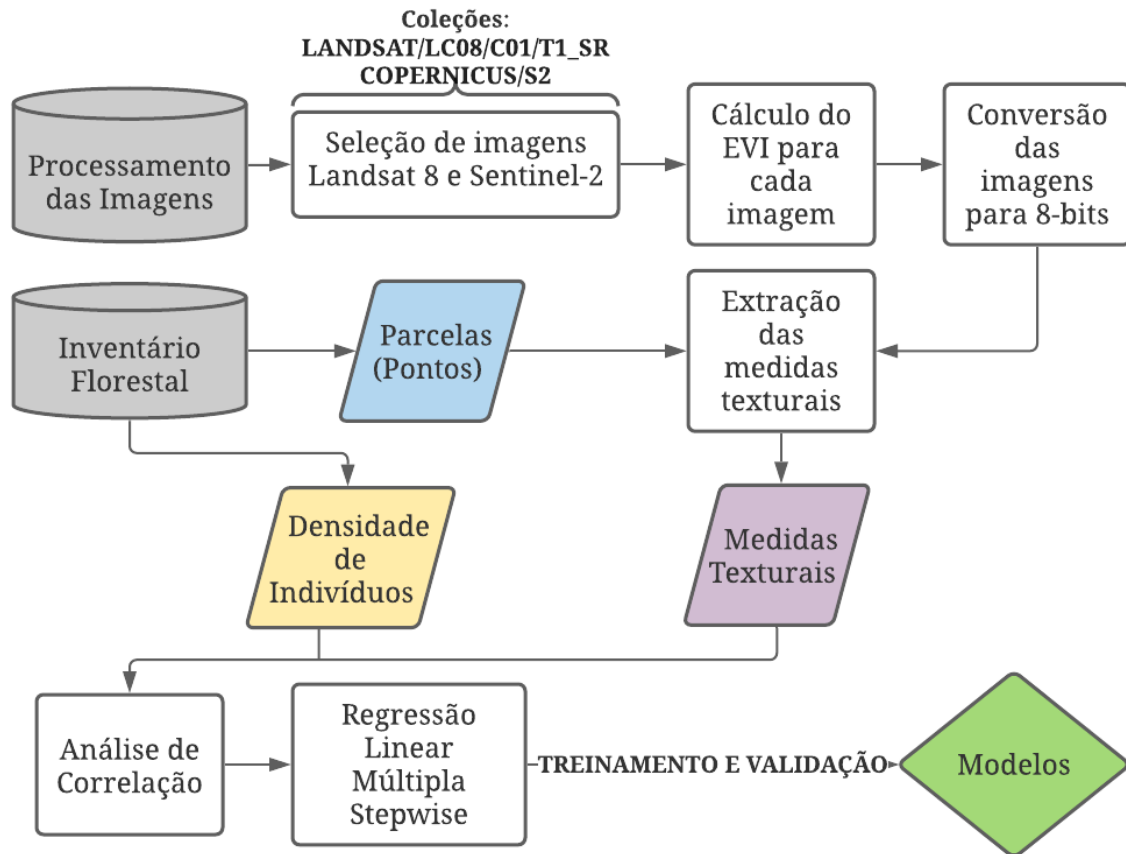
transformações espectrais envolvendo as bandas do infravermelho próximo e vermelho, como no índice de vegetação da diferença normalizada, são as mais usadas para análise da vegetação.

O índice de vegetação melhorado, ou EVI (*Enhanced Vegetation Index*), foi proposto por Huete *et al.* (2002) para amenizar as influências atmosféricas e do solo, utilizando a banda do azul para correção das influências do aerossol na banda do vermelho. Comparado ao índice de vegetação da diferença normalizada, o EVI é menos sensível às contaminações do solo e da atmosfera (LIU E HUETE, 1995; MIURA *et al.*, 1998, 2001) e responde melhor às variações fisionômicas e estruturais no dossel (GAO *et al.*, 2000).

### 3 MATERIAIS E MÉTODOS

Os processos realizados neste estudo estão representados no fluxograma da Figura 1.

Figura 1 – Fluxograma da metodologia.



Fonte: Do autor (2021)

#### 3.1 Inventário florestal

A base de dados de mensuração florestal foi oriunda do projeto “*Modelo Fitogeográfico da Bacia do Rio Grande*”<sup>1</sup>, em que foram inventariados fragmentos florestais na Bacia Hidrográfica do Rio Grande entre os anos de 2013 e 2015. O inventário florestal foi realizado pelo método de amostragem sistemático por conglomerados, onde cada unidade era composta por um conjunto de três parcelas de 250 m<sup>2</sup>. Foram mensuradas, dentro de cada parcela, todas

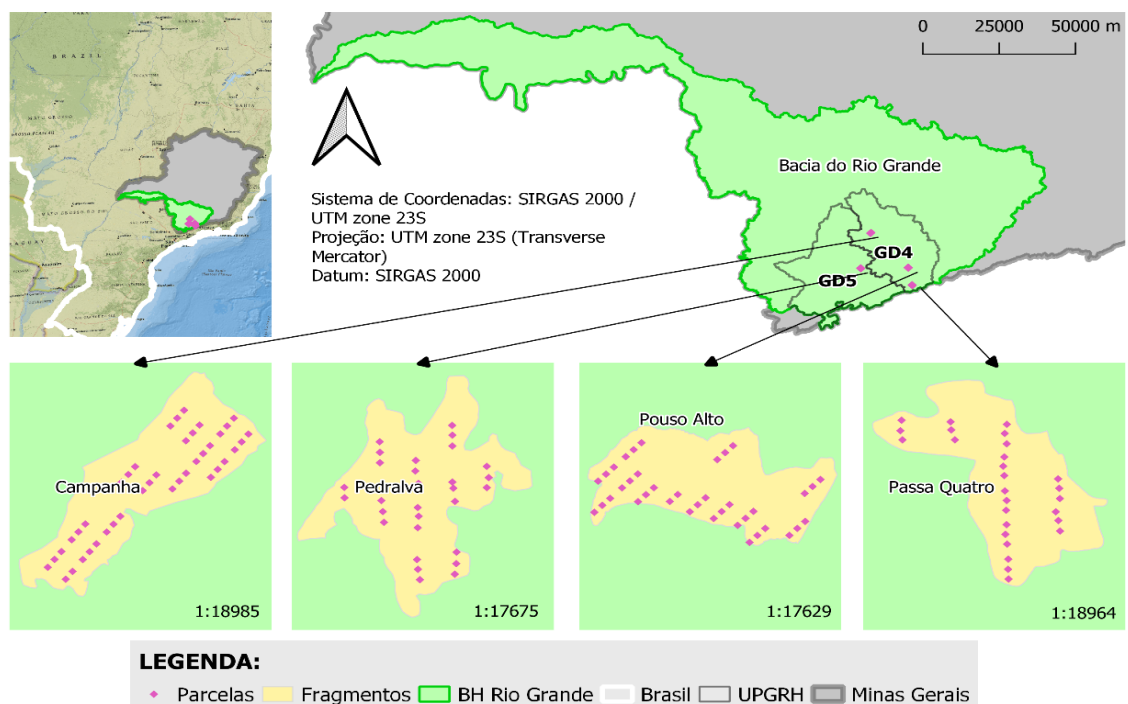
<sup>1</sup> O projeto é uma parceria entre a Universidade Federal de Lavras (UFLA) e a Companhia Energética de Minas Gerais (CEMIG).

as árvores com circunferência medida a 1,30 m de altura do solo igual ou superior a 15,7 cm, obtendo-se assim o número de indivíduos por parcela.

Os fragmentos florestais selecionados para este estudo estão localizados nas cidades de Campanha, Pouso Alto, Passa Quatro e Pedralva, no estado de Minas Gerais, totalizando 136 parcelas (Figura 2). Essas áreas situam-se na parte central da Bacia Hidrográfica do Rio Grande, inseridas nas Unidades de Planejamento de Gestão e Recursos Hídricos (UPGRH) GD4 e GD5 (Figura 2).

O clima predominante nessa área, segundo a classificação climática de Köppen (ALVARES *et al.*, 2013) é o Cwb - clima temperado úmido com inverno seco e verão temperado, característico de locais com altitude elevada e temperaturas amenas. A área de estudo está inserida no bioma Mata Atlântica, sendo a Floresta Estacional Semidecidual a fitofisionomia predominante.

Figura 2 – Mapa de localização dos fragmentos florestais e distribuição das parcelas.



Fonte: Do autor (2021)

### 3.2 Seleção e processamento das imagens

Para fins de comparação, selecionamos uma imagem Landsat OLI (30 m) e uma imagem Sentinel-2 (10 m), de acordo com os seguintes critérios:

1. Imagens com cobertura de nuvens abaixo de 10%;
2. Menor diferença possível entre a data de aquisição das imagens.

A filtragem e a seleção das imagens foram realizadas na plataforma Google Earth Engine (GEE). Posteriormente, foi calculado o EVI utilizando as bandas do infravermelho próximo, vermelho e azul para cada imagem selecionada e excluimos os pixels com valores negativos, que geralmente indicam ausência de vegetação (rocha, solo exposto). Depois, multiplicamos o valor dos pixels por 100 e redimensionamos linearmente as imagens para 8-bit utilizando a função *uint8()* no GEE.

### 3.3 Extração das medidas texturais

A partir dos índices EVI, utilizou-se a função *glcmTexture()* no GEE com tamanho de janela de 3x3 pixels para extração de todas as medidas de textura de segunda ordem desenvolvidas por Haralick, Shanmugam e Dinstein (1973). São elas: *Angular Second Moment* (ASM), *Contrast* (CON), *Correlation* (CORR), *Variance* (VAR), *Inverse Difference Moment* (IDM), *Sum Average* (SAVG), *Sum Variance* (SVAR), *Sum Entropy* (SENT), *Entropy* (ENT), *Difference Variance* (DVAR), *Difference Entropy* (DENT), *Information Measures of Correlation 1* (IMCORR1) e *Information Measures of Correlation 2* (IMCORR2).

Além das métricas de segunda ordem, foi calculado também a média do valor dos pixels dentro da janela, que consiste em uma medida de primeira ordem. Os valores das medidas de texturas foram obtidos para cada parcela de cada um dos fragmentos. Para isso, foi utilizado um raio de 30 metros a partir do ponto central da parcela para a imagem Landsat OLI e um raio de 10 metros para a Sentinel-2.

### 3.4 Métodos estatísticos: correlação e modelagem

O coeficiente de correlação de Pearson ( $\rho$ ) foi utilizado na análise da correlação linear entre o parâmetro DI e as medidas de textura derivadas das imagens. Utilizamos o valor p com um nível de significância de 0,05 para verificar quando a correlação entre as variáveis foi significativa. Em seguida, a densidade de indivíduos foi modelada em função das medidas de texturas derivadas das imagens de satélite que apresentaram correlação significativa.

A regressão linear múltipla é um método comumente utilizado para modelar uma variável resposta em função de múltiplas variáveis preditoras (MURTAUGH, 2009). Sendo assim, no software R, ajustamos vários modelos, utilizando o método *stepwise* de seleção de variáveis, para avaliar a contribuição de cada medida de textura na predição da DI.

O conjunto de dados ( $n = 136$ ) foi dividido em dados de treinamento (75%,  $n = 103$ ) e dados de validação (25%,  $n = 33$ ). As análises se basearam na avaliação gráfica dos resíduos e a partir das métricas de desempenho de  $R^2_{\text{ajustado}}$  e RMSE.

## 4 RESULTADOS

### 4.1 Análise da correlação

A partir da estatística descritiva dos dados advindos do inventário florestal, obtemos que o valor mínimo de DI para as parcelas foi de 320 n/ha e máximo de 5.520 n/ha, com uma média de 1.732,94 n/ha e desvio padrão de 803,50 n/ha.

Com base na análise de correlação de Pearson (Tabela 1), foram encontradas correlações estatisticamente significativas entre a DI e as medidas texturais. Para ambas as imagens de satélite, as medidas texturais IDM, ENT, DENT, IMCORR1 e IMCORR2 (Figura 3) foram significativamente correlacionadas com a DI ( $p < 0,05$ ). Ainda, a medida ASM derivada da imagem Sentinel-2 também teve correlação significativa com a DI ( $p < 0,05$ ). A medida de primeira ordem derivada de ambas as imagens não apresentou correlação significativa com a DI.

Tabela 1 – Coeficiente de correlação de Pearson entre o parâmetro densidade de indivíduos e as medidas de textura das imagens Landsat 8 e Sentinel-2. (continua)

MEDIDAS TEXTURAIS	CORRELAÇÃO DE PEARSON	
	Landsat 8	Sentinel-2
ASM	0,284	0,325*
CON	-0,263	-0,172
CORR	0,057	0,046
VAR	-0,255	-0,158
IDM	0,402*	0,377*
SAVG	0,070	0,060
SVAR	-0,244	-0,145
SENT	-0,161	-0,250

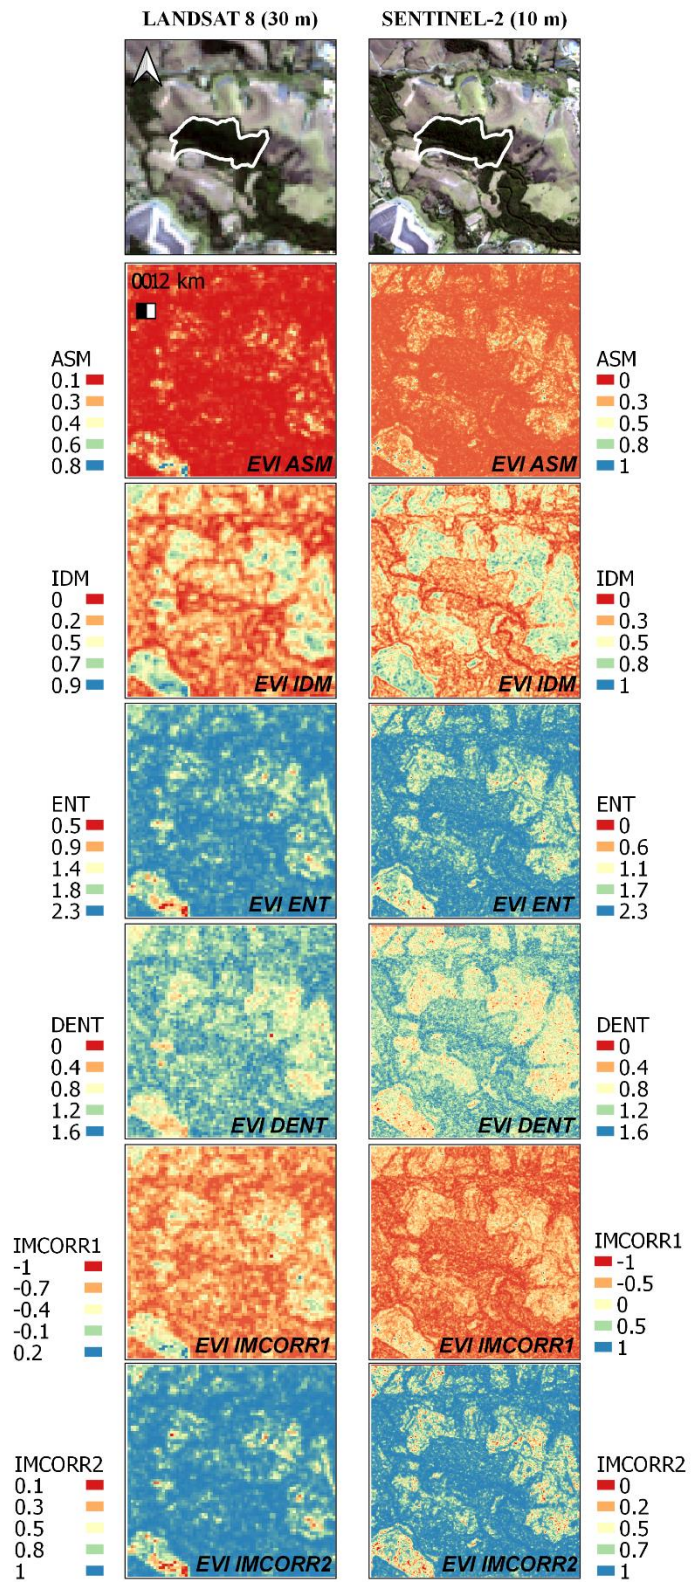
\*A correlação foi significativa ao nível de 0,05.

Tabela 1 – Coeficiente de correlação de Pearson entre o parâmetro densidade de indivíduos e as medidas de textura das imagens Landsat 8 e Sentinel-2. (conclusão)

MEDIDAS TEXTURAIS	CORRELAÇÃO DE PEARSON	
	Landsat 8	Sentinel-2
ENT	0,300*	-0,347*
DVAR	-0,263	-0,210
DENT	-0,356*	-0,374*
IMCORR1	0,357*	0,353*
IMCORR2	-0,377*	-0,357*
MEAN	0,075	0,062

Fonte: Do autor (2021)

Figura 3 – Medidas texturais extraídas do EVI.



Fonte: Do autor (2021)



## 4.2 Predição da densidade de indivíduos

A aplicação da regressão linear múltipla *stepwise* resultou nos modelos de regressão apresentados na Tabela 2.

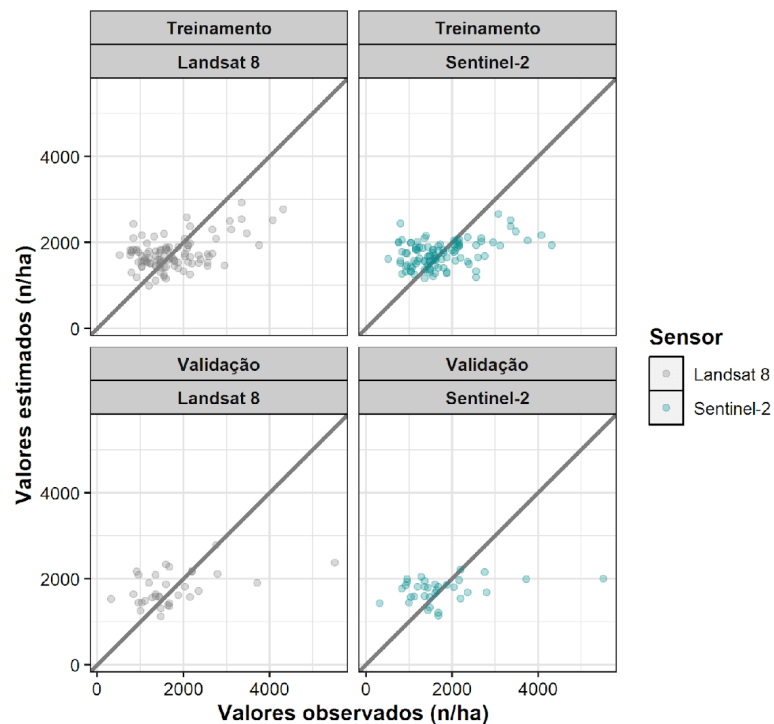
Tabela 2 – Modelos de regressão ajustados.

Imagem	Modelo ajustado	R <sup>2</sup> aj	RMSE	P
Landsat OLI	DI = 4641 + 3438 x SENT – 3002 x DENT – 4364 x IMCORR2	0,20	829	0,011
Sentinel- 2	DI = 932,8 + 3084 x IDM	0,15	888	0,016

Fonte: Do autor (2021)

Os coeficientes de determinação ajustados (R<sup>2</sup>) para treinamento foram de 0,20 e 0,15, para a Landsat OLI e Sentinel-2, respectivamente. Os gráficos representados na Figura 4 mostram a distribuição linear das amostras de treinamento e de validação.

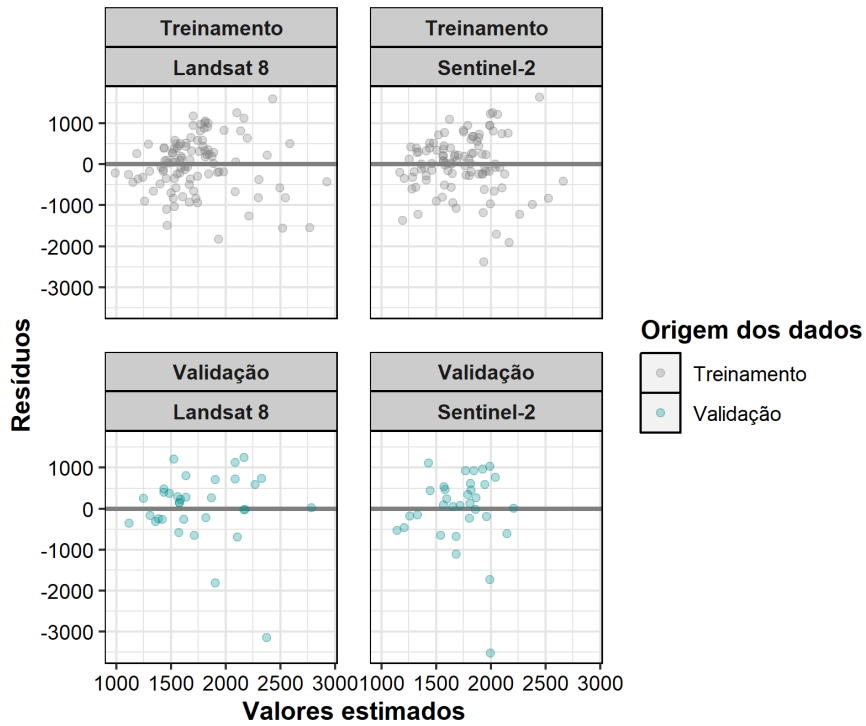
Figura 4 – Distribuição das amostras de treinamento e validação.



Fonte: Do autor (2021)

A partir da inspeção visual do gráfico de resíduos (Figura 5), observa-se que a distribuição dos erros apresentou comportamento semelhante para ambas as imagens (Landsat OLI e Sentinel-2). Os maiores erros foram observados em fragmentos com DI superior a 2000 n/ha.

Figura 5 – Distribuição dos resíduos.



Fonte: Do autor (2021)

## 5 DISCUSSÃO

Conforme os resultados apresentados, o erro foi diretamente proporcional ao aumento da densidade de árvores na área. Ou seja, à medida que a imagem foi ficando mais homogênea devido a quantidade de árvores, o modelo foi perdendo sua capacidade preditiva. Neste estudo, o tamanho de janela escolhido foi o de 3x3 pois tem a vantagem de capturar heterogeneidade de valores de pixel em pequenas extensões (WOOD et al., 2012). Porém, como não foram testados outros tamanhos de janela, não é possível afirmar que a janela 3x3 não conseguiu capturar a heterogeneidade dos fragmentos estudados.

Com relação ao efeito da resolução espacial das imagens nas estimativas, os resultados surpreendem ao indicarem que as métricas de desempenho do modelo criado a partir de dados Sentinel-2 foram inferiores às aquelas apresentadas pelos modelos criados a partir de dados Landsat OLI.

Outros trabalhos como o de Kayitakire et al. (2006) encontraram resultados superiores a este estudo. Os autores modelaram parâmetros estruturais, incluindo área basal, altura superior, circunferência, densidade de povoamento e idade em uma floresta na Bélgica usando medidas de textura derivadas de imagens IKONOS-2 com resolução espacial de 1 metro. Os valores de  $R^2$  dos melhores modelos variaram de 0,35 a 0,82 para essas variáveis. Já Ozdemir e Karnieli (2011), encontraram valores de  $R^2$  próximos aos encontrados neste estudo ( $R^2 = 0,38$ ) utilizando medidas texturais derivadas de imagens WorldView 2 (2 m) na modelagem do número de indivíduos em uma floresta plantada de *Pinus ssp.*

A regressão linear múltipla é uma forma simples para predição de parâmetros, avaliando apenas a relação linear entre as variáveis. Além disso, a quantidade de amostras para treinamentos dos modelos foi relativamente baixa (136 parcelas).

Diversos autores utilizam métodos preditivos mais robustos, como *Random Forest*, para a modelagem de atributos florestais com uso de índices espectrais e texturais (DOS REIS et al, 2019; DANG et al, 2019; LÓPEZ-SERRANO et al, 2019). Dessa forma, as relações entre os parâmetros e as medidas de textura são melhores explorados, resultando em modelos com maiores capacidades preditivas.

## 6 CONCLUSÃO

O objetivo principal deste estudo foi averiguar a capacidade de imagens de média resolução espacial de estimar a densidade de indivíduos por hectare utilizando medidas de texturas combinadas ao índice espectral. Dessa forma, apesar dos  $R^2_{\text{ajustado}}$  terem apresentado valores relativamente baixos, este estudo mostrou que existe correlação significativa entre as medidas texturais e a densidade de árvores por hectare.

A modelagem ficou comprometida pelo uso de um método preditivo simples, entretanto, é importante ressaltar que os dados obtidos neste trabalho não representam a potencialidade das medidas de textura na modelagem, já que o método de regressão linear múltipla não é suficiente para deduzir se existe alguma relação entre as variáveis com melhor capacidade preditiva.

## REFERÊNCIAS

- AKBARI, H.; KALBI, S. **Determining Pleiades satellite data capability for tree diversity modeling.** *IForest*, v. 10, n. 1, p. 348–352, 1 Feb. 2017.
- ALVARES, C. A. *et al.* **Köppen's climate classification map for Brazil.** *Meteorologische Zeitschrift*, v. 22, n. 6, p. 711–728, 2013.
- DANG, A. T. N. *et al.* **Forest aboveground biomass estimation using machine learning regression algorithm in Yok Don National Park, Vietnam.** *Ecological Informatics*, v. 50, p. 24–32, 1 mar. 2019.
- DOS REIS, A. *et al.* **Volume estimation in a Eucalyptus plantation using multi-source remote sensing and digital terrain data: a case study in Minas Gerais State, Brazil.** *International Journal of Remote Sensing*, v. 40, n. 7, p. 2683-2702, 2019.
- DUBE, T.; MUTANGA, O. **Investigating the robustness of the new Landsat-8 Operational Land Imager derived texture metrics in estimating plantation forest aboveground biomass in resource constrained areas.** *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 208, n. 2015, p. 12–32, 2015.
- FRANKLIN, S. E.; MAUDIE, A. J.; LAVLGNE, M. B. **Using spatial co-occurrence texture to increase forest structure and species composition classification accuracy.** *Photogrammetric Engineering and Remote Sensing*, v. 67, n. 7, p. 849–855, 2001.
- GAO, X. *et al.* **Optical-biophysical relationships of vegetation spectra without background contamination.** *Remote Sensing of Environment*, v. 74, n. 3, p. 609–620, 2000.
- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. **Textural Features for Image Classification.** *IEEE Transactions on Systems, Man, and Cybernetics*, v. SMC-3, n. 6, p. 610–621, nov. 1973.
- HUETE, A. *et al.* **Overview of the radiometric and biophysical performance of the MODIS vegetation indices.** *Remote Sensing of Environment*, v. 83, n. 1–2, p. 195–213, 2002.
- JACKSON, R. D.; HUETE, A. R. **Interpreting vegetation indices.** *Preventive Veterinary Medicine*, v. 11, n. 3–4, p. 185–200, 1991.
- KAYITAKIRE, F.; HAMEL, C.; DEFOURNY, P. **Retrieving forest structure variables**

**based on image texture analysis and IKONOS-2 imagery.** Remote Sensing of Environment, v. 102, n. 3–4, p. 390–401, 2006.

LECHNER, A. M.; FOODY, G. M.; BOYD, D. S. **Applications in Remote Sensing to Forest Ecology and Management.** One Earth, v. 2, n. 5, p. 405–412, 2020.

LIU, H. Q.; HUETE, A. **Feedback based modification of the NDVI to minimize canopy background and atmospheric noise.** IEEE Transactions on Geoscience and Remote Sensing, v. 33, n. 2, p. 457–465, 1995.

LÓPEZ-SERRANO, P. M. et al. **Modeling of Aboveground Biomass with Landsat 8 OLI and Machine Learning in Temperate Forests.** Forests, v. 11, n. 1, p. 11, 19 dez. 2019.

MENG, J. et al. **Estimation of forest structural diversity using the spectral and textural information derived from SPOT-5 satellite images.** Remote Sensing, v. 8, n. 2, 2016.

MIURA, T. *et al.* **An error and sensitivity analysis of atmospheric resistant vegetation indices derived from dark target-based atmospheric correction.** Remote Sensing of Environment, v. 78, n. 3, p. 284–298, 2001.

MIURA, T. *et al.* **Vegetation detection through smoke-filled AVIRIS images: An assessment using MODIS band passes.** Journal of Geophysical Research Atmospheres, v. 103, n. D24, p. 32001–32011, 1998.

HALL-BEYER, M. **GlcM Texture: a Tutorial.** 17th International Symposium on Ballistics, v. 2, n. March, p. 18–19, 2017.

MURTAUGH, P. A. **Performance of several variable-selection methods applied to real ecological data.** Ecology Letters, v. 12, n. 10, p. 1061–1068, 2009.

OZDEMIR, I.; KARNIELI, A. **Predicting forest structural parameters using the image texture derived from worldview-2 multispectral imagery in a dryland forest, Israel.** International Journal of Applied Earth Observation and Geoinformation, v. 13, n. 5, p. 701–710, 2011.

WOOD, E. M. et al. **Image texture as a remotely sensed measure of vegetation structure.** Remote Sensing of Environment, v. 121, n. 2012, p. 516–526, 2012.