



MINISTÉRIO DA  
CIÊNCIA, TECNOLOGIA  
E INOVAÇÕES



sid.inpe.br/mtc-m21d/2021/08.31.21.18-TDI

**CONTRIBUIÇÃO DE MÉTRICAS DE TEXTURA EM  
CLASSIFICAÇÃO PIXEL-A-PIXEL PARA  
IDENTIFICAR ÁREAS CONSTRUÍDAS DE CIDADES  
AMAZÔNICAS**

Gabriel Crivellaro Gonçalves

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Sensoriamento Remoto, orientada  
pelas Dras. Silvana Amaral  
Kampel, e Ana Paula Dal'Asta,  
aprovada em 18 de agosto de 2021.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/45C2C52>>

INPE  
São José dos Campos  
2021

**PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE  
Coordenação de Ensino, Pesquisa e Extensão (COEPE)  
Divisão de Biblioteca (DIBIB)  
CEP 12.227-010  
São José dos Campos - SP - Brasil  
Tel.:(012) 3208-6923/7348  
E-mail: pubtc@inpe.br

**CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):**

**Presidente:**

Dra. Marley Cavalcante de Lima Moscati - Coordenação-Geral de Ciências da Terra (CGCT)

**Membros:**

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação (CPG)  
Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia, Tecnologia e Ciência Espaciais (CGCE)  
Dr. Rafael Duarte Coelho dos Santos - Coordenação-Geral de Infraestrutura e Pesquisas Aplicadas (CGIP)  
Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)

**BIBLIOTECA DIGITAL:**

Dr. Gerald Jean Francis Banon  
Clayton Martins Pereira - Divisão de Biblioteca (DIBIB)

**REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)  
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)

**EDITORAÇÃO ELETRÔNICA:**

Ivone Martins - Divisão de Biblioteca (DIBIB)  
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)



MINISTÉRIO DA  
CIÊNCIA, TECNOLOGIA  
E INOVAÇÕES



sid.inpe.br/mtc-m21d/2021/08.31.21.18-TDI

**CONTRIBUIÇÃO DE MÉTRICAS DE TEXTURA EM  
CLASSIFICAÇÃO PIXEL-A-PIXEL PARA  
IDENTIFICAR ÁREAS CONSTRUÍDAS DE CIDADES  
AMAZÔNICAS**

Gabriel Crivellaro Gonçalves

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Sensoriamento Remoto, orientada  
pelas Dras. Silvana Amaral  
Kampel, e Ana Paula Dal'Asta,  
aprovada em 18 de agosto de 2021.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/45C2C52>>

INPE  
São José dos Campos  
2021

Dados Internacionais de Catalogação na Publicação (CIP)

---

Gonçalves, Gabriel Crivellaro.

G586c Contribuição de métricas de textura em classificação pixel-a-pixel para identificar áreas construídas de cidades amazônicas / Gabriel Crivellaro Gonçalves. – São José dos Campos : INPE, 2021.

xx + 106 p. ; (sid.inpe.br/mtc-m21d/2021/08.31.21.18-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2021.

Orientadoras : Dras. Silvana Amaral Kampel e Dra. Ana Paula Dal'Asta.

1. Classificação. 2. Machine learning. 3. Área construída.  
4. Amazônia. I.Título.

CDU 528.87

---



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).



MINISTÉRIO DA  
CIÊNCIA, TECNOLOGIA  
E INOVAÇÕES



**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**  
Serviço de Pós-Graduação - SEPGR

**DEFESA FINAL DE DISSERTAÇÃO DE GABRIEL CRIVELLARO GONÇALVES**  
**BANCA Nº 208/2021, REG 141909/2019**

No dia 18 de agosto de 2021, às 14h00min, por teleconferência, o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Mestre em Sensoriamento Remoto. O trabalho precisa da incorporação das correções sugeridas pela Banca Examinadora e revisão final pelo(s) orientador(es).

**Título: “CONTRIBUIÇÃO DE MÉTRICAS DE TEXTURA EM CLASSIFICAÇÃO PIXEL-A-PIXEL PARA IDENTIFICAR ÁREAS CONSTRUÍDAS DE CIDADES AMAZÔNICAS”**

**Membros da banca:**

Dra. Maria Isabel Sobral Escada - Presidente - INPE  
Dra. Silvana Amaral Kampel - Orientadora - INPE  
Dra. Ana Paula Dal'Asta - Orientadora - INPE  
Dr. Thales Sehn Körting - Membro Interno - INPE  
Dra. Mariana Abrantes Giannotti - Membro Externo - USP



Documento assinado eletronicamente por **Thales Sehn Korting, Pesquisador**, em 24/08/2021, às 08:15 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Silvana Amaral Kampel, Pesquisadora**, em 24/08/2021, às 08:54 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Ana Paula dal'asta (E), Usuário Externo**, em 25/08/2021, às 12:25 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **mariana abrant es giannotti (E), Usuário Externo**, em 25/08/2021, às 14:34 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Maria Isabel Sobral Escada, Tecnologista**, em 25/08/2021, às 18:10 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

A autenticidade deste documento pode ser conferida no site <http://sei.mctic.gov.br/verifica.html>, informando o código verificador **7976556** e o código CRC **D0EA83FA**.



---

**Referência:** Processo nº 01340.005222/2021-63

SEI nº 7976556

*"Avaliar é criar, sem avaliação a noz da existência seria oca"*

*Assim Falou Zaratustra, Friedrich Nietzsche*



*À minha família, pai Leandro, mãe Carla, irmã Beatrice e meus avós Pedro,  
Alvino, Ledy e Marília que me garantiram toda estrutura e apoio que me  
trouxeram até aqui....*



## AGRADECIMENTOS

É difícil compilar em uma página agradecimentos a todos que participaram destes últimos 30 meses. Foram 30 meses de aprendizado, crescimento e autoconhecimento. Mas primeiramente, tenho que agradecer a minha família, meu pai Leandro, minha mãe Carla e minha irmã Beatrice que sempre estiveram ao meu lado, mesmo que geograficamente distantes, participaram de cada momento me encorajando e garantindo que nunca me faltasse nada em todo esse processo, seja recursos, saúde, educação e principalmente amor e carinho. A eles sou grato por estar aqui, chegando no fim desta etapa, e reconheço que com todos os privilégios que tive na vida não fiz mais que a minha obrigação (como dizem todos os pais hehe). Uma pessoa que também tenho muito a agradecer é a Bruna, que foi minha companheira por seis anos, e segue como uma amiga da vida, acompanhou bem de perto toda essa caminhada, se mudou comigo para São José dos Campos e enfrentou comigo todas as dificuldades de construir uma nova vida em uma cidade sem nenhum amigo ou familiar. Bruna sempre me apoiou e nos piores momentos fez o possível (e o impossível as vezes) para me garantir todo o suporte necessário para alcançar essa linha de chegada. De São José dos Campos, primeiramente, preciso agradecer a quatro pessoas, a minha orientadora Silvana que me abriu as portas do INPE, também sempre demonstrando empatia, carinho e garantindo um processo humanizado de aprendizado. As oportunidades fruto dessas portas abertas por ela, vão definir o rumo de toda a minha trajetória profissional. O aprendizado que tive ao seu lado tem sido ímpar, exponencial e sempre e me trouxe a realização profissional. A segunda pessoa é a Maria Isabel, Bel também me acolheu em um dos piores momentos de 2017, quando meu futuro no INPE ficou incerto. Me garantiu que dependendo dela eu ficaria no INPE, e assim fez, me contratando e confiando no meu trabalho em um dos maiores projetos do INPE. Muitas conversas e risadas no hall dos hotéis pela Amazonia durante as atividades de campo e depositando confiança no meu trabalho. A terceira pessoa é a Ana Paula, minha coorientadora, que sempre esteve totalmente disponível, se dedicou ao máximo para garantir um processo de orientação humanizado com muita empatia, reconheço a importância da participação dela em cada etapa desta jornada. A quarta pessoa é o Juan, além de um grande amigo que fica para vida, Juan é um grande mentor profissional e de causa, me mostrou que nosso trabalho como “remoteiros” pode auxiliar pessoas que estão na linha de frente da batalha contra um sistema de opressão, me levou para trabalhar com populações indígenas e me apresentou um mundo que não vemos pelas imagens de satélite. Ademais foi um terceiro orientador na minha dissertação, um mentor na programação dedicando tempo para me passar conhecimento. Por último tenho que agradecer a toda equipe do LISS, colegas que sempre estiveram dispostos a colaborar com

o trabalho dos colegas, em especial Danilo, Afonso, Gabriel Bragion e Mateus Macul. Da minha turma do INPE, a turma de 2019 também agradeço a parceria, a solidariedade de todos nos momentos difíceis e, em especial agradeço pelos bons momentos as colegas Sabrina e Ana Larissa e pelo suporte, solidariedade, amizade companhia em muitas jornadas “Inpeanas” a Raíssa, amiga para vida. Também agradeço a CAPES pelos fomentos.

## RESUMO

A Amazônia brasileira detém a maior área de floresta tropical preservada e contínua do mundo e ao mesmo tempo, apresenta intensa dinâmica de urbanização de sua população, tendo sido anteriormente considerada por Bertha Becker uma floresta urbanizada. A caracterização do fenômeno urbano é central na organização socioespacial contemporânea do espaço regional amazônico, e para tanto, sensoriamento remoto e geotecnologias são ferramentas básicas para produzir informações. Contudo, em geral, as metodologias e produtos disponíveis, como as que produzem grades globais e mapeamentos de cobertura, ignoram as especificidades regionais e invisibilizam processos e expressões da ocupação humana. Neste contexto, o objetivo geral deste trabalho foi desenvolver uma metodologia de classificação de áreas construídas urbanizadas baseada em atributos espectrais e texturais de imagens Sentinel-2 (10m) em seis cidades paraense: Altamira, Cametá, Itaituba, Novo Progresso, São Félix do Xingu e Santarém. A metodologia foi desenvolvida de modo a ser replicável e extensível para outras áreas da Amazônia brasileira, através da implementação de algoritmo em *Python*, na plataforma de processamento *Google Earth Engine*. Mosaicos de imagem de luzes noturnas VIIRS foram utilizados para inicialmente restringir a área de processamento às áreas iluminadas das sedes municipais. Além das quatro bandas espectrais originais (10m) do Sentinel-2, foram geradas imagens índices de vegetação e de água, e bandas referentes a 17 métricas de textura, totalizando 74 variáveis. Utilizando o algoritmo *Random Forest*, foram realizados quatro experimentos para avaliar a contribuição das variáveis de textura na classificação de coberturas urbanas das áreas urbanizadas. Três experimentos consideraram uma floresta de árvore de decisão única para todas as cidades e como dados, somente as bandas espectrais (SRF-OS); incluindo os índices NDVI e NDWI (SRF-OSI); e incluindo as métricas de textura (SRF-GLCM), ou seja, todas as variáveis. O quarto experimento construiu uma floresta de árvores de decisão para cada uma das cidades com todas as variáveis (MRF-GLCM). Os resultados demonstraram uma acurácia global de 96,26% para a classificação SRF-OS, 96,34% para SRF-OSI, 97,03% para SRF-GLCM e 98,12% para MRF-GLCM. Entretanto, a maior diferença observada foi na acurácia da classe área construída, variando entre 89,8%, 90,3%, 96,3% e 96,5% respectivamente. Os resultados mostraram que a inclusão das métricas de textura aumentaram a capacidade do classificador diferenciar coberturas com assinaturas espectrais semelhantes, como as áreas de solo exposto com os arruamentos não-pavimentados, frequentes nas cidades amazônicas. Ainda que seja factível a aplicação de um único modelo RF para diferentes cidades em escala regional, e neste caso, SRF-GLCM seria o mais indicado, modelos específicos (MRF-GLCM) são mais indicados para estudos de uma cidade ou município, em escala mais local. Mapeamentos das coberturas urbanas, como proposto neste trabalho, possibilitam a análise e estudo do fato urbano, em diferentes realidades, permitindo a construção de narrativas que tornem visíveis as particularidades e especificidades locais, como as das cidades amazônicas.

Palavras-chave: Classificação. Machine Learning. Área Construída. Amazônia

# **CONTRIBUTION OF TEXTURE METRICS IN PIXEL-A-PIXEL CLASSIFICATION TO IDENTIFY CONSTRUCTED AREAS OF AMAZON CITIES**

## **ABSTRACT**

The Brazilian Amazon has the largest area of preserved and continuous tropical forest in the world and, at the same time, it has an intense urbanization dynamic of its population, having previously been considered an urbanized forest. The characterization of the urban phenomenon is central to the contemporary socio-spatial organization of the Amazonian regional space, and for that, remote sensing and geotechnologies are basic tools to produce information. However, in general, available methodologies and products, such as those that produce global grids and coverage mappings, ignore regional specificities and make processes and expressions of human occupation invisible. In this context, the general objective of this work was to develop a methodology for classifying urbanized areas based on optical images of high spatial resolution (10m) and to evaluate the contribution of texture metrics for the digital classification of intra-urban coverage of six cities in Pará: Altamira, Cametá, Itaituba, Novo Progresso, São Félix do Xingu and Santarém. The methodology was developed in order to be replicable and extensible to other areas of the Brazilian Amazon, through the implementation of an algorithm in Python, on the Google Earth Engine processing platform. VIIRS night-light image mosaics were used to initially restrict the processing area to the illuminated areas of municipal headquarters. In addition to the original four spectral bands (10m) of Sentinel-2, for the classification tests, images of vegetation and water indexes, and bands referring to 17 texture metrics were generated, totaling 74 variables. Using the Random Forest algorithm, four experiments were carried out to evaluate the contribution of texture variables in the classification of urban coverage in urbanized areas. Three experiments considered a single decision tree forest for all cities and as data, only the spectral bands (SRF-OS); including the NDVI and NDWI (SRF-OSI) indices; and including texture metrics (SRF-GLCM), all variables. The fourth experiment built a forest of decision trees for each of the cities with all variables (MRF-GLCM). The results showed an overall accuracy of 96.26% for the SRF-OS classification, 96.34% for SRF-OSI, 97.03% for SRF-GLCM and 98.12% for MRF-GLCM. However, the greatest difference observed was in the accuracy of the built-up area, varying between 89.8%, 90.3%, 96.3% and 96.5%, respectively. The results showed that the inclusion of texture metrics increased the classifier's ability to differentiate covers with similar spectral signatures, such as exposed soil areas with unpaved streets, common in Amazonian cities. Although it is feasible to apply a single RF model for different cities on a regional scale, and in this case, SRF-GLCM would be the most suitable, specific models (MRF-GLCM) are more suitable for studies of a city or municipality, in scale more local. Mappings of urban coverage, as proposed in this work, enable the analysis and study of the urban fact, in different realities, allowing the

construction of narratives that make visible local particularities and specificities, such as those of Amazonian cities

Keywords: Classification. Machine Learning. Build up areas. Amazon

## LISTA DE FIGURAS

Figura 2.1 - Comportamento espectral de materiais presente em área urbana	18
Figura 3.1 - Fluxograma geral de etapas para construção da metodologia de identificação de áreas construídas em cidades amazônicas.....	23
Figura 3.2 - Localização da área de estudos, e das sedes municipais utilizadas para avaliação dos resultados no estado do Pará, Amazônia Legal, Brasil. ....	26
Figura 4.1 - Limites de áreas para processamento em Altamira, Cametá, Itaituba, Novo Progresso, São Félix do Xingu e Santarém. ....	50
Figura 4.2 - Distribuição das amostras (total, treinamento e validação) dentre as classes. ....	51
Figura 4.3 - Gráficos <i>boxplot</i> das amostras de treinamento e para cada classe de cobertura urbana, nas bandas espectrais do S2. ....	52
Figura 4.4 - Gráficos <i>boxplot</i> das amostras de treinamento de para cada classe nos índices biofísicos (NDVI e NDWI).....	53
Figura 4.5 - Gráficos <i>boxplot</i> das amostras de treinamento de para algumas métricas texturais. ....	54
Figura 4.6 - Importância das variáveis (SRIIG) para o Randon Forest de árvore única (SRF): somente com dados espectrais (SRF-OS), incluindo índices biofísicos (SRF-OSI), e texturas (SRF-GLCM).....	62
Figura 4.7 - Importância das variáveis (SRIIG) para o Randon Forest com árvores específicas (MRF-GCLM) para Altamira e Cametá. ....	64
Figura 4.8 - Importância das variáveis (SRIIG) para o Randon Forest com árvores específicas (MRF-GLCM) para Itaituba e Novo Progresso. ....	65
Figura 4.9 - Importância das variáveis (SRIIG) para o Randon Forest com árvores específicas (MRF-GLCM) para São Félix do Xingu e Santarém. ....	66
Figura 4.10 - Classificações de Altamira, Cametá, Itaituba, Novo Progresso, São Félix do Xingu e Santarém, para o Randon Forest de árvore única (SRF): somente com dados espectrais (SRF-OS), incluindo índices biofísicos (SRF-OSI), texturas (SRF-GLCM), e uma árvore para cada cidade com todas as variáveis (MRF-GLCM). ....	68
Figura 4.11 - Proporção das classes no mapa temático predito pelas RF em cada uma das sedes municipais. ....	69
Figura 4.12 - Área das classes no mapa temático predito pelas RF em cada uma das sedes municipais. ....	71
Figura 4.13 - Área das classes no mapa temático predito pelas RF em cada uma das sedes municipais. ....	73
Figura 4.14 - Matrizes de erro para todas as classificações Randon Forest com árvore única (SRF) e múltiplas (MRF).....	75
Figura 4.15 - Matrizes de erro para as classificações Randon Forest em Altamira, Cametá, Itaituba, Novo Progresso, São Félix do Xingu e Santarém.	76

Figura 4.16 - Acurácia do produtor, consumidor, global e coeficiente de Kappa para todas classes e sedes municipais analisadas. ....	77
Figura B.1 - Mapas contendo o NDVI calculado para as seis sedes municipais. ....	99
Figura B.2 - Mapas contendo o NDWI calculado para as seis sedes municipais. ....	100
Figura C.1 - Mapas temáticos resultantes para Altamira.....	101
Figura C.2 - Mapas temáticos resultantes para Cametá. ....	102
Figura C.3 - Mapas temáticos resultantes para Itaituba. ....	103
Figura C.4 - Mapas temáticos resultantes para Novo Progresso. ....	104
Figura C.5 - Mapas temáticos resultantes para São Félix do Xingú.....	105
Figura C.6 - Mapas temáticos resultantes para Santarém. ....	106

## LISTA DE TABELAS

Tabela 3.1 - Composição populacional em 2010 (Censo) e 2020 (estimativa), para cidades selecionadas na área de estudo. ....	28
Tabela 3.2 - Síntese dos dados utilizados e suas características básicas .....	30
Tabela 3.3 - Bandas espectrais dos satélites Sentinel 2A e 2B utilizadas .....	31
Tabela 3.4 - Classes de coberturas urbanas para caracterizar a área urbanizada construída de cidades amazônicas.....	32
Tabela 3.5 - Descrição das métricas de texturas utilizadas .....	42



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>1</b>
1.1	Objetivo geral	4
1.2	Objetivos específicos	4
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>6</b>
2.1	A heterogeneidade das cidades amazônicas	6
2.2	Área urbana, área urbanizada e área construída	12
2.3	Sensoriamento remoto para mapeamento de áreas construídas urbanizadas	15
2.3.1	Sensores e plataformas: características e estudos urbanos	15
2.3.2	Métricas de textura e classificação de imagem	19
<b>3</b>	<b>METODOLOGIA</b>	<b>23</b>
3.1	Área de estudo	24
3.2	Dados	28
3.3	Definição das classes de interesse	31
3.4	Procedimentos metodológicos	36
3.4.1	Delimitação da extensão geográfica para o processamento e classificação	36
3.4.2	Pré-processamento das Imagens Sentinel-2	38
3.4.3	Processamento - classificação digital das imagens	43
3.4.4	Pós-classificação: avaliação da acurácia temática	47
<b>4</b>	<b>RESULTADOS E DISCUSSÕES</b>	<b>49</b>
4.1	As áreas urbanizadas das sedes de município e seus entornos - delimitação da extensão geográfica para processamento	49
4.2	Comportamento espectral das classes de uso e cobertura a partir das amostras	50
4.3	Avaliação dos parâmetros e critérios para a classificação de áreas construídas	59
4.3.1	Contribuição das variáveis - bandas espectrais, biofísicas e de textura	60
4.4	Classificação das áreas construídas das cidades	67

4.5	Avaliação da acurácia temática das classificações .....	74
<b>5</b>	<b>CONCLUSÕES .....</b>	<b>78</b>
	<b>REFERENCIAS BIBLIOGRAFICAS.....</b>	<b>81</b>
	<b>APENDICE A - BREVE HISTÓRICO DE CRIAÇÃO DAS CIDADES.....</b>	<b>94</b>
	<b>APENDICE B – MAPAS DE NDVI E NDWI.....</b>	<b>99</b>
	<b>APENDICE C – MAPAS COM RESULTADOS DA CLASSIFICAÇÃO EM MAIOR ESCALA.....</b>	<b>101</b>

## 1 INTRODUÇÃO

A Amazônia brasileira ocupa um vasto território, com notória heterogeneidade social, ambiental e econômica (BECKER, 2005). Ao mesmo tempo em que abriga a maior área de floresta tropical preservada e contínua do mundo, detém uma intensa dinâmica de urbanização de sua população, com grau de urbanização superior a 70%, segundo Censo de 2010 (IBGE, 2010a). Bertha Becker (1995), já em meados da década de 1990, chamava atenção para a urbanização da Amazônia ao propor o termo floresta urbanizada como um caminho para designar a região e reforçar a necessidade de incluir as questões urbanas nas agendas para a Amazônia. Atualmente, para além do número e tamanho das cidades, diversos estudos discutem a urbanização também a partir da transformação de valores da sociedade, evidenciando um fenômeno que se estende pelo território com diferentes intensidades (MONTE-MÓR, 2004). Apesar do esforço global e diante das preocupações com as emissões e os sumidouros de carbono, por exemplo, em relação a Amazônia, “o ‘urbano’ continua sendo o “elefante na sala”, muito confuso para ser abordado, mas, paradoxalmente, “muito fácil de ser ignorado” (BRONDIZIO, 2016).

Nesse contexto, o sensoriamento remoto (SR), aliado a outras tecnologias da geoinformação, possui imenso potencial para incluir inúmeras feições da urbanização amazônica nos mapas (CARDOSO; LIMA, 2006; DAL’ASTA et al., 2012), gráficos, ferramentas e cenários que retratam o ambiente regional (BRONDIZIO, 2016). O SR ainda se constitui como possibilidade metodológica e economicamente viável para realizar estudos urbanos em diferentes escalas (ALMEIDA et al., 2007). Nas últimas décadas, a evolução das tecnologias de geoinformação e as capacidades computacionais, têm tornado a utilização de dados de SR mais frequentes, sendo essenciais para representar, descrever e compreender a intensa urbanização no mundo (LU et al., 2011; LI et al., 2013; SIDIKE; ASARI; SAGAN, 2018; GONG; LI; ZHANG, 2019; OU et al., 2019).

Diferentes ferramentas computacionais têm sido propostas para processamento de dados de SR, tais como algoritmos de Inteligência Artificial (NOURANI; ROUSHANGAR; ANDALIB, 2018), Redes Neurais Artificiais, Árvores de Decisão

(HASTIE; TIBSHIRANI; FRIEDMAN, 2009) ou Conjuntos de árvores de decisão (BREIMAN, 2001), as quais produzem classificações de uso e cobertura do solo cada vez mais confiáveis. Adicionalmente, houve a evolução dos sensores de imageamento, com sensores de melhor resolução espacial, como as imagens dos sistemas IKONOS (80cm), Pléiades (50cm) e SkySat (50cm); com maior frequência de aquisição de imagens, como nos sistemas Planet e MODIS, com aquisição diária de imagens; e melhor resolução espectral, como nos sistemas Hyperion e Hypersat, com mais de 200 bandas espectrais, além de novas plataformas orbitais. Esta profusão de dados de SR possibilita análises de fenômenos na superfície terrestre mais detalhadas e precisas, características fundamentais para estudos urbanos (WENG; LU, 2008; ANCHANG; ANANGA; PU, 2016; FENG et al., 2017; POK; MATSUSHITA; FUKUSHIMA, 2017).

Atualmente, há diversas iniciativas que contemplam o mapeamento da extensão da cobertura urbana por SR, a partir de bases de mapeamento de uso e cobertura do solo, ou de algumas características urbanas. Como exemplo, podemos citar os projetos de mapeamento de uso e cobertura do Brasil, como TerraClass (ALMEIDA et al., 2016) e MapBiomias (SOUZA et al., 2020) baseados em dados Landsat (30m) que apresentam a limitação de identificar apenas uma classe urbana associada à área urbanizada construída. Há ainda bases globais que mapeiam os assentamentos humanos, como a *Global Human Settlement Layer* (FLORCZYK et al., 2019), baseada em imagens Sentinel (10m), ou que identificam as coberturas urbanas a partir de áreas impermeabilizadas, como a *Global Man-made Impervious Surface* (COLSTOUN et al., 2017), baseada em imagens Landsat (30m).

Em análise preliminar, Gonçalves et al. (2021), considerando o ano de 2010, observaram a consistência e concordância de alguns produtos de mapeamento para um conjunto de cidades paraenses, a fim de entender qual urbanização seria captada por essas bases gerais de mapeamento. Os autores observaram que tais mapeamentos fornecem uma aproximação da dimensão espacial da urbanização amazônica. Contudo, essas bases tendem a considerar apenas os padrões de expressão urbana mais consolidados, áreas impermeabilizadas e centrais nas cidades como já apresentado por Becker (2013) e Brondizio (2016),

em detrimento de áreas com menor adensamento da ocupação e estrutura urbana menos consolidada, traços marcantes em cidades amazônicas. Outro ponto destacado pelos autores refere-se à definição do que está sendo mapeado, como uma mediação para descrever o urbano. Embora essas bases forneçam um elemento comparável no espaço, as feições mapeadas estão intrinsecamente relacionadas aos conceitos de área urbanizada construída, associada a superfícies impermeáveis.

Genericamente, as definições acima, buscam medir a dimensão física da urbanização a partir das concentrações espaciais de população e de edificações. Essa mediação parte de uma parametrização genérica das cidades vistas em oposição ao rural, fortemente associada ao tipo de dado de SR. Apesar de a urbanização amazônica guardar semelhanças internas e também com outras regiões do Brasil, as cidades são espaços produzidos a partir do contexto local (OLIVEIRA, 2006), compondo espaços múltiplos de diferentes temporalidades que coexistem (TRINDADE JÚNIOR et al., 2011) e com uma diversidade espacial e espectral de formas e arranjos dos alvos urbanos (POWELL; ROBERTS, 2008). Há uma diversidade de fatores e agentes que atuam no espaço regional, conferindo diferentes naturezas, velocidades e padrões de ocupação e de mudanças no território (AMARAL, 2003; BARBIERI, 2007; ESCADA et al., 2009; ALVES et al., 2010).

Assim, mais do que a demanda por informações e a disponibilidade de dados, é indiscutível (re)posicionar abordagens e conceitos para a realidade tão diversa da Amazônia, levando em consideração as características locais, intrínsecas ao estilo de vida e condições estruturais da região (CARDOSO; MELO; GOMES, 2017; LOBO; TOURINHO; COSTA, 2017). Dessa forma, tais abordagens permitiriam visibilizar a riqueza e extensão das expressões espaciais das múltiplas formas da urbanização regional na Amazônia (CARDOSO; LIMA, 2006).

Por conseguinte, nesta dissertação é apresentada uma metodologia analítica baseada em dados de SR para mapeamento das áreas construídas urbanizadas em um conjunto de seis cidades paraenses, que são representativas de uma

gama de populações, contextos sócio-espaciais e dinâmicas territoriais. O desafio é acomodar a diversidade espectral e textural de elementos intraurbanos e das particularidades da urbanização amazônica em uma abordagem classificatória baseada em grande volume de dados e com potencial para reprodução espaço-temporal em outros territórios amazônicos.

### **1.1 Objetivo geral**

Este trabalho apresenta uma metodologia para mapeamento das áreas construídas em sedes municipais de seis municípios do estado do Pará, a partir de imagens de satélite aplicando técnicas de processamento digital de imagens e de *machine learning*<sup>1</sup>. Parte-se do pressuposto que para caracterizar as áreas construídas urbanizadas através de classificação digital de imagens que possa ser extensível para toda a região, é necessário considerar as particularidades das cidades Amazônicas.

Desenvolver uma metodologia de classificação baseada em imagens ópticas de alta resolução espacial (10m) e avaliar a contribuição de métricas de textura, para a classificação digital das coberturas intraurbanas de cidades amazônicas.

### **1.2 Objetivos específicos**

Para alcançar o objetivo geral, os seguintes objetivos específicos foram delineados, adotando-se o estado do Pará como área de estudo e recorte para testes:

1. Desenvolver procedimentos metodológicos que permitam a replicação e ampliação da classificação para toda a Amazônia Legal, utilizando ferramentas acessíveis, como dados livres e plataformas de processamento aberto, e capazes de trabalhar com grandes volumes de dados;

---

<sup>1</sup> Aprendizado de máquina, subcampo da engenharia da computação onde uma inteligência artificial é treinada para desenvolver de forma automática uma determinada operação.

2. Propor estratégias para identificar a extensão do território associada a áreas construídas urbanizadas nas cidades, ou núcleos populacionais, a serem mapeadas;
3. Identificar e mapear as principais coberturas que compõem as áreas construídas urbanizadas das cidades amazônicas, a partir de classificação digital de bandas espectrais e métricas de textura derivadas;
4. Apresentar os parâmetros adequados para a classificação, considerando o efeito da amostragem no desempenho do classificador, bem como a contribuição específica dos dados espectrais e das métricas de textura.

O presente documento está dividido em quatro principais seções construídas com o propósito de justificar a temática desta dissertação de mestrado. No Capítulo 2, busca-se apresentar um arcabouço teórico-conceitual para fundamentar a problemática desta pesquisa e uma breve revisão bibliográfica sobre o uso de geotecnologias em mapeamentos de áreas construídas urbanizadas. O Capítulo 3 apresenta a metodologia desenvolvida de acordo com os objetivos propostos. No Capítulo 4, os resultados são descritos e discutidos e, a partir de trabalhos similares, comparados. Por último, no Capítulo 5 destacam-se as principais conclusões obtidas no trabalho, limitações e a possibilidade de trabalhos futuros.

Este trabalho de dissertação de mestrado busca desenvolver uma metodologia que permita a utilização de dados livres para mapeamento de áreas construídas em cidades amazônicas. O objetivo é garantir a inclusão das particularidades das cidades amazônicas e permitir o mapeamento de áreas indicativas dos modelos de urbanização neste vasto e heterogêneo território, produzindo informações assertivas que auxiliem tomadores de decisões no planejamento de desenvolvimento sustentável do crescimento urbano nesta região.

## **2 FUNDAMENTAÇÃO TEÓRICA**

Nesta seção estão detalhadas as bases científicas que compõem o arcabouço teórico conceitual que fundamenta esta pesquisa. O objetivo é uma revisão de literatura para conceituar as definições de áreas construídas urbanizadas assim como as características intrínsecas de cidades amazônicas. Tendo em vista o cunho metodológico desta dissertação, apresentam-se também ferramentas, metodologias e dados de SR usuais na identificação de coberturas urbanas.

### **2.1 A heterogeneidade das cidades amazônicas**

A heterogeneidade das formas socioespaciais da Amazônia brasileira é resultado de distintos processos e fases de ocupação de seu território, desde as ocupações pelos povos tradicionais, a colonização europeia até os programas de ocupação promovidos pelo governo brasileiro no século XX e as estratégias atuais de expansão da fronteira agropecuária (HORN; D'ALENÇON; CARDOSO, 2018). Em decorrência desses processos, a atual conformação das cidades amazônicas contempla uma multiplicidade de formas e elementos de diferentes temporalidades que se combinam e (co)existem em um espaço híbrido. Este item se propõe a resgatar genericamente o contexto histórico na perspectiva de produção desses elementos nas cidades. As cidades são espaços produzidos socialmente, ou seja, “as cidades amazônicas são tempos e espaços produzidos a partir do específico”, e “retratam o vivido de quem as constrói” (OLIVEIRA, 2006).

Além das cidades, uma profusão de vilas e localidades, interligadas por rio e por terra, constituem registros de um padrão de dispersão de população pelo território amazônico. Herdado de tempos pré-cabralinos (HECKENBERGER et al., 2008; LOPES, 2017) este padrão de dispersão teve origem na conexão da população com a natureza e sua biodiversidade, e foi se modificando ao incorporar os processos de intervenção no território.

A partir do século XVII, teve início a colonização portuguesa na região. Em 1616, houve a fundação de Belém e a introdução das primeiras povoações europeias. Estas eram constituídas basicamente por aparato militar (fortins), religioso

constituído por igrejas e propriedades agrícolas das missões, e pela presença de algumas casas (CORREA, 1987).

No século XVIII, a gestão de Marques de Pombal foi decisiva para a disseminação de cidades como fortalecimento da presença portuguesa na região (BECKER, 2013; CARDOSO et al., 2020). O período pombalino foi marcado pela exploração das drogas do sertão (especiarias) e a consolidação de núcleos urbanos nas calhas dos grandes rios, aproveitando aldeamentos e conventos. Se diferencia do período anterior da colonização, principalmente pela especialização no uso da terra com a introdução da agricultura e intensificação da produção extrativista, e a miscigenação induzida da população (CORREA, 1987; OLIVEIRA, 2006). Os núcleos passaram a ter padrões espaciais que facilitaram as operações militares, como defesa, cobrança e controle de tributos, além do atendimento das necessidades civis, configurando-se em entreposto comercial de produtos extrativos e agrícolas. Esses entrepostos eram tanto a base para a captura de índios, como a sede do poder temporal do Estado e das missões religiosas (OLIVEIRA, 2006; BECKER, 2013). Mesmo com as imposições do colonizador quanto ao modelo de urbanização, o espaço urbano que se constituía refletia também as condições locais específicas oriundas do cotidiano e da interação entre os moradores e a floresta (OLIVEIRA, 2006).

Contudo, entre o fim do século XIX e início do século XX, a economia gomífera trouxe uma importante transformação na malha urbana amazônica: a redefinição das relações sociais intraurbanas em Belém e Manaus e dessas com as demais cidades da região e suas hinterlândias (CARDOSO, 2020). A expectativa de trabalho, criada pela demanda mundial por borracha da seringueira, atraiu milhares de pessoas para a Amazônia, principalmente das regiões Nordeste e Sudeste e até de outros países (MACHADO, 1999). A rede de núcleos urbanos, suas relações e interdependência constituíam uma representação física da cadeia comercial da exportação da borracha. A posição hierárquica de cada aglomerado era definida de acordo com sua posição na cadeia de comercialização da borracha. As aglomerações se situavam em pontos de transbordo, nos portos das unidades produtoras, ou na confluência de rios que escoavam a produção de outras sub-bacias. A espacialidade da urbanização

desse período é marcada pelo padrão dendrítico, consolidação das metrópoles Belém (de 20 mil habitantes em 1856, para 192 mil habitantes em 1907) e Manaus (de 8.500 habitantes em 1852, para 50 mil habitantes em 1914), criação de novas cidades e expansão urbana como base para a exploração da borracha (MACHADO, 1999; CARDOSO et al., 2020).

Nesse período, a riqueza acumulada localmente resultou numa produção arquitetônica, com investimento em equipamentos e espaços públicos nas cidades persistente na cidade contemporânea (CARDOSO, 2020). Em contrapartida, essa estrutura sócio-político-institucional excluiu, ao longo do período de exploração da borracha, uma parcela significativa da população de seus benefícios, sejam diretos, pela oferta de trabalho e melhor remuneração, ou indiretos, pela provisão de equipamentos urbanos (OLIVEIRA, 2010; MACHADO, 1999). O resultado foi o contraste entre o centro, de melhor infraestrutura, e as regiões periféricas, e ou as cidades pequenas, de infraestrutura urbana mínima. Em Belém, a população da região central era provida de água encanada, bondes elétricos, iluminação elétrica e residências de alto padrão e as populações periféricas não possuíam infraestrutura de saneamento e as residências eram construídas com madeira e palha (CARDOSO et al., 2015).

Até meados do século XX, nas pequenas cidades da região, a igreja matriz e a prefeitura eram normalmente as construções mais proeminentes, localizadas na rua em frente ao rio, que era o centro da vida cidadina. Em cidades mais proeminentes, a feira assumia papel destacado na orla da cidade, e associadas à prática de atividades comerciais, estabeleciam-se as edificações localizadas em frente ao rio. À medida que se afastavam do centro da cidade, ruas e edificações ficavam mais simples e mais dispersas, confundindo-se com a floresta (CARDOSO; LIMA, 2006). Entretanto, a floresta não era um elemento intocado, mas um espaço de produção e manejo, com frequentes intervenções (PINHO; CARDOSO, 2016).

Na segunda metade do século XX, esse padrão sócio-espacial foi fortemente impactado pela intensa urbanização regional promovida pela geopolítica do

governo militar, caracterizada pela superposição de padrões territoriais e produtivos (PINHO; CARDOSO, 2016). O planejamento governamental enfatizava e subsidiava uma ocupação voltada para a agropecuária, tendo na implantação de núcleos urbanos sua estratégia explícita (BECKER, 2013; 1995). Entretanto, a prioridade foi dada às obras voltadas para à produção, seja ela agropecuária, mineral, etc., em detrimento das estruturas de apoio à vida da população residente nas cidades (CARDOSO et al., 2015). É desse período a criação, para fins de planejamento, da Amazônia Legal<sup>2</sup> como jurisdição para a atuação da Superintendência do Plano de Valorização Econômica da Amazônia (SUDAM).

Tem-se então, múltiplas formas de urbanização emergindo na Amazônia: as resultantes de processos espontâneos, como o crescimento explosivo de antigas cidades localizadas à beira das estradas; aquelas resultantes do surgimento de novas cidades e de inúmeros povoados altamente instáveis; e ainda as formas associadas à ocupação dirigida por meio do urbanismo rural<sup>3</sup>, esses movimentos criaram cidades ou fortaleceram projetos de colonização ao longo dos novos eixos de circulação (BECKER, 2013). Outra herança desse período é a implantação das *company towns* por empresas de grandes projetos associados à exploração mineral, como na Serra do Navio e Vila Amazonas, e projetos hidroelétricos, como Tucuruí e Monte Dourado (CARDOSO et al., 2015).

A racionalidade das iniciativas do governo militar baseava-se em um modelo de desenvolvimento externo, ou seja, previa a apropriação da terra para usos produtivos modernos em detrimento do extrativismo e saber tradicional (PINHO; CARDOSO, 2016). A partir desse período, as estradas emergiram como vetores da expansão urbana e interiorização da ocupação. Com consequência do abandono das estruturas hidroviárias, houve a desvalorização de práticas produtivas associadas às margens dos rios, seja no entorno, seja na frente das cidades ribeirinhas, como o extrativismo em áreas públicas, a produção de

---

<sup>2</sup> [http://www.planalto.gov.br/ccivil\\_03/leis/L5173compilado.htm](http://www.planalto.gov.br/ccivil_03/leis/L5173compilado.htm)

<sup>3</sup> Proposta do INCRA para apoio aos assentamentos rurais em áreas sob influência da BR-230 (Transamazônica).

embarcações, as indústrias alimentícias, e as feiras<sup>4</sup> (CARDOSO, 2020). O entorno ou o entroncamento viário passa a ser o núcleo comercial, com serviços voltados também para o fluxo da estrada (DAL´ASTA et al., CARDOSO; LIMA, 2006). O forte caráter simbólico dos núcleos ribeirinhos, diretamente ligado à natureza, que articulava o rio para pesca, obtenção de água, locomoção; o quintal, para coleta de frutos, plantação de ervas medicinais, criação de animais; a roça, para plantação de alimentos; e a mata, para extrativismo e caça (VICENTE; CARDOSO, 2016), foi enfraquecido pela racionalidade e dinâmica promovidas pela acessibilidade rodoviária. Ou seja, esse padrão de estruturação urbana, com o rio como principal referência para a disposição dos objetos espaciais, quando integrado territorialmente pelas redes viárias, passou a ser redesenhado pela influência de novos eixos. A distribuição das vias levou a definição o novo traçado das cidades, redesenhando o seu padrão e crescimento. Esse padrão híbrido na dinâmica contemporânea de cidades centenárias foi descrito em Trindade Trindade Júnior et al. (2011) para as cidades de Cametá, Mocajuba e Baião<sup>5</sup>, e por Costa (2012) para a cidade de Santarém.

Ainda que as cidades tenham características de uma expressiva urbanização, são carentes de infraestrutura urbana básica. Em Santarém, por exemplo, apesar do tamanho, sua importância na rede urbana regional, intensa circulação de objetos e pessoas, e do acesso a tecnologias, há carência de pavimentação de vias públicas, especialmente nas áreas de expansão mais recentes (COSTA, 2012). A atuação historicamente seletiva do capital prioriza a margem da rodovia ou do rio, no que se considera a “frente da cidade”, para ação e urbanização, refletindo em uma gestão urbanística dissociada das ações que realmente modelam a cidade (CARDOSO et al., 2015).

Na dinâmica mais recente, a produção do espaço urbano amazônico resulta de vários atores e processos, tais como: do interesse do mercado imobiliário, com

---

<sup>4</sup> A partir da década de 2000, essas faixas urbanas das margens dos grandes rios foram redirecionadas para atividades turísticas.

<sup>5</sup> Cametá possui 408 anos, Mocajuba 168 anos e Baião 327 anos

a multiplicação de loteamentos (CARDOSO; CAROLINA; GOMES, 2015; NEGRÃO; BASTOS; CARDOSO, 2015); da expansão urbana indiscriminada em surtos de investimentos curtos, com a transformação de parcelas de áreas urbanas já consolidadas por meio de obras de infraestrutura urbana (CARDOSO; PEREIRA; NEGRÃO, 2013; RODRIGUES et al., 2019); e até do aprofundamento das condições de precariedade urbana nas metrópoles e cidades polo (OLIVEIRA, 2008; MACIEL, 2016).

Tem-se assim, o espaço urbano amazônico constituído de inúmeras formas urbanas e paisagens derivadas que guardam elementos residuais da interação complexa entre os diferentes tempos que moldaram sua urbanização. Independente da gênese das cidades amazônicas tradicionais ou contemporâneas, nelas coexistem formações socioespaciais que mudam e aquelas que permanecem no tempo e no espaço (TRINIDAD et al., 2009).

Vicente e Cardoso (2016) descreveram, a partir de relatos de moradores antigos, a dinâmica mais recente de Afuá, cidade ribeirinha da várzea do Amazonas datada do século XIX, com o adensamento construtivo no bairro Centro, os quintais se tornaram menores, não sendo mais comum o plantio de árvores, reduzindo ou eliminado os jardins na frente e ao lado das casas, e a presença de árvores nas ruas. Diniz (2020) observou processo semelhante em localidades ribeirinhas do baixo Tocantins, onde em decorrência do adensamento populacional, a distância entre as residências diminuiu em um padrão de expansão que seguia o contorno do rio.

Assim, o resultado desse processo é um complexo arranjo espacial e espectral de elementos físicos, naturais ou construídos, compondo a paisagem urbana amazônica (POWELL; ROBERTS, 2008). O adensamento de construções resulta em áreas com maior taxa de impermeabilização do solo, especialmente naquelas centrais providas de ruas pavimentadas, e lotes com pouca ou nenhuma área com cobertura vegetal arbórea. Há também aquelas áreas cujo adensamento de construções não foi acompanhado da implementação de infraestrutura urbana, apresentando um padrão de ruas com solo exposto; e ainda há áreas de ocupação esparsa. Vegetação arbórea no interior das quadras

é um traço marcante em muitas cidades amazônicas. A presença do rio é testemunha da ligação com a lógica tradicional. Em contrapartida, para as cidades contemporâneas, que emergiram no cruzamento ou entorno de rodovias, um novo traçado caracteriza a organização espacial da cidade, cuja integração orgânica da rodovia com a cidade é variada.

## **2.2 Área urbana, área urbanizada e área construída**

Para os objetivos deste trabalho, deve-se fazer a devida distinção entre os termos: áreas urbanas, áreas urbanizadas, áreas urbanas consolidadas e áreas construídas. Este último conceito foi adaptado para expressar a urbanização em cidades Amazônicas a partir de dados de SR.

Ressalta-se que neste trabalho, o termo urbano é entendido a partir de sua dimensão física territorial das concentrações populacionais e de construções, sem discutir o conteúdo desse termo. Para compreender o significado de áreas urbanizadas deve-se inicialmente definir o termo áreas urbanas para então apresentar a diferença de áreas urbanizadas.

Áreas Urbanas são definidas por meio de leis municipais que dividem juridicamente o território em urbano e rural. É uma delimitação político administrativa que permite aos gestores planejar e ordenar a ocupação do solo, deliberando sobre o local dos diferentes tipos de edificações e práticas comerciais. A área urbana é uma ferramenta para “nortear” as direções das ocupações urbanas dentro do município e definir os limites a partir dos quais incidem determinados impostos. Uma área urbana pode conter áreas de vegetação nativa, recursos hídricos, arruamentos, edificações domiciliares ou comerciais e até mesmo áreas de plantio. A presença de diferentes usos do solo dentro de uma áreas urbanas deve-se ao fato da necessidade de prever áreas passíveis de expansão do tecido urbano, áreas definidas como vazios urbanos (MAGALHÃES et al., 2013).

Áreas urbanizadas são produzidas pela ocupação humana do espaço, podendo ou não estar dentro de uma área urbana. “São áreas que possuem uma ocupação contínua de edificações, ou que de alguma forma sofreram impacto

antrópico destinado à ocupação urbana” (MAGALHÃES et al., 2013). As áreas urbanizadas podem ser utilizadas como métrica para mensurar e analisar o processo de ocupação urbana do território, podendo levar em conta parâmetros como densidade demográfica, densidade de edificações e outras variáveis socioeconômicas que indiquem a urbanização do espaço (MAGALHÃES et al., 2013). Áreas urbanizadas são heterogêneas compostas pela presença de diferentes elementos que estruturam e moldam o espaço, como casas, ruas, lotes, edifícios, áreas verdes, parques etc. Estes elementos por sua vez, são constituídos por inúmeros materiais, de diferentes naturezas e respostas espectrais, o que dificulta a abstração da área urbanizada em apenas uma classe a partir de dados orbitais. A concentração da população desses espaços e o ritmo do processo de urbanização justificam a importância do estudo das áreas urbanizadas, tanto para compreender a distribuição dos elementos que as compõem, como para subsidiar seus planejamentos e monitoramentos. As particularidades dos elementos das áreas urbanizadas são resultantes dos processos de ocupação de cada local, que no caso da urbanização na Amazônia brasileira refletem o processo histórico de ocupação humana e transformação da paisagem, como explicitado no Item 2.1. Caracterizar as áreas urbanizadas das cidades amazônicas está associado ao objetivo geral deste trabalho.

Área urbana consolidada, utilizada no planejamento e ordenamento urbano, é definida por lei. Ou seja, corresponde a uma definição política que qualifica o estado em que uma determinada área urbana se encontra em um dado momento.

Acho que aqui dá para trazer a definição genérica de área construída e depois trazer a abordagem para a Amazônia

A partir dos conceitos apresentados, este trabalho propõe o uso do termo Área Construída, para rotular as coberturas urbanas das cidades amazônicas como resultado de intervenções humanas e passíveis de observação por dados de SR. Neste caso, uma área construída corresponde à identificação dos elementos que estruturam e moldam o espaço de uma área urbanizada (casas, ruas, lotes,

edifícios, áreas verdes, arruamentos, etc.), considerando a possibilidade de detecção destes elementos construídos pelo homem a partir de dados de SR.

Tendo em vista que a identificação dessas áreas se dará através de imagens de SR orbital, levando em conta suas respostas espectrais e as métricas de textura, a classificação de cada pixel depende principalmente de sua cobertura preponderante, independente de sua vizinhança. Assim, uma área coberta com gramíneas ou solo exposto inserida em um loteamento é considerada uma expressão da urbanização. Diferentes coberturas do solo, seja vegetação ou edificações, são classes de área urbanizada construída. Contudo, uma última distinção, em relação às possíveis classes de coberturas da terra para caracterizar áreas urbanizadas construídas nas cidades amazônicas precisa ser explicitada.

Na literatura internacional, áreas urbanizadas são aquelas que apresentam alta intensidade de impermeabilização (FENG et al., 2017; LIU et al., 2018; OUYANG et al., 2019). Entretanto, uma característica das cidades amazônicas é a baixa intensidade de impermeabilização. Desta maneira, áreas urbanizadas na Amazônia brasileira são compostas por superfícies impermeáveis (casas, edifícios, arruamentos pavimentados) e permeáveis (arruamentos não pavimentados, ou de terra). Porém arruamentos de terra possuem respostas espectrais semelhantes às áreas de solo exposto, como áreas preparadas para plantio, campos naturais, áreas de movimentação de terra para construção etc. Essa semelhança espectral dificulta o processo de classificação automática a partir de informações espectrais. Por isso, neste trabalho, propõe-se a generalização destas feições, superfícies impermeáveis e os arruamentos não pavimentados, em uma única classe, simplificada e denominada áreas construídas.

Desta forma, neste trabalho, a proposta metodológica de classificação digital de imagens se propõe a caracterizar as áreas urbanizadas das cidades amazônicas, classificando as áreas urbanizadas construídas detectáveis por SR. Para tanto, faz-se a identificação de diferentes coberturas do solo urbano (água, vegetação herbácea, vegetação arbórea, solo exposto e área construída),

apresentados em detalhes na metodologia. Para distinguir a cobertura de área construída das áreas de solo exposto, propõe-se o uso de métricas de textura, conforme apresentado no Item 2.3.2.

### **2.3 Sensoriamento remoto para mapeamento de áreas construídas urbanizadas**

Outra maneira de definir área urbana é diferenciar a cobertura urbana do uso urbano da terra. A cobertura urbana corresponde à condição física da terra, referindo-se apenas ao tipo de cobertura, que pode incluir além de edificações e arruamento (áreas construídas), áreas com vegetação, como parques e praças. Por sua vez, o uso urbano refere-se ao tipo de atividade associada à área física ocupada, podendo ser, por exemplo, atividades industriais, de comércio, habitação ou lazer, como no caso de um parque (BHATTA, 2010).

A cobertura urbana pode ser identificada por dados de SR. Em classificações de imagens, pode-se atribuir a cobertura do pixel urbano como “área impermeável”, “área construída”, ou somente “cobertura urbana”. As coberturas urbanas podem ser constituídas por estruturas construídas, asfalto, concreto, ruas ou calçadas. Ao contrário da cobertura urbana, o uso urbano não pode ser observado somente por SR, tendo em vista que são necessários dados complementares para atestar o uso daquela área, como dados de cadastros imobiliários ou observações de campo (MARTINUZZI; GOULD; RAMOS GONZÁLEZ, 2007).

Neste trabalho, inicialmente propõe-se discriminar as coberturas urbanas da terra a partir de imagens de SR. Para tanto apresenta-se a seguir uma breve revisão de conceitos e técnicas adequados para este fim.

#### **2.3.1 Sensores e plataformas: características e estudos urbanos**

Para a detecção de coberturas urbanas por SR deve-se observar as configurações dos sensores e plataformas e seus respectivos produtos. Resolução espacial, temporal e espectral são as principais propriedades que devem ser levadas em conta para escolha do dado de SR.

Resolução espacial determina o nível de detalhamento que uma imagem poderá resumir, e depende de diferentes propriedades do sensor, como altitude, tamanho do detector, tamanho focal do sensor e configurações do sistema (JENSEN, 2005). Em teoria, apenas objetos maiores que a resolução espacial poderiam ser identificados pelo sensor. Entretanto, feições com tamanho menor que a resolução espacial podem ser detectados quando a refletância deste alvo for muito maior que das feições no entorno, ou quando esta houver uma forma única, como no caso de feições lineares, a detecção de estradas de dimensão menor que a RE (WENG, 2012).

Segundo Jensen e Cowen (1999), o ideal para detectar um objeto de interesse, é que a resolução espacial seja ao menos a metade do tamanho do objeto. Em estudos de alvos urbanos, para detecção das bordas de construções é necessário no mínimo 0,5 metros de resolução espacial, enquanto estradas podem ser detectadas com resolução espacial de 30 metros (JENSEN; COWEN, 1999).

Nos últimos anos, muitos trabalhos têm utilizado sensores com resolução espacial sub-métrica para mapeamentos urbanos (HARTNETT; NASH, 2017; ROY CHOWDHURY; BHADURI; MCKEE, 2018; ZHAO et al., 2019). Isto se deve aos inúmeros satélites lançados na última década e em um novo formato, as constelações de satélites de pequeno porte.

Apesar disso, a disponibilidade e gratuidade desses dados ainda limitam seus usos. A missão *Landsat*, com a maior série histórica de imagens, é o dado mais utilizado em estudos urbanos. A continuidade da missão de mais de 30 anos permite que análises temporais de crescimento urbano sejam realizadas. Essa resolução espacial é suficiente para mapear o crescimento da mancha urbana de cidades (LIU et al., 2020).

Resoluções espaciais mais finas permitem a identificação de bordas de construções e diferenciação de materiais como asfalto, concreto ou diferentes tipos de telhados. Em estudos intraurbanos têm sido empregadas resoluções espaciais menores que 10 metros, como exemplo, imagens do sensor MSI (*Multispectral Scanner*) dos satélites *Sentinel - 2A* e *2B* (ESA, 2016) com 10

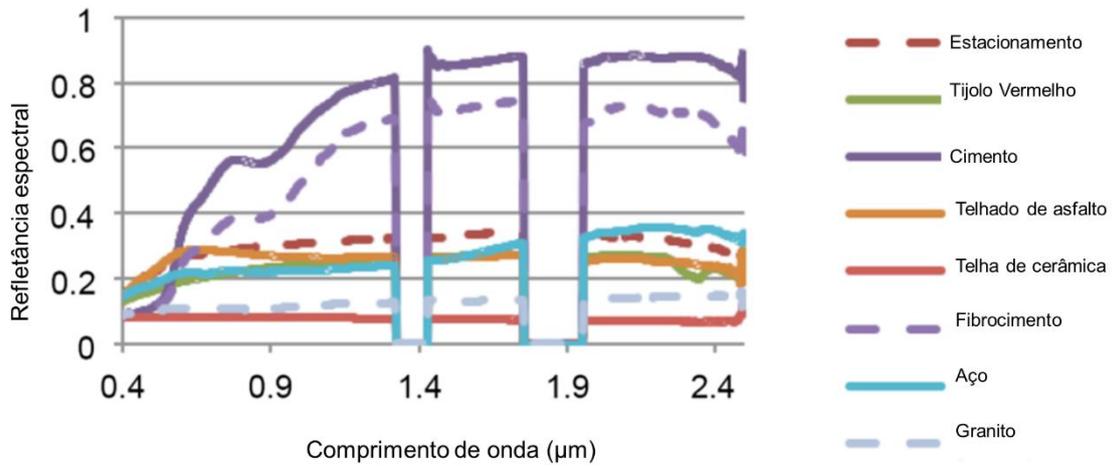
metros de RE (HAAS; BAN, 2017; PRIEM; OKUJENI, 2019; ROSENTERETER; HAGENSIEKER; WASKE, 2020), imagens da plataforma *Ikonos* com bandas de 1 a 4 metros de RE (MESEV, 2005; BHASKARAN; PARAMANANDA; RAMNARAYAN, 2010; ZIGH; BELBACHIR, 2012) ou imagens *Rapideye* com 5 metros de resolução espacial (TIGGES; LAKES; HOSTERT, 2013; LÖW; CONRAD; MICHEL, 2015; AWUAH et al., 2018).

Resolução temporal é definida pelo tempo de revisita de um satélite sobre uma mesma área. Em estudos de crescimento urbano, imagens quinquenais podem ser suficientes para detectar mudanças significativas na cobertura terrestre. Entretanto, para análises de desenvolvimento rodoviário faz-se necessário obter imagens no mínimo a cada dois anos (JENSEN; COWEN, 1999).

O SR de áreas urbanas requer explorar os materiais que compõem a cobertura urbana da terra, para em um segundo momento investigar as relações com seu uso da terra. Para mapear a cobertura, a resolução espectral é também condicionante para a escolha do sensor. O número de bandas espectrais dos sensores úteis para estudos de áreas urbanas varia de poucas bandas (*Landsat*) até sensores com 224 bandas (*Hyperion*). Um grande número de bandas permite a obtenção de mais informações sobre o fenômeno em estudo, e conseqüentemente um detalhamento maior entre as feições, mas ao mesmo tempo dificulta o processamento, exigindo maior capacidade computacional e tempo de processamento (THENKABAIL et al., 2004).

Áreas urbanas apresentam uma notória variedade de materiais, o que aumenta a complexidade na utilização do SR para estudos urbanos. É importante conhecer o comportamento espectral dos diferentes materiais para escolher as bandas espectrais corretas para composição de imagens. A maioria dos materiais urbanos apresentam um pico de reflexão nos comprimentos de onda entre o verde e o NIR (*Near Infrared*). Entretanto, o cimento e telhas de fibrocimento possuem maior reflexão em comprimentos de onda próximo ao SWIR (*Shortwave Infrared*) (Figura 2.1) (BRIOTTET et al., 2017).

Figura 2.1: Comportamento espectral de materiais presente em área urbana.



Fonte: Adaptado de Briottet et al. (2017).

Muitos autores utilizam a composição das bandas NIR (R), vermelho (G) e verde (B) em estudos urbanos (LU et al., 2014, 2014; JIANG et al., 2018). A utilização do NIR permite uma maior distinção entre vegetação e outras feições, tendo em vista que vegetações apresentam maior reflexão no NIR (BRIOTTET et al., 2016).

Em termos de dados livres, atualmente diversos trabalhos são encontrados na literatura utilizando dados da missão *Sentinel-2*. A missão *Sentinel-2* é composta por duas plataformas (*Sentinel-2A* e *Sentinel-2B*) a 786 quilômetros de altitude em órbitas heliosíncronas. As plataformas 2A e 2B possuem a bordo o sensor MSI (*Multispectral instrument*) com 13 bandas espectrais, sendo as bandas R4-G3-B2-NIR-8 com 10 metros de resolução espacial; quatro bandas no vermelho próximo e duas no infravermelho de ondas curtas com 20 metros de resolução espacial, e as bandas aerossol, vapor de água e cirros com 60 metros (ESA, 2016). Para o mapeamento de áreas construídas, é possível encontrar uma diversidade de trabalhos que utilizam dados da missão *Sentinel-2* em diversas partes do mundo. A resolução espacial de 10 metros permite análises intraurbanas com um significativo ganho de precisão, quando comparados com o uso de dados da missão *Landsat* (30 metros) (LÖW; CONRAD; MICHEL, 2015;

HAAS; BAN, 2017; AWUAH et al., 2018; CHAIRET; BEN SALEM; AOUN, 2019; PRIEM; OKUJENI, 2019; TAVARES et al., 2019).

### **2.3.2 Métricas de textura e classificação de imagem**

#### ***Gray Level Co-Occurrence Matrix (GLCM)***

*Gray Level Co-Occurrence Matrix (GLCM)* é um método para representar a textura de imagens a partir de uma matriz de dependência espacial dos níveis de cinza (ou matriz de coocorrência) proposto por Haralick et al. (1973). Cada elemento de uma matriz de coocorrência deve ser entendido como uma medida da probabilidade de que dois valores de nível de cinza, separados por uma distância, em um determinado sentido, ocorram na imagem.

A utilização das feições de texturas podem melhorar a acurácia de classificações entre 4 e 40% (HARALICK; DINSTEIN; SHANMUGAM, 1973; MARCEAU et al., 1990). Lu e colaboradores (2014) aplicaram o GLCM para a cidade de Lucas do Rio Verde – MT, Altamira – PA e Machadinho do Oeste – RO, em imagens *QuickBird*, *Landsat TM* e *SPOT 5 HRG*. Os resultados mostraram ganhos significativos na qualidade do mapeamento com a utilização do GLCM, com os seis tipos de feições (SMA, COM, PVAR, HOM, COR e ENT). Esta metodologia foi relevante para contornar tanto as singularidades provenientes dos diferentes padrões de áreas urbanas, como a semelhanças espectral entre coberturas de cerâmica e solo exposto. O GLCM pode auxiliar na distinção de feições que apresentem nuances em assinaturas espectrais, como alternativa na ausência de imagens hiperespectrais (LU et al., 2014).

Antes de submeter as imagens ao cálculo do GLCM é necessária uma preparação dos dados para que o máximo de informação textural seja extraída. As métricas de textura são calculadas a partir das matrizes de coocorrência de níveis de cinza nos pixels da imagem. Quando a imagem possui elevado nível de quantização (mais de 10 bits) a probabilidade de coocorrência dos níveis de cinza é baixa, gerando matrizes somente com zeros. Clausi (2002), ao analisar a influência dos níveis de quantização na acurácia em classificações texturais a partir de dados de sensores orbitais ativos, observou que a diminuição dos níveis

de quantização das imagens melhora significativamente a acurácia da classificação. Contudo, Soh e Tsatsoulis (1999) advertem que a redução do nível de quantização ocasiona uma perda de informação e que a escolha errada do método de requantização das imagens faz com que essa perda de informação não compense a melhora dos resultados do GLCM.

Existem três principais abordagens para alterar a quantização de imagens, que devem ser ponderadas de acordo com a necessidade e o dado utilizado, a quantização uniforme, a quantização Gaussiana e a quantização de probabilidades iguais. Na quantização uniforme, a mais simples das três, os níveis de cinza são quantizados em intervalos iguais e uniformes sem levar em conta a distribuição dos valores de níveis de cinza da imagem, o que resulta numa maior perda de informação tendo em vista que os valores tendem a ocorrer com maior frequência em determinados intervalos de valores.

A quantização Gaussiana é proposta para mitigar a perda de informação no método uniforme, assumindo a normalidade da distribuição dos valores na imagem. A quantização dos níveis de cinza é feita ponderando a área abaixo da curva da distribuição dos intervalos que os pixels ocupam, porém esta técnica é consideravelmente mais complexa demandando maior capacidade computacional e também assume que a distribuição dos valores seja normal, o que dificilmente ocorre nos dados (SOH; TSATSOULIS, 1999; CLAUSI, 2002).

A quantização de probabilidades iguais também pondera a quantização dos níveis de cinza conforme os intervalos de frequência dos valores, entretanto não assume normalidade da distribuição, os intervalos de valores são determinados estatisticamente de acordo com a frequência de ocorrência dos níveis de cinza (percentis), permitindo uma ponderação mais precisa quantizando os níveis de cinza preservando a real representação da imagem original quanto as feições texturais baseadas no GLCM (HARALICK; DINSTEIN; SHANMUGAM, 1973; CONNERS; TRIVEDI; HARLOW, 1984; SOH; TSATSOULIS, 1999).

## **Random Forest**

Árvores de decisões, um método de mapeamento hierárquico, têm sido amplamente utilizadas para classificação de imagens por SR em análises urbanas (DOS SANTOS SILVA et al., 2008; WENG; LU, 2008), Árvores de decisões são compostas por uma hierarquia de nós, cada nó é um ponto de decisões, ou regras que podem ser definidas pelo analista, a partir do qual o algoritmo identifica se o caminho atende ao requisito do nó (HARDIN; JACKSON; OTTERSTROM, 2007; BHATTA, 2008; WENG; LU, 2008).

*Random Forest* (RF) é uma técnica de *machine learning* desenvolvida por Breiman (2001) que prevê uma floresta de árvores de decisões. Com diferentes dados de entrada, cada árvore de decisão classifica um pixel de acordo com um dado de entrada, após todas as árvores de decisão terem determinado um rótulo para o pixel, a classe mais votada dentre todas as árvores será utilizada para o rótulo final do dado pixel. A classe mais votada é então escolhida para rotular o pixel. Essa técnica melhora significativamente a precisão de classificação quando comparada com árvores de decisões individuais. Diversos autores relataram a precisão do RF para mapeamento de uso e cobertura da terra (LÖW; CONRAD; MICHEL, 2015; BELGIU; DRĂGU, 2016; TAVARES et al., 2019; YOO et al., 2019; ROSENTERETER; HAGENSIEKER; WASKE, 2020).

Segundo Hastie et al. (2009), RF é uma modificação do *bagging*<sup>6</sup>, que após a construção de diversas árvores não correlacionadas calcula a média delas. De uma forma simplificada, RF precisa de um número definido de árvores e um número definido de feições ou preditores para cada nó.

Uma vantagem do RF é a existência de uma medida estatística de acurácia, para isso o algoritmo utiliza amostras chamadas de “*out-of-bags*” (OOB). Durante o processo de seleção das amostras de treinamento um grupo de amostras é selecionada para o teste do modelo, resultando em um ranqueamento de qual fonte de dado melhor classifica cada classe (BREIMAN, 2001).

---

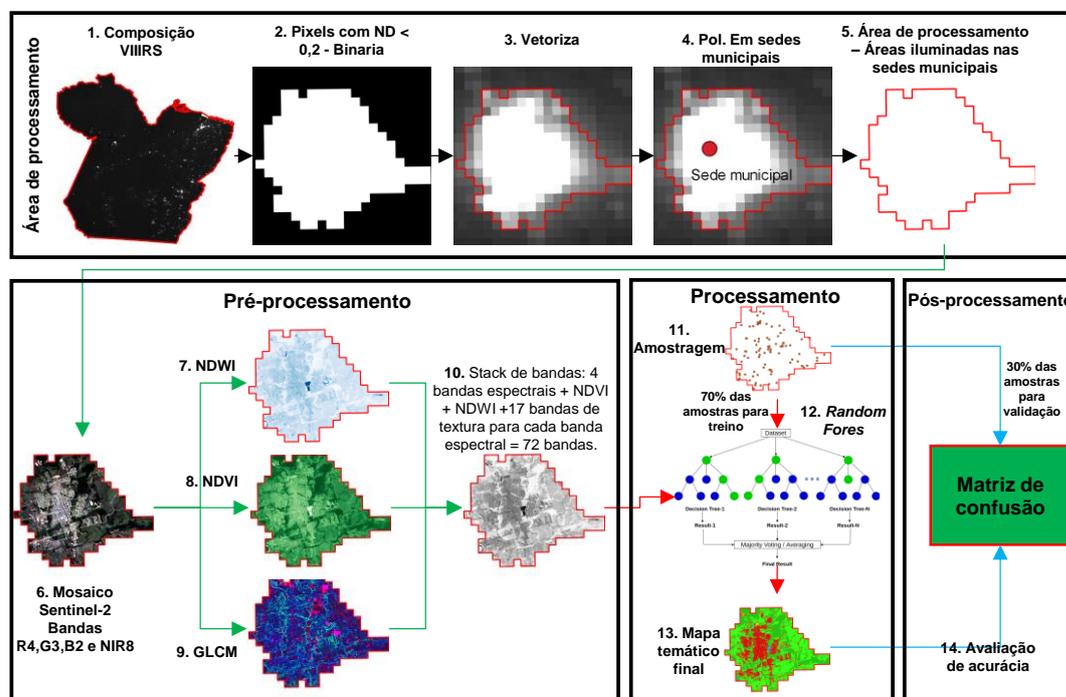
<sup>6</sup> Mais detalhes sobre a metodologia *bagging* em Hastie et al. (2009).

O RF é composto por uma floresta de árvores de decisão, onde cada árvore é um modelo, e o resultado da predição é obtido por meio da soma do total de votos de qual classe a feição pertence. Para evitar a alta correlação entre as árvores, o RF faz o uso do *Bootstrapping*, ou seja, seleção aleatória e com reposição das amostras. Para cada árvore de decisão faz-se um *Bootstrapping*, diminuindo o conjunto de dados e eliminando a correlação entre as árvores. Ou seja, cada árvore possui um subconjunto de amostras diferentes e reduzido. Esse procedimento também acelera o processo de treinamento e diminui a possibilidade de *overfitting* (BREIMAN, 2001; HASTIE; TIBSHIRANI; FRIEDMAN, 2009). Por estas funcionalidades, o RF atende às características dos dados a serem utilizados nesta metodologia.

### 3 METODOLOGIA

Os procedimentos foram organizados em quatro etapas, conforme sintetizado na Figura 3.1. Para desenvolver e testar a metodologia, adotou-se o estado do Pará como recorte espacial, e o ano de 2020 como referência temporal. Definiu-se a área de processamento, a partir das áreas iluminadas do sensor VIIRS (*Visible infrared imaging radiometer suite*) e das coordenadas geográficas de seis sedes municipais.

Figura 3.1. - Fluxograma geral de etapas para construção da metodologia de identificação de áreas construídas em cidades amazônicas.



Na etapa seguinte, de pré-processamento, imagens Sentinel-2 (S2) foram obtidas para o recorte definido, a partir das quais foram calculados índices biofísicos: uma banda de NDVI e outra de NDWI. As imagens foram então requantizadas e métricas de textura, através de matriz de coocorrência (GLCM), foram computadas para cada banda espectral (R4-G3-B2-NIR8) do S2 utilizada.

Na etapa de Processamento, realizou-se a classificação supervisionada por pixel, por meio do algoritmo *Random Forest* para discriminar as classes Áreas

Construídas, Solo exposto, Vegetação Arbórea, Vegetação Herbácea e Água. Como produto desta etapa tem-se um mapa temático de cinco classes. Por fim, realizou-se a avaliação da acurácia do mapeamento a partir de matrizes de confusão construídas utilizando parte das amostras de treinamento separadas a priori para validação do modelo.

Toda metodologia foi desenvolvida em linguagem de programação *Python* através da plataforma *Google Earth Engine*<sup>7</sup> (GEE) *Python API*<sup>8</sup>, buscando atender as particularidades amazônicas. O código desenvolvido encontra-se disponível em: <<https://github.com/gabpcrivellaro/AmazonBuiltUp>>. Esta estratégia foi adotada de modo a não se restringir o processamento em nuvens ou computadores de alta capacidade. A metodologia foi planejada e desenvolvida buscando a possibilidade de ser replicável para qualquer cidade da Amazônia Brasileira. Os itens seguintes apresentam a área de estudo e o detalhamento das etapas propostas.

### **3.1 Área de estudo**

Ainda que este trabalho pretenda contribuir para as cidades da Amazônia Legal, seis cidades do estado do Pará foram selecionadas como área de estudo para desenvolvimento e teste dos procedimentos. O estado do Pará, com 1.248.000 km<sup>2</sup>, abrange 23% da área da Amazônia Legal (AL) e é o estado mais populoso da Região Norte. Em 2010, o Censo de 2010 registrou 7.581.051 habitantes (IBGE, 2010a) no Pará, e em 2019 foram estimados 8.602.865 habitantes, com cerca de 69% dessa população residindo em áreas urbanas (5.191.559 habitantes) (IBGE, 2019). O Pará também se destaca na AL por sua economia, contribuindo com cerca de 40% no PIB da região Norte (FUNDAÇÃO AMAZÔNIA DE AMPARO A ESTUDOS E PESQUISAS DO PARÁ, 2017).

O Pará apresenta-se como um mosaico de formas socioespaciais diversas e de arranjos territoriais derivados de projetos de colonização, populações

---

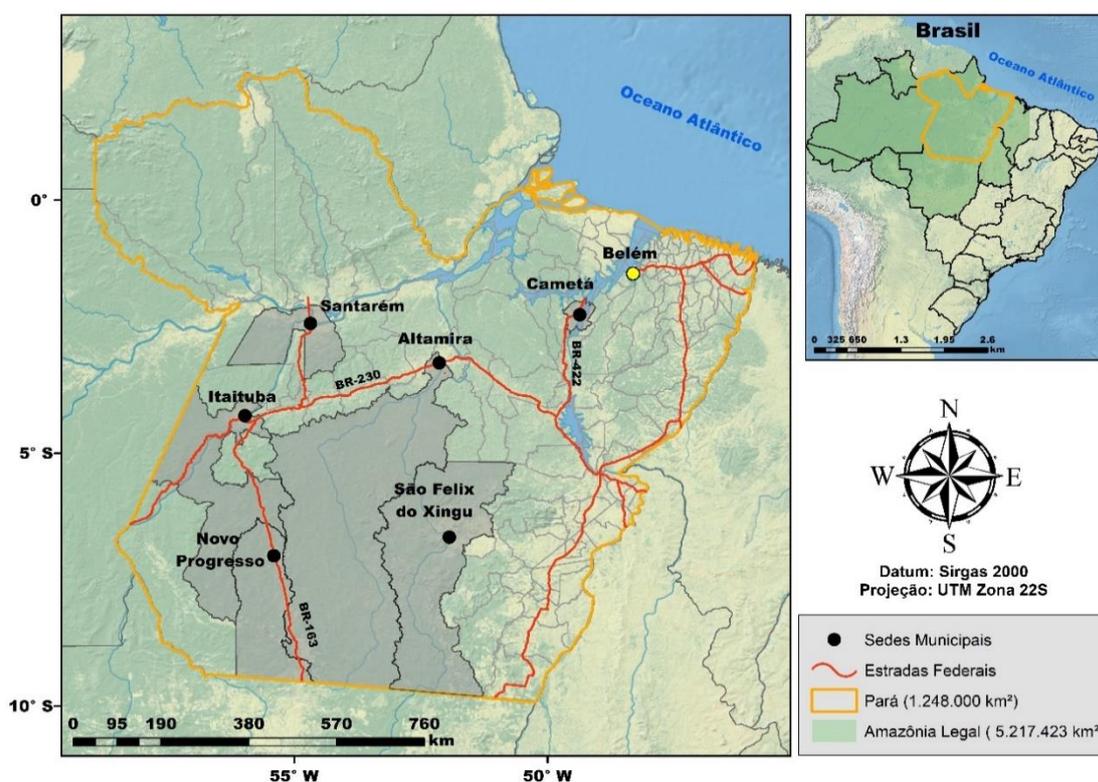
<sup>7</sup> [https://developers.google.com/earth-engine/guides/python\\_install](https://developers.google.com/earth-engine/guides/python_install)

<sup>8</sup> *Application Programming Interface*

tradicionais, ribeirinhos, unidades de conservação, assentamentos rurais, cidades e uma importante capital, até grandes projetos minerários e de infraestrutura, e núcleos garimpeiros (MACHADO, 1999). Há uma variedade de atores e estratégias para sua integração às estruturas econômicas regionais, nacionais e internacionais (INPE, 2011). Ao mesmo tempo, o estado lidera as taxas de desmatamento na Amazônia legal desde 2006 atingindo 11.080 km<sup>2</sup> de taxa em 2020 (INPE, 2019a). Por sua importância e complexidade, tem-se no estado do Pará uma amostra da heterogeneidade da Amazônia, que demanda por informações e estudos para a discussão de modelos de desenvolvimento ajustados ao estado e suas cidades.

Neste trabalho, a metodologia de mapeamento deve ser suficiente para a classificação de todas as sedes municipais do estado do Pará. Contudo, para desenvolver a metodologia, testar e avaliar o desempenho dos resultados, seis cidades foram selecionadas: Cametá, Santarém, Itaituba, Altamira, Novo Progresso e São Félix do Xingu (**Erro! Fonte de referência não encontrada**). Figura 3.2 - Localização da área de estudos, e das sedes municipais utilizadas para avaliação dos resultados no estado do Pará, Amazônia Legal, Brasil. (Figura 3.2). Esta escolha teve como critério inicial selecionar cidades inseridas em diferentes contextos socioespaciais, para as quais tem-se algum conhecimento de campo, a partir de expedições anteriores (PINHO et al., 2010; DAL'ASTA et al., 2017; SOUZA et al., 2021) realizadas pelos pesquisadores do Laboratório de investigações em Sistemas Socioambientais (LISS – INPE).

Figura 3.2 - Localização da área de estudos, e das sedes municipais utilizadas para avaliação dos resultados no estado do Pará, Amazônia Legal, Brasil.



Fonte dos dados: Limites geopolíticos e pontos de sedes municipais – IBGE<sup>9</sup>; Estradas – DNIT<sup>10</sup>; Basemap – Natural Earth Basemap<sup>11</sup>.

Um segundo critério buscou municípios representativos das categorias identificadas por Ribeiro et al. (2018) quanto às dinâmicas de urbanização, capturadas pelas medidas de evolução de população e áreas urbanas, e de desmatamento recentes observadas nos municípios paraenses. Os autores agruparam os municípios paraenses em quatro grupos. Do grupo I – municípios com menor variação nas áreas urbanas e baixo desmatamento- foi escolhido o município de Cametá, integrante da Região do Baixo Tocantins. Do grupo II - municípios com variação intermediária do desmatamento e crescimento de áreas urbanas - foram escolhidos os municípios de Santarém e Itaituba, representantes

<sup>9</sup> <https://www.ibge.gov.br/geociencias/downloads-geociencias.html>

<sup>10</sup> <http://servicos.dnit.gov.br/vgeo/>

<sup>11</sup> <https://www.naturalearthdata.com/downloads/>

de cidades que se desenvolveram às margens do rio Tapajós. Do grupo III - municípios com alto índice de desmatamento e crescimento urbano - foram escolhidos os municípios de Altamira, cidade ribeirinha do Xingu com transformações decorrentes da construção da BR-230 (Transamazônica) e, mais recentemente, da construção da hidroelétrica de Belo Monte; e Novo Progresso, cidade recente sob influência da dinâmica associada a BR-163 (Cuiabá-Santarém). São Félix do Xingu, único representante do grupo IV, caracterizado pelas altas taxas de desmatamento, baixo crescimento urbano e intensa atividade pecuária, também foi incluído nesta análise.

O último fator considerado na escolha dos municípios foi a variabilidade da urbanização da população: os municípios escolhidos possuem diferentes contingente populacionais, taxas de crescimento e proporções de população urbana e rural. Entre 2010 e 2020, das as seis cidades analisadas, Santarém, Itaituba e Novo Progresso apresentaram as menores taxas de crescimento e possuem proporções de população urbana semelhantes. Altamira, por sua vez, é o município com a maior proporção de população urbana, enquanto Cametá apresenta a menor proporção

Tabela 3.1 - Composição populacional em 2010 (Censo) e 2020 (estimativa), para cidades selecionadas na área de estudo.

Município	População - Censo 2010				População - Estimativa 2020 <sup>12</sup>			Taxa de crescimento
	Urbana	Rural	Total	Grau de Urbanização	Urbana	Rural	Total	
<b>Santarém</b>	215790	78790	294580	73,25%	224507	81973	306480	3,88%
<b>Itaituba</b>	70682	26811	97493	72,50%	73511	27884	101395	3,85%
<b>Novo Progresso</b>	17717	7407	25124	70,52%	18170	7596	25766	2,49%
<b>Altamira</b>	84092	14983	99075	84,88%	98431	17538	115969	14,57%
<b>Cametá</b>	58838	68058	126896	46,37%	64619	74745	139364	8,95%
<b>São Félix do Xingú</b>	45113	46227	91340	49,39%	65263	66875	132138	30,88%

Observação: Devido à ausência da informação, a população urbana e rural de 2020 foi estimada com base no grau de urbanização observado no censo de 2010.

Fonte: IBGE (2010a; 2020).

### 3.2 Dados

Foram utilizados dados de SR orbital e dados cartográficos vetoriais (Tabela 3.2). Todas as bases de dados utilizadas são de acesso aberto e foram escolhidas em função da disponibilidade e adequação em cada etapa do desenvolvimento.

Imagens de luzes noturnas do sistema **VIIRS** (*Visible infrared imaging radiometer suite*) a bordo do *Suomi National Polar-orbiting Partnership* (**SNPP**) foram utilizadas para identificar áreas indicadoras potenciais de superfícies urbanizadas (AMARAL et al., 2005). A banda Day Night Band (DNB) do sensor VIIRS detecta baixos níveis de radiância provenientes de atividades antrópicas, como iluminação urbana, e fontes efêmeras, como queimadas. O sensor possui resolução espacial de 742 metros, reamostrada para 500 metros, quantização de 14 bits e sensibilidade na ordem 10-11 W/cm<sup>2</sup>/sr/μm, faixa de imageamento de 3.000 km, órbita polar a uma altitude de 827 km, e amplitude espectral de baixa intensidade de 0,5 a 0,9 μm (ELVIDGE et al., 2013). Foi utilizado foi o produto VIIRS Nighttime Day/Night Band Composites Version 1 (vcmcf),

<sup>12</sup> <https://www.ibge.gov.br/estatisticas/sociais/populacao/9103-estimativas-de-populacao.html?=&t=resultados>

referente a uma composição mensal livre de nuvens, dos efeitos de radiação lunar e de raios. Porém, este produto contém fontes de iluminação estáveis (cidades) e efêmeras (fogo, aurora boreal e etc.), uma vez que as composições mensais estáveis não estavam disponíveis para o ano de 2020 quando da aquisição dos dados para a execução deste trabalho. Assim, foi necessário realizar um processamento para remover a presença de pixels com fontes de iluminação efêmeras, descrito no Item 3.3.1.

Para identificar as sedes municipais dentre todas as áreas iluminadas detectadas pelos dados VIIRS, foi utilizado o arquivo vetorial multiponto de sedes municipais fornecido pelo IBGE (2019).

Para análise e interpretação visual dos resultados e eventuais aferições de erros nos produtos finais, foram utilizadas imagens do sensor WPM a bordo da plataforma orbital CBERS-4A. As imagens possuem resolução espacial nativa de 8 metros nas bandas espectrais (B1-G2-R3-NIR4) e uma banda pancromática de 2 metros de resolução espacial. Assim as imagens foram acessadas para todas as seis sedes municipais para o ano de 2020 livre de nuvens e então submetidas ao procedimento de fusão (*Pan-sharpening*) para agregar as informações espectrais das bandas azul, verde e vermelho à banda pancromática, resultando em imagens com composição de cores verdadeiras com 2 metros de resolução espacial. A metodologia utilizada para fusão foi o IHS (*Intensity, hue and saturation*) (ZHENG et al., 2017), as imagens foram carregadas no *assets* do GEE criando uma *Image Collection*, em seguida um algoritmo<sup>13</sup> foi desenvolvido para submeter as imagens ao procedimento de fusão referido, ao final as mesmas foram exportadas para o google drive para que pudessem ser utilizadas em um sistema de informações geográficas.

---

<sup>13</sup> [https://github.com/gabpcrivellaro/AmazonBuiltUp/blob/main/pan\\_sharp.ipynb](https://github.com/gabpcrivellaro/AmazonBuiltUp/blob/main/pan_sharp.ipynb)

Tabela 3.2 – Síntese dos dados utilizados e suas características básicas.

Dado/Tipo	Bandas	Resolução	Característica/produto	Data	Fonte	Finalidade
Imagem SNPP/VIIRS	DayNightBand (DNB)	500m	Composição mensal (vcmcfg)	2020	NASA <sup>14</sup>	Identificar áreas de atividade humana
Imagem Sentinel-2 (S2)	R4, G3, B2, NIR8	10m	Composição de pixels livre de nuvens	2020	ESA <sup>15</sup>	Classificação das coberturas nas áreas iluminadas
Imagem CBERS-4A - WPM	R3, G2, B1 e PAN - 0	2 m (Fusionada)	Sensor WPM L4A	2020	INPE <sup>16</sup>	Imagem de referência para análise de resultados
Vetor - sedes municipais	NA	NA	Ponto	2019	IBGE <sup>17</sup>	Selecionar as áreas iluminadas das sedes de município

Para a classificação da cobertura do solo foram utilizadas imagens da missão Sentinel-2 A e B (S2), considerando-se todas as bandas reflexivas de 10 metros de resolução espacial (Vermelho (B04), Verde (B03), Azul (B02) e Infravermelho Próximo (B08)), descritas na Tabela 3.3. Um mosaico com pixels livres de nuvens foi construído para o ano de 2020, a partir do acervo de imagens S2 de refletância da superfície (RS) disponível no *Google Earth Engine*. A partir da biblioteca *Sentinel2-cloud-detector*, a probabilidade de presença de nuvens (0 – 100%) é determinada para cada pixel das bandas do S2. Pixels com probabilidade superior a 30% foram removidos do mosaico, e pixels com a menor probabilidade de ocorrência de nuvens foram escolhidos para compor o mosaico final

<sup>14</sup> [https://developers.google.com/earth-engine/datasets/catalog/NOAA\\_VIIRS\\_DNB\\_MONTHLY\\_V1\\_VCMCFG](https://developers.google.com/earth-engine/datasets/catalog/NOAA_VIIRS_DNB_MONTHLY_V1_VCMCFG)

<sup>15</sup> [https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS\\_S2\\_SR](https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2_SR)

<sup>16</sup> <http://www2.dgi.inpe.br/catalogo/explore>

<sup>17</sup> <https://www.ibge.gov.br/geociencias/downloads-geociencias.html>

Tabela 3.3 - Bandas espectrais dos satélites Sentinel 2A e 2B utilizadas.

Banda	Faixa espectral (nm)	
	2A	2B
<b>Azul – B2</b>	459,4 - 525,4	459,1 - 525,1
<b>Verde – B3</b>	543,3 - 576,3	543,0 – 576,0
<b>Vermelho – B4</b>	648,1 - 679,1	647,8 - 678,8
<b>NIR – B8</b>	779,8 - 882,8	779,7 - 882,7

Fonte: ESA (2016).

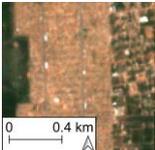
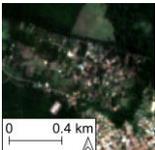
### 3.3 Definição das classes de interesse

Considerando o exposto na Seção 1.2, este trabalho busca mapear as áreas construídas existentes nas sedes municipais das seis cidades escolhidas. Para o contexto amazônico, esse conceito engloba tanto as edificações e infraestruturas urbanas quanto feições e coberturas do solo naturais associados à estrutura urbana, como áreas de vegetação ou solo exposto. Predominantemente nestas cidades, as edificações possuem telhados de material cerâmico e arruamento sem pavimentação, ou seja, ruas de terra, semelhantes a coberturas de solo exposto (DAL'ASTA et al., 2012; GONÇALVES et al., 2018; AMARAL et al., 2019). Assim, para mapear as áreas construídas das cidades amazônicas, propõe-se a distinção de cinco classes de cobertura da terra, passíveis de identificação em imagens de média resolução espacial (10m), presentes em sedes municipais e nas suas proximidades, conforme sintetizado na Tabela 3.4.

Considerando o exposto na Seção 1.2, este trabalho busca mapear as áreas construídas existentes nas sedes municipais das seis cidades escolhidas. Para o contexto amazônico, esse conceito engloba tanto as edificações e infraestruturas urbanas quanto feições e coberturas do solo naturais associados à estrutura urbana, como áreas de vegetação ou solo exposto. Predominantemente nestas cidades, as edificações possuem telhados de material cerâmico e arruamento sem pavimentação, ou seja, ruas de terra, semelhantes a coberturas de solo exposto (DAL'ASTA et al., 2012; GONÇALVES et al., 2018; AMARAL et al., 2019). Assim, para mapear as áreas construídas das cidades amazônicas, propõe-se a distinção de cinco classes de

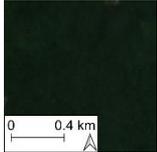
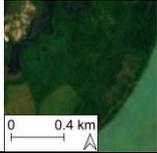
cobertura da terra, passíveis de identificação em imagens de média resolução espacial (10m), presentes em sedes municipais e nas suas proximidades, conforme sintetizado na Tabela 3.4.

Tabela 3.4 - Classes de coberturas urbanas para caracterizar a área urbanizada construída de cidades amazônicas.

Classe	Descrição Geral	Exemplos (Imagens Sentinel- 2 - R4-G3-B2)	
Área Construída (AC)	Edificações comerciais, residenciais e industriais; Arruamento definido, incluindo ruas pavimentadas, com calçamento ou não-pavimentadas (ruas de terra).	Áreas Centrais, de urbanização antiga e consolidada: Grande variabilidade de respostas espectrais, devido à presença de diferentes materiais utilizados nas coberturas e pavimentação.	
		Áreas residenciais: Arruamento definido, com ou sem pavimentação; Tamanho de quadras e lotes regulares; Homogeneidade nas quadras, em função da predominância de telhados de material cerâmico	
		Áreas de expansão: Arruamento definido; Ruas ainda sem pavimentação; Quadras com pouca ou nenhuma edificação, e presença de vegetação herbácea ou solo exposto.	
		Franja rural-urbano: Zona de transição entre o urbano e rural; Muita heterogeneidade de respostas espectrais, pela diversidade de coberturas; Ausência de regularidade no arruamento e padrão construtivo; Vegetação arbórea e arbustiva presentes.	
		Áreas aparentemente sem uso definido: Áreas de expansão urbanas em fase inicial, de deslizamento de terra, ou de movimentação de solo; Regiões com maior homogeneidade nos níveis de cinza.	
		Solo Exposto (SE)	Áreas extensas de cobertura de solo exposto;  Solo Preparado para construção, praias, banco de areia em rios, mineração e áreas de pousio.
Mineração: Áreas de garimpo ou mineração industrial. Porções extensas de solo exposto, bordas indefinidas, usual observar terraços ou níveis de terra movimentada.			
Solo exposto para atividade agrícola, ou áreas de pousio: Áreas extensas sem vegetação, após a colheita ou preparada para plantio; São áreas espectralmente homogêneas, usualmente de limites regulares.			

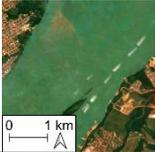
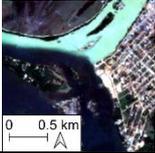
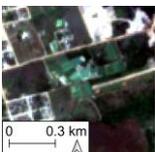
continua

Tabela 3.4 – Continuação.

Classe	Descrição Geral	Exemplos (Imagens Sentinel-2 - R4-G3-B2)	
Vegetação Arbórea (VA)	Coberturas com Vegetação de estrutura predominantemente arbórea;  Floresta primária, secundária, vegetação arbustiva, e arborização urbana.	Floresta Primária (sem degradação aparente): Áreas coberta por vegetação arbórea densa, sem contribuição de solo, espectralmente homogênea, e de limites irregulares;	
		Floresta Secundária: Áreas de vegetação florestal em que se observam alterações na estrutura do dossel e contribuição de resposta do solo. Apresentam maior heterogeneidade espectral que as áreas de floresta "primária".	
		Mata ciliar: Vegetação ao longo dos cursos d'água, constituindo as áreas de preservação permanente (APP); Vegetação de estrutura variada - arbórea, arbustiva e herbácea.	
		Arborização urbana: Vegetação arbórea presente nas ruas, lotes, parques ou APPs;	
Vegetação Herbácea (VH)	Coberturas com Vegetação de estrutura predominantemente herbácea;  Vegetação rasteira/gramíneas naturais, áreas de pastagens, áreas de cultivo agrícola (trigo, soja, aveia etc.).	Gramíneas: Gramados, campos de futebol, cobertura de lotes; Áreas em recuperação natural ou sem uso definido; Resposta espectral homogênea.	
		Pastagens: Áreas extensas, cobertura de gramíneas, alguma contribuição do solo; Resposta espectral homogênea	
		Campos naturais: Áreas naturalmente sem cobertura florestal, de estrutura herbácea-arbustiva; Podem ter contribuição da resposta do solo;	
		Cultivos Agrícolas: Extensas áreas cobertas por culturas que cobrem o solo, como soja, trigo e outras culturas perenes; Resposta espectral homogênea; baixo contraste	

continua

Tabela 3.4 – Conclusão.

Classe	Descrição Geral	Exemplos (Imagens Sentinel- 2 - R4-G3-B2)	
Água (AG)	Áreas cobertura por corpos d'água de diferentes naturezas;  Rios, lagos, tanques de piscicultura, barragens, etc.	Rios: Resposta espectral homogênea;	
		Rios com águas de diferentes características físicas: Áreas de encontro de afluentes;	
		Lagos: Corpos d'água de limite definido e restrito; Resposta espectral usualmente homogênea.	
		Piscicultura: Tanques de criação de peixe; Corpos d'água usualmente retangulares, de pequena dimensão (2 a 5 pixels S2), e agrupados; Resposta espectral variável entre os tanques	

A classe “Área Construída” (AC), ou “*Built Up*” na literatura internacional, é a classe usualmente utilizada para mapeamentos de áreas urbanas (OUYANG et al, 2019; TRIPATHY & KUMAR, 2019; GOLDBLATT et al, 2016; BHATTA et al., 2010; ANGEL & CIVCO, 2007). Ao mensurar a área construída no espaço das cidades, essa classe subsidia estudos para diferentes aplicações, tais como: aumento da temperatura urbana e formação de ilhas de calor (SVENSSON e ELIASSON, 2002; RADHI et al., 2013); crescimento urbano (IANOŞ et al., 2016; TRIPATHY; KUMAR, 2019); espalhamento urbano (ANGEL; PARENT; CIVCO, 2007); desigualdade social e alteração da biodiversidade (COHEN et al., 2012); estimativas populacionais (ALAHMADI; ATKINSON; MARTIN, 2016); exposição a desastres naturais (CHEN; XIE; XU, 2019), delimitação da mancha urbana (GOLDBLATT et al., 2016) dentre outras aplicações. Nestes trabalhos, o termo “áreas construídas” é utilizado como uma generalização de feições urbanas como arruamentos urbanos e edificações, usualmente associadas a superfícies impermeabilizadas.

Para que o termo AC possa se referir à descrição da área urbanizada das cidades amazônicas, para por exemplo auxiliar na definição da mancha urbana,

ou compor uma métrica de área urbana, a AC deve incluir também as superfícies permeáveis que estruturam as cidades. Como descrito anteriormente, a alta frequência de arruamentos não pavimentados é uma característica dessas cidades. A não inclusão destas áreas ocultaria grande parte da infraestrutura urbana, resultando em uma métrica que não representaria a realidade do espaço urbano local.

Neste trabalho, a classe áreas construídas engloba superfícies permeáveis (SP) e impermeáveis (SI). Dentre as feições que compõem o grupo de SP estão as ruas de solo exposto, mais frequentes nas áreas periféricas ao centro comercial, em áreas de expansão urbana (loteamentos) e em regiões de franja rural-urbano (áreas onde feições urbanas e rurais se fundem marcando uma zona de transição). As SI correspondem aos demais elementos, como arruamentos ou espaços pavimentados (estacionamentos, pátios, praças), e as construções, como casas, edifícios, galpões, indústrias ou comércio, com coberturas (telhado) de materiais diversos, como cerâmica, fibrocimento, zinco ou concreto. Dentre as diferentes coberturas que fazem parte da classe AC, existem diferentes padrões texturais.

A classe “Solo exposto” (SE) corresponde a uma cobertura que pode estar associada a diferentes usos do solo, tais como: áreas de extração e movimentação de terra para uso na construção civil, áreas preparadas para agricultura ou pecuária, ou ainda áreas naturais, como em campos onde a contribuição do solo predomina sobre a vegetação. Áreas de mineração, em geral com limites de geometrias não lineares (amorfa), também estão inclusas nessa classe. No espaço das cidades, a classe SE é comum nas áreas de expansões urbanas.

A classe “Vegetação Arbórea” (VA) corresponde a áreas com cobertura de vegetação arbórea. Esta classe, no interior das cidades, corresponde às áreas de remanescentes florestais, matas galerias, arborização urbana, vegetação arbórea periurbana e no interior dos lotes. A classe VA é usualmente mais frequente em regiões da cidade de menor adensamento construtivo, como franjas rural-urbanas e outras áreas de expansão.

A classe “Vegetação Herbácea” (VH) corresponde a áreas com cobertura de vegetação herbácea arbustiva, que podem ser de origem natural ou antrópica. Além dos campos naturais, há VH em áreas de várzea, ilhas ou próximas aos rios. Nas cidades, VH é usualmente encontrada, além dos gramados urbanos, nas áreas de expansão urbana, de baixo adensamento construtivo ou em lotes vagos. Nesta classe, incluem-se também áreas de uso com pastagens e culturas agrícolas.

A classe “Água” (AG) corresponde aos corpos d’água, como rios e lagos. Cinco das seis cidades analisadas são ribeirinhas (exceção Novo Progresso). Além disso, é comum a presença de lagos e tanques de piscicultura no interior ou entorno imediato de todas as cidades.

### **3.4 Procedimentos metodológicos**

#### **3.4.1. Delimitação da extensão geográfica para o processamento e classificação**

Áreas iluminadas identificadas a partir de sensores orbitais de imageamento noturno são associadas à presença de ocupação humana (ELVIDGE et al., 2013; XIE; WENG; FU, 2019) também na Amazônia (AMARAL et al., 2005; ELVIDGE et al., 2013; XIE; WENG; FU, 2019). Portanto, dados de luzes noturnas da banda *Day/Night Band* do sensor VIIRS foram utilizados para limitar a extensão geográfica de interesse às áreas associadas à presença de atividades humanas, a partir do centro das sedes municipais, reduzindo o volume de dados para o processamento.

A utilização das imagens de luzes noturnas para restringir a área a ser processada garante a inclusão de áreas urbanizadas periféricas, ainda que de menor iluminação. No caso, tanto a resolução espacial do sensor VIIRS (500 m), quanto o efeito de *overflow* causam polígonos de luzes ampliados em torno de ocupações humanas (AMARAL et al., 2005; ELVIDGE et al., 2013; XIE; WENG; FU, 2019). Ou seja, a reflexão e retroespalhamento da radiação pode resultar no registro de níveis de radiância onde não há fontes de luzes noturnas (ELVIDGE et al., 2013). Este efeito é mais intenso em áreas próximas a espelhos

d'água e áreas com alto albedo, ou quando nuvens pouco espessas sobrepõem a região imageada (IMHOFF et al., 1997). Assim, os polígonos de luzes resultantes deste dado correspondem a uma máscara que abrange todas as áreas urbanizadas consolidadas e áreas de ocupação mais esparsa, como bairros de sítios, novos loteamentos com baixa ocupação e vazios urbanos, comuns nas franjas urbanas.

A partir das composições mensais livres de nuvens nos meses mais secos de 2020 (maio a outubro) calculou-se a radiância média no período por pixel para todo estado do Pará. Em seguida, utilizando como limiar o valor de 0,8 nanoWatts.cm<sup>-2</sup>.sr<sup>-1</sup> (definido empiricamente), gerou-se uma imagem binária, onde os pixels de valor maior que o limiar receberam o valor 1 e os demais, 0. Esse procedimento eliminou extensas áreas de floresta, agricultura e rios, não associadas à presença de atividades humanas. Esta imagem binária, foi submetida a uma vetorização, obtendo-se 7.273 polígonos indicativos de ocupação e presença humana.

Para selecionar apenas as áreas iluminadas correspondentes às sedes dos municípios, foi criado um algoritmo para a seleção automática dos polígonos que intersectam o ponto da coordenada geográfica das seis sedes municipais (IBGE, 2017). Desta forma, pode-se indicar quais locais deverão ser mapeados, a partir de pontos com as coordenadas de referência. Outras áreas de interesse com concentrações populacionais, como comunidades, vilas e localidades, poderão também ser no futuro selecionadas a partir deste procedimento.

Tendo-se restringido a área de interesse, imagens Sentinel-2 foram acessadas para a classificação. A frequente cobertura de nuvens da região amazônica, dificulta e, em alguns casos, impossibilita a aquisição de imagens livres de nuvens ao longo do ano. Para contornar esta dificuldade, optou-se pela criação de um mosaico com pixels livres de nuvens adquiridos em diferentes datas em uma janela temporal definida.

A partir do produto *S2 Cloud Probability* (RICHTER, 2017), disponibilizado pelo programa Copernicus da Agência Espacial Europeia e implementado no GEE, obteve-se a probabilidade de presença de nuvens para cada pixel. Um limiar de

probabilidade máxima de 30% foi definido. O período de 01/01/2020 a 31/12/2020 corresponde ao intervalo temporal para seleção dos pixels que intersectaram os polígonos de áreas iluminadas, obtendo-se seis mosaicos de pixels livres de nuvens (um para cada sede municipal), para as quatro bandas de 10 metros de resolução espacial do Sentinel-2 (Azul, Verde, Vermelho e Infravermelho Próximo) com nível 2A de processamento (Refletância da superfície).

### 3.4.2. Pré-processamento das imagens Sentinel-2

A etapa de pré-processamento consiste na criação das variáveis utilizadas como entrada no algoritmo Random Foresta (RF). Além das 4 bandas espectrais (R4-G3-B2-NIR8) do sensor MSI a bordo do Sentinel-2, foram utilizados índices biofísicos (NDVI e NDWI) e métricas de textura.

#### 3.4.2.1 Índices biofísicos

A partir das imagens Sentinel geradas na etapa anterior, outros dados (bandas) foram produzidos a partir de expressões algébricas para subsidiar o processo de classificação. O NDVI (*Normalized difference Vegetation Index*) foi incluído para auxiliar a distinção entre as classes de vegetação (VA e VH). O NDWI (*Normalized Difference Water Index*) para a distinção de corpos d'água (AG) (LI; GONG; LIANG, 2015; TELUGUNTLA et al., 2018; THITAWADEE; YOSHIHISA, 2018).

O NDVI, como a maioria dos índices de vegetação, é obtido a partir das bandas do Infravermelho próximo (NIR) e vermelho (RED), e é dado por:

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (3.2)$$

Na imagem NDVI, os pixels terão valores entre -1 a 1, onde: valores negativos próximo a -1 representam nuvem, neve e areia; valores entre -0,1 e 0,1 representam rocha, solo exposto e áreas construídas; valores entre 0,1 a 0,5

correspondem a vegetação arbustiva ou herbácea; e valores maiores que 0,6 indicam a presença de florestas densas (ROUSE et al., 1974).

O NDWI é uma razão da diferença entre as bandas na região do verde (GREEN) e do infravermelho próximo (NIR), e sua equação é:

$$NDWI = \frac{GREEN - NIR}{GREEN + NIR} \quad (3.3)$$

A imagem NDWI resultante possui pixels com valores entre -1 e 1. Pixels com valores negativos e próximos a 0 representam áreas sem presença de água, pixels com valores de até 0,2 representam solo úmido e pixels com valores maiores que 0,2 são compostos por água. Quanto mais próximo a 1, menor a presença de sedimentos, algas ou macrófitas (GAO, 1996; MCFEETERS, 1996).

#### **3.4.2.2. Bandas de informações texturais a partir de GLCM**

Sabendo-se que o método de quantização equivalente degrada demasiadamente as informações da imagem (SOH E TSATSOULIS, 1999) e o método Gaussiano pressupõe normalidade da distribuição dos valores (CLAUSI, 2002), o método escolhido foi a quantização de igual probabilidade. Este método normaliza o brilho dos pixels (SOH; TSATSOULIS, 1999), fazendo com que feições de alto e baixo albedo com mesma textura (ex.: rua de solo exposto e asfalto) tenham a mesma matriz de coocorrência, permitindo ao classificador diferenciar uma rua de solo exposto de uma área natural de solo exposto, ou até mesmo de telhados cerâmicos. O método foi implementado em Python na plataforma GEE. Testes indicaram notória melhora na qualidade das bandas de texturas com uma representação mais precisa das feições texturais em relação ao método uniforme.

A definição do nível de quantização ao qual as imagens seriam submetidas baseou-se tanto nos resultados de Hallada e colaboradores (1982), como em testes empíricos que avaliaram a relação da acurácia de classificação com os níveis de quantização, resolução espacial do sensor e tamanho da janela utilizada para construir a matriz de coocorrência. Os referidos autores

constatarem que o limite para evitar a perda de informações em uma imagem com resolução de 30 metros não deve ser menor que 16 níveis de cinza (4 bits).

O sensor MSI a bordo do satélite Sentinel-2 possui 12 bits de resolução radiométrica, ou seja, 4.096 níveis digitais. Entretanto para este trabalho foram utilizadas imagens em nível  $2A^{18}$  de processamento (refletância de superfície), a refletância varia de 0 a 1 (*float*). Com o objetivo de reduzir o volume de dados e evitar problemas de compatibilidade com programas de processamento de imagens, a refletância é multiplicada por 10.000, requantizadas para 16 bits (65.536 níveis de cinza) e então convertido para valores inteiros (UINT16). Para definir o nível de quantização a ser utilizado nesta metodologia, foram testados os níveis de 4, 8, 10 e 12 bits. O melhor resultado encontrado, que apresentou a melhor extração das texturas, foi a utilização de 16 níveis de cinza (4 bits), quanto maior o nível de quantização, menor era a capacidade de identificação das texturas.

Além dos níveis de quantização, também foram conduzidos testes para definir o tamanho da janela (*kernel*) do GLCM. Foram conduzidos testes com janelas de 3x3, 5x5 e 9x9 pixels. O melhor resultado encontrado foi para a janela de 3x3, para a resolução espacial de 10 metros das imagens S2, as janelas de 5x5 e 9x9 invisibilizam feições que possuem menores dimensões como pequenas ruas, pequenas edificações ou vegetação intraurbana. A matriz foi construída analisando quatro direções ( $0^\circ$ ,  $90^\circ$ ,  $180^\circ$  e  $270^\circ$ ). Para cada uma das direções são calculadas 17 métricas de textura para cada banda espectral, resultando em uma imagem com 272 bandas. Para reduzir o número de bandas e o tempo de processamento na etapa de classificação, foi calculada a média de todas as texturas para todas as direções, resultando em 68 bandas na imagem final (17 bandas para cada banda espectral), conforme Haralick et al. (1973) sugerem para reduzir a dimensão dos dados.

Com as imagens requantizadas e as variáveis de distância e direção definidas, as quatro bandas espectrais do S2 foram utilizadas para construir a matriz de

---

<sup>18</sup> [https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS\\_S2\\_SR](https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2_SR)

coocorrência, utilizando a função “*glcmTexture(size, kernel, average)*”<sup>19</sup> no GEE, onde “*size*” é o tamanho da janela, “*kernel*” são as direções e “*average*” é a opção booleana para que seja calculada a média de cada métrica para todas as direções. O resultado é uma imagem GLCM com 17 texturas por banda espectral S2, cabendo ao usuário escolher quais bandas de textura irá utilizar na classificação.

Das 17 texturas calculadas, 13 são provenientes de Haralick et al. (1973) e quatro de Cornners et al. (1984) (Tabela 3.5). As texturas descrevem métricas de contraste (3 métricas), ordem (7 métricas) e estatística descritiva (6 métricas). O grupo de contraste é composto por métricas que mensuram quão diferentes ou iguais são os níveis de cinza. No grupo de ordem, as métricas indicam a repetição de pares dentro da janela. E por fim, no grupo de estatísticas descritivas as métricas correspondem a equações similares às equações de estatísticas descritivas, média, variância, correlação e outras. Por fim, criou-se um arquivo raster com todas as variáveis de entrada para o classificador, para cada sede municipal, as 68 bandas de textura somadas as quatro bandas espectrais do S2, a banda NDVI e NDWI totalizaram 74 bandas.

---

<sup>19</sup> <https://developers.google.com/earth-engine/apidocs/ee-image-glcmttexture>

Tabela 3.5 - Descrição das métricas de texturas utilizadas.

Grupo	Métrica	Descrição	Referência
Contraste	Contraste	Indica quão diferente o nível de cinza é em relação aos pixels adjacentes. O peso aumenta exponencialmente de acordo com a quantidade de valores diferentes.	Haralick; Dinstein; Shanmugam (1973)
	Dissimilaridade	Mede a distância (número de pixel) entre um par de pixels com mesmo valor.	Connors; Trivedi; Harlow, (1984)
	Homogeneidade	Inverso do contraste, o peso diminui exponencialmente. Janelas com pixels de valores mais semelhantes terão maior valor.	Haralick; Dinstein; Shanmugam (1973)
Ordem	Segundo Momento Angular	Mede o número de pares de pixels com valores repetidos na janela. Maiores valores indicam ordem, pares de pixels com mesmo valor ocorrem com maior frequência.	Haralick; Dinstein; Shanmugam (1973)
	Entropia	Entropia mede a desordem. Maiores valores indicam menor ocorrência de pares de pixels com valores repetidos na janela.	Haralick; Dinstein; Shanmugam (1973)
	Soma da entropia	Mede a desordem relacionada à distribuição da soma dos níveis de cinza da imagem.	Haralick; Dinstein; Shanmugam (1973)
	Diferença da entropia	Mede o distúrbio relacionado à distribuição da diferença do nível de cinza da imagem.	Haralick; Dinstein; Shanmugam (1973)
	Sombra de cluster	Mede a tendência a formação de clusters.	Connors; Trivedi; Harlow, (1984)
	Inércia	Qualidade da periodicidade da textura.	Connors; Trivedi; Harlow, (1984)
	Proeminência do cluster	Mede quão maior são os níveis de cinza do cluster em relação a seu entorno.	Connors; Trivedi; Harlow, (1984)
Estatística descritiva	Variância	Análogo à estatística descritiva (dispersão dos valores no entorno da média), a variância GLCM mede a dispersão dos níveis de cinza no entorno do pixel central.	Haralick; Dinstein; Shanmugam (1973)
	Soma da variância	Mede a dispersão (em relação à média) da distribuição da soma dos níveis de cinza da imagem.	Haralick; Dinstein; Shanmugam (1973)
	Diferença da variância	Mede a dispersão (em relação à média) da distribuição da diferença de nível de cinza da imagem.	Haralick; Dinstein; Shanmugam (1973)
	Correlação	Mede a dependência linear dos níveis de cinza no entorno do pixel central da janela. Pixels normalmente possuem maior correlação com pixels mais próximos (correlação espacial).	Haralick; Dinstein; Shanmugam (1973)
	Soma das médias	Mede a média da distribuição da soma do nível de cinza da imagem.	Haralick; Dinstein; Shanmugam (1973)
	Medidas de Informação de Correlação 1	Medida de dependência com os pixels vizinhos.	Haralick; Dinstein; Shanmugam (1973)
	Medidas de Informação de Correlação 2	Medida de dependência em relação a toda imagem.	Haralick; Dinstein; Shanmugam (1973)

### 3.4.3. Processamento - classificação digital das imagens

Para a classificação das imagens, inicialmente foi adquirido um conjunto de amostras para o treinamento, validação e teste do classificador. E então, as bandas espectrais S2, NDVI, NDWI, e as 68 bandas de texturas foram utilizadas para classificação das cinco classes de interesse, utilizando-se o método de aprendizagem de conjunto *Random Forest*. Foi utilizada a função “*ee.Classifier.smileRandomForest()*”<sup>20</sup> no GEE.

#### 3.4.3.1 Coleta das amostras de treinamento, teste e validação

A aquisição de amostras foi realizada por interpretação visual das imagens S2, composição R4-G3-B2, identificando-se regiões representativas das diferentes classes de interesse. No sistema de informações geográficas (SIG) QuantumGis, foram acessadas as imagens S2 e então criada uma camada vetorial (formato shapefile) do tipo multi-polígono. Neste arquivo vetorial, foi criado o campo “C\_ID” (classe ID) na tabela de atributos, campo utilizado para inserir um rótulo numérico referente a classe da mostra a ser coletada pertence (1 – AC; 2 – SE; 3 – VA; 4 – VH; 5 – AG). No mesmo arquivo vetorial, foram coletadas as amostras para as cinco classes e para as seis sedes municipais analisadas.

Devido à ausência de um mapa de referência que indicasse a proporção de cada classe na imagem, não foi possível uma definição analítica do tamanho da amostra para cada classe. Analisando visualmente as imagens de cada uma das sedes municipais, foi identificado uma proporção aproximada das classes para evitar uma sub-amostragem das classes com maior proporção. Através da vetorização de regiões de interesse que representassem as classes, polígonos foram criados e rotulados com o número referente a classe. Após a coleta das amostras, foi feito o *upload* do arquivo vetorial para os “Assets” no GEE.

---

<sup>20</sup> <https://developers.google.com/earth-engine/apidocs/ee-classifier-smilerandomforest>

No algoritmo foi utilizada a função “*sampleRegions(collection, properties, scale, projection, tileScale, geometries)*”<sup>21</sup> para criar pontos referentes a cada pixel que os polígonos intersectam. O argumento “*collection*” corresponde às amostras de treinamento em polígonos. Em “*properties*” deve-se inserir o nome do campo do arquivo de amostras que possui o rótulo das classes (“C\_ID”); “*scale*” deve-se inserir o tamanho do pixel do arquivo de entrada (10 metros); “*projection*” é o código EPSG referente ao sistema de coordenadas e DATUM do dado de origem; “*tileScale*” é o tamanho da janela de amostragem, neste caso foi utilizado o valor padrão de 1, ou seja, cada pixel é amostrado como uma amostra independente; e por fim “*geometries*” foi definido como verdadeira para que fosse armazenado no arquivo de treinamento as coordenadas geográfica de cada amostra. Em seguida foi utilizada a função “*randomColumn(columnName, seed, distribution)*”<sup>22</sup> para criar uma coluna de valores aleatórios entre 0 e 1, o argumento “*seed*” para garantir a replicabilidade, ou seja, toda a vez que o algoritmo for executado cada feição receberá o mesmo valor, e sempre as mesmas amostras serão utilizadas para cada uma das finalidades.

Em seguida um filtro foi utilizado para dividir o conjunto de amostras em dois grupos, 70% das amostras para o Treinamento (*bagging*) e teste (*out of bag*) do modelo e 30% para validação da acurácia temática (completude). A seleção aleatória das amostras para treinamento/teste e validação evita a tendenciosidade proveniente da amostragem manual e a autocorrelação espacial.

Em seguida a função “*sampleRegions(collection, properties, scale, projection, tileScale, geometries)*”<sup>23</sup> foi utilizada para extrair as informações de todas as variáveis (bandas) no arquivo de entrada (imagem) a partir dos pontos de amostras coletadas. O argumento “*collection*” corresponde às amostras de treinamento separadas a priori (70%). A função cria um arquivo tabular, identifica todas as variáveis presentes (bandas) no arquivo de entrada (imagem), cria uma

---

<sup>21</sup> <https://developers.google.com/earth-engine/apidocs/ee-image-samplerregions>

<sup>22</sup> <https://developers.google.com/earth-engine/apidocs/ee-featurecollection-randomcolumn>

<sup>23</sup> <https://developers.google.com/earth-engine/apidocs/ee-image-samplerregions>

coluna para cada variável, identifica os pixels da imagem que intersectam os pontos de amostras, extrai os valores brutos de todas as bandas em cada pixel, rotula o pixel com a classe do polígono que intersecta e por fim, extrai as coordenadas geográficas de cada pixel e armazena na memória. O arquivo de treinamento foi exportado em formato CSV (*Command separate value*) para posterior análise das amostras.

### **3.4.3.2 Random Forest**

O algoritmo *Random Forest* (RF) foi o selecionado para a classificação das imagens. As características dos alvos, as variáveis preditoras, o tamanho do conjunto de dados e a finalidade da análise devem ser considerados na escolha do classificador. Neste trabalho, há desproporcionalidade das classes, alta variância e alta correlação entre as variáveis em um espaço de grande dimensão (74 variáveis), além da quantidade de pixels a serem classificados, o que justificam a escolha do RF.

Os dados de entrada para o modelo correspondem a 74 bandas, das quais 68 são bandas de texturas, quatro são as bandas espectrais do S2 e as outras duas bandas são os índices NDVI e NDWI. O RF requer hiperparâmetros que devem ser definidos pelo usuário, como o número de árvores de decisão, o número de variáveis por divisão, número mínimo de amostras por nó, *bag fraction* e o número máximo de nós<sup>24</sup>. Para definir os hiperparâmetros, diversos testes foram executados variando-se os valores de cada hiperparâmetro.

O primeiro parâmetro que deve ser definido é o “*bag fraction*”, esse parâmetro define o percentual de amostras de treinamento que vão ser separados para teste, as amostras separadas para teste são denominadas “*out of bag*”, estas amostras são utilizadas para determinar a estimativa de erro. Esse erro é utilizado para avaliar o efeito da variação dos hiperparâmetros no resultado do modelo. Após a definição de todos os hiperparâmetros, o *bag fraction* é definido

---

<sup>24</sup> *Classifier.smileRandomForest(numberOfTrees, variablesPerSplit, minLeafPopulation, bagFraction, maxNodes, seed)*

como 1, assim todas as amostras são utilizadas para treinamento do modelo, e avaliação de acurácia temática pode ser feita com amostras de validação separadas a priori (30%) (BREIMAN, 2001; HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

Após a definição de todos os hiperparâmetros do classificador RF foram realizados testes para avaliar quais variáveis (bandas) possuíam pouca importância ou nenhuma importância. Na etapa de construção de modelos, recomenda-se que sejam removidas as variáveis com menor importância e avaliar se há aumento da acurácia de classificação (BREIMAN, 2001; HASTIE; TIBSHIRANI; FRIEDMAN, 2009). A importância das variáveis foi mensurada pelo índice de impureza de Gini (IIG) em cada árvore de decisão (BREIMAN, 2001; HASTIE; TIBSHIRANI; FRIEDMAN, 2009). No GEE automaticamente é feita a soma do IIG dentre todas as árvores de decisão para cada variável, resultando na soma da redução do índice de impurezas de GINI (SRIIG). Bandas com maiores valores do SRIIG são as de maior importância para separar as classes.

O algoritmo foi executado de duas formas, em função do uso das amostras e a construção das árvores para as cidades estudadas. No modo único, ou *Single Random Forest* (SRF<sup>25</sup>), o algoritmo foi executado utilizando todas as amostras coletadas (de todas as seis cidades - áreas de estudo) e construiu apenas uma floresta de árvore de decisão, e realizando a classificação com o mesmo modelo para todas as sedes municipais. Este procedimento permitiu avaliar a robustez da metodologia, ou seja, discutir se apenas um modelo RF, com um conjunto único de amostras, seria suficiente para classificar adequadamente todas as cidades, o que permitiria expandir diretamente metodologia para o Pará e a Amazônia brasileira.

No modo múltiplo, ou *Multi-Random Forest* – (MRF<sup>26</sup>) o algoritmo construiu uma floresta de árvores de decisão para cada sede de município estudada,

---

<sup>25</sup> <https://github.com/gabpcrivellaro/AmazonBuiltUp/blob/main/AmazonBuiltUP-SRF.py>

<sup>26</sup> <https://github.com/gabpcrivellaro/AmazonBuiltUp/blob/main/AmazonBuiltUP-MRF.py>

considerando apenas suas respectivas amostras, para então classificar as seis sedes municipais. Este procedimento possibilitou avaliar se a importância das variáveis seria dependente do contexto geográfico.

Finalmente, para avaliar a contribuição das métricas de textura na classificação, foram definidos subconjunto de bandas espectrais para classificações específicas: 1) utilizando somente as quatro bandas espectrais do S2, ou *Only Spectral* (OS); 2) utilizando as bandas espectrais (4) e os índices NDVI e NDWI, ou *Only Spectral and Index* (OSI); e 3) utilizando as bandas espectrais (4), os índices NDVI e NDWI, e as 74 bandas de textura (GLCM). A classificação GLCM foi executada no modo SRF (SRF-GLCM) e no modo (MRF-GLCM). As classificações OS e OSI foram executadas no modo SRF (SRF-OS e SRF-OSI, respectivamente). O detalhamento da importância das variáveis e da acurácia final estão descritos no capítulo de resultados e discussões.

#### **3.4.4 Pós-classificação: avaliação da acurácia temática**

A última etapa da metodologia corresponde à avaliação da acurácia temática da classificação. Para esta avaliação foram utilizadas as amostras separadas (30%) a priori, conforme descrito no Item 0. Novamente foi utilizada a função “*sampleRegions()*” para amostrar todos os pixels dos mapas temáticos que intersectam os pontos de amostras, resultando em um arquivo tabular com a classe de referência e predita de cada pixels amostrado. Em seguida esse arquivo foi utilizado para construção das matrizes de erro através da função “*errorMatrix(actual, predicted, order)*”<sup>27</sup>.

Com as matrizes de erro computadas, foi feita então a análise de completude da classificação. A completude dos dados é uma maneira de analisar tecnicamente a comissão e omissão da classificação (PONTIUS; MILLONES, 2011) e o coeficiente Kappa (STEHMAN, 1997) para efeito de comparação entre os mapas das sedes municipais e os quatro mapas temáticos finais (SRF-OS; SRF-OSI,

---

<sup>27</sup> <https://developers.google.com/earth-engine/apidocs/ee-confusionmatrix>

SRF-GLCM e MRF-GLCM). Nesta etapa foram utilizadas outras quatro funções: “*accuracy*<sup>28</sup>”; “*consumerAccuracy*<sup>29</sup>”; “*producerAccuracy*<sup>30</sup>”; “*Kappa*<sup>31</sup>”. Estas funções foram utilizadas para determinar a acurácia global, acurácia de consumidor, acurácia de produtor e o coeficiente Kappa, respectivamente.

---

<sup>28</sup> <https://developers.google.com/earth-engine/apidocs/ee-confusionmatrix-accuracy>

<sup>29</sup> <https://developers.google.com/earth-engine/apidocs/ee-confusionmatrix-consumersaccuracy>

<sup>30</sup> <https://developers.google.com/earth-engine/apidocs/ee-confusionmatrix-producersaccuracy>

<sup>31</sup> <https://developers.google.com/earth-engine/apidocs/ee-confusionmatrix-Kappa>

## **4 RESULTADOS E DISCUSSÕES**

A descrição dos resultados inicialmente apresenta itens específicos associados aos resultados de testes dos procedimentos metodológicos de classificação proposto e ao final, tem-se uma análise qualitativa das classificações especificidades das seis cidades paraenses estudadas.

### **4.1 As áreas urbanizadas das sedes de município e seus entornos - delimitação da extensão geográfica para processamento**

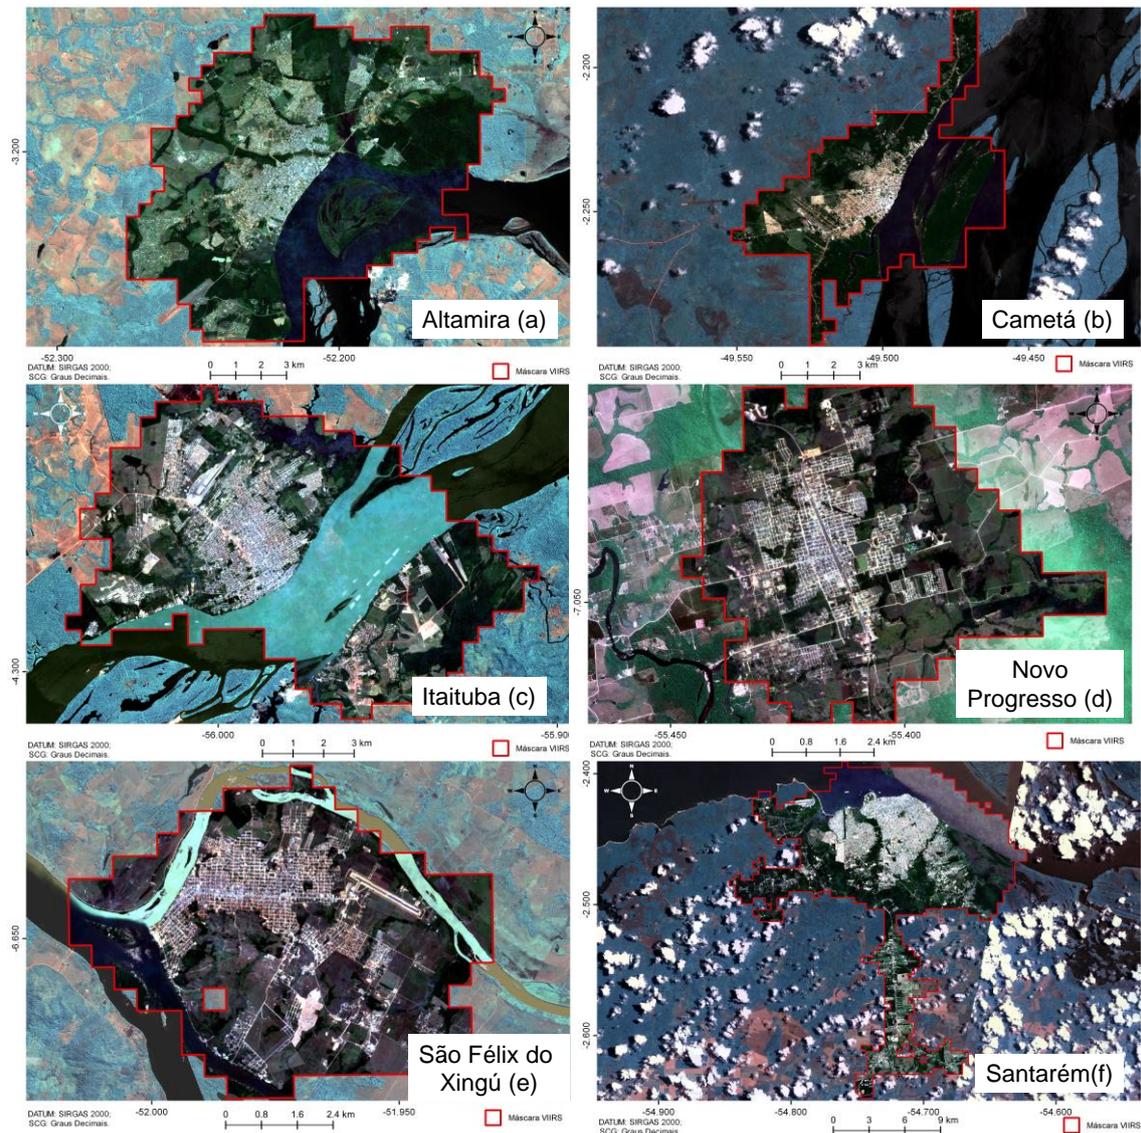
A Figura 4.1 apresenta as áreas de interesse delimitadas para cada uma das seis cidades analisadas. De modo geral, o limiar utilizado para o fatiamento das imagens VIIRS ( $0.8 \text{ nanoWatts.cm}^{-2}.\text{sr}^{-1}$ ) permitiu a inclusão de áreas adjacentes ao núcleo da cidade, como as franjas rurais-urbanas, compondo uma área contígua. Em Santarém, a área total de processamento corresponde a 26.498 hectares, 12.550 hectares em Altamira, 9.775 hectares em Itaituba, em 5.300 hectares em Cametá, 4.825 hectares em Novo Progresso, e 4.550 hectares em São Félix do Xingu.

Nas cidades ribeirinhas, ou seja, excetuando-se Novo Progresso, significativas áreas de lâmina d'água foram incluídas nas áreas de processamento devido ao reflexo das luzes noturnas na água. Em função desse fenômeno, pixels originalmente não iluminados, com valores de radiância menores que  $0,8 \text{ nanoWatts.cm}^{-2}.\text{sr}^{-1}$ , são contaminados (ELVIDGE et al., 2013).

Ilhas como Itaúna em Cametá (Figura 4.1 (b)), e do Arapujá em Altamira (Figura 4.1 (a)), foram incorporadas à área de processamento, assim como o distrito de Miritituba, na margem oposta da cidade de Itaituba (Figura 4.1 (c)), no rio Tapajós. Áreas de ocupação seguindo eixos rodoviários, como observado em Santarém e Cametá, também expandem a área iluminada. Em particular para a cidade de Santarém, destaca-se a ocupação ao longo do eixo da BR-163, onde ocorrem comunidades, como Cipoal, Terra Preta e Tabocal, e loteamentos privados (Figura 4.1 (d)) (Dados de campo – LiSS/INPE). Considerando as características dos dados de luzes noturnas, a presença de estruturas de

iluminação eventualmente presentes em localidades, como as citadas, favoreceu o registro dessas áreas pelo sensor (AMARAL et al., 2015).

Figura 4.1 - Limites de áreas para processamento em Altamira, Cametá, Itaituba, Novo Progresso, São Félix do Xingú e Santarém.

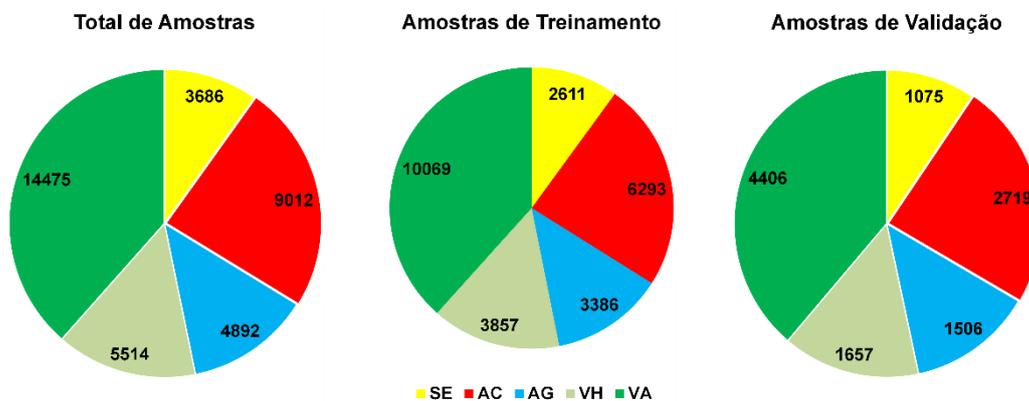


## 4.2 Comportamento espectral das classes de uso e cobertura a partir das amostras

Um conjunto de 36.968 pixels, representativos das classes de uso e cobertura da terra de interesse foram amostrados nas imagens Sentinel 2, dos quais 70%

constituem amostras para treinamento (26.216 pixels) e 30% para validação e teste do algoritmo (10.752 pixels). A distribuição das amostras entre as classes é apresentada na Figura 4.2. A maior proporção de amostras está associada à classe Vegetação Arbórea - VA (39,15% do total de amostras), seguida pelas classes Área Construída - AC (24,38%), Vegetação Herbácea (15,18%), Água – AG (13,23%) e Solo Exposto - SE (9,97%), respectivamente.

Figura 4.2 – Distribuição das amostras (total, treinamento e validação) dentre as classes.

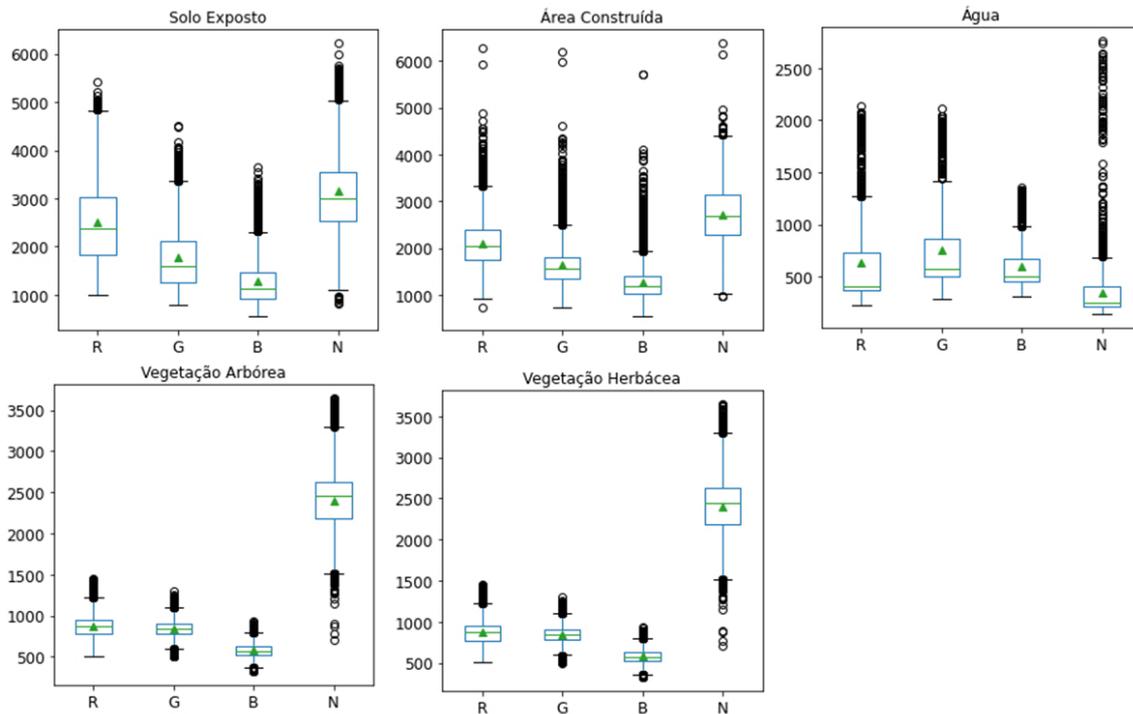


Há uma grande variabilidade espectral intra-classe, especialmente nas classes SE e AC Figura 4.3. A classe SE apresentou a maior amplitude interquartílica, resultado das diferentes composições do solo presentes nas seis cidades (Raimundo et al., 2007). Nessa classe, a presença de *outliers* está associada, geralmente, à presença de praias ou bancos de areias nos rios. A classe AC, por sua vez, apresenta menor intervalo interquartílico em comparação à classe SE, porém, com maior frequência de *outliers* (Figura 4.3).

Na classe AC, os *outliers* foram identificados em construções com cobertura de materiais metálicos (zinco) e arruamentos não pavimentados, de solo claros. Para a cidade de Santarém especificamente, Dal’Asta et al. (2015) associaram feições construídas a materiais brilhantes (telhados metálicos e amianto e outros materiais de alta refletância), claros (telhado cerâmicos e outros materiais de cor clara) e escuros (incluindo materiais de concreto, asfalto etc.) identificáveis em imagem SPOT-5/HRG2. Salvo as particularidades, o comportamento espectral

das classes SE e AC possui padrão semelhante, haja vista que o material de algumas feições construídas tem origem na própria região.

Figura 4.3– Gráficos *boxplot* das amostras de treinamento e para cada classe de cobertura urbana, nas bandas espectrais do S2.



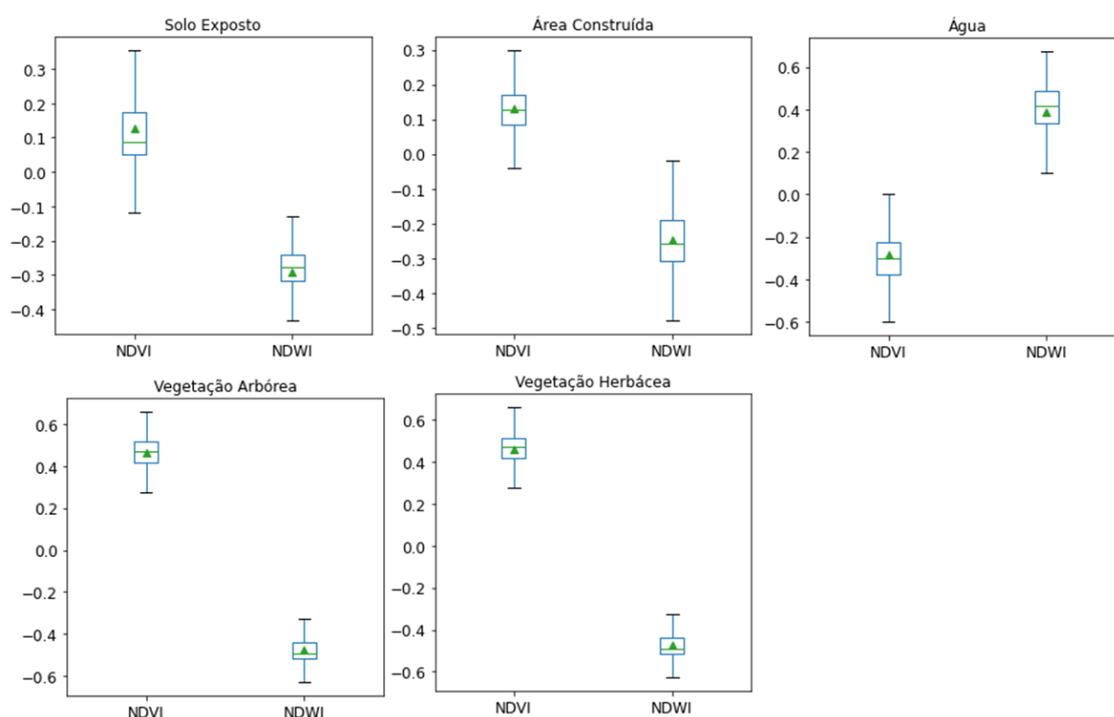
A classe AG é a classe com maior número de *outliers*, devido à diversidade de tipos de água encontrados em rios, lagos e tanques para piscicultura nas áreas analisadas. Essa diversidade também se reflete na variabilidade interquartílica observada.

As estatísticas das amostras para as classes VH e VA são similares. Baixa amplitude interquartílica, poucos *outliers* e valores da banda NIR com maiores ordens de grandeza que as demais bandas, devido à reflexão da radiação pela clorofila presente na vegetação. Na classe VA a resposta é ainda maior que na classe VH devido à maior presença de biomassa vegetal fotossintética.

A Figura 4.4 apresenta o comportamento das cinco classes nos índices NDVI e NDWI. No NDVI, as classes de vegetação (VA e VH) apresentam os valores mais

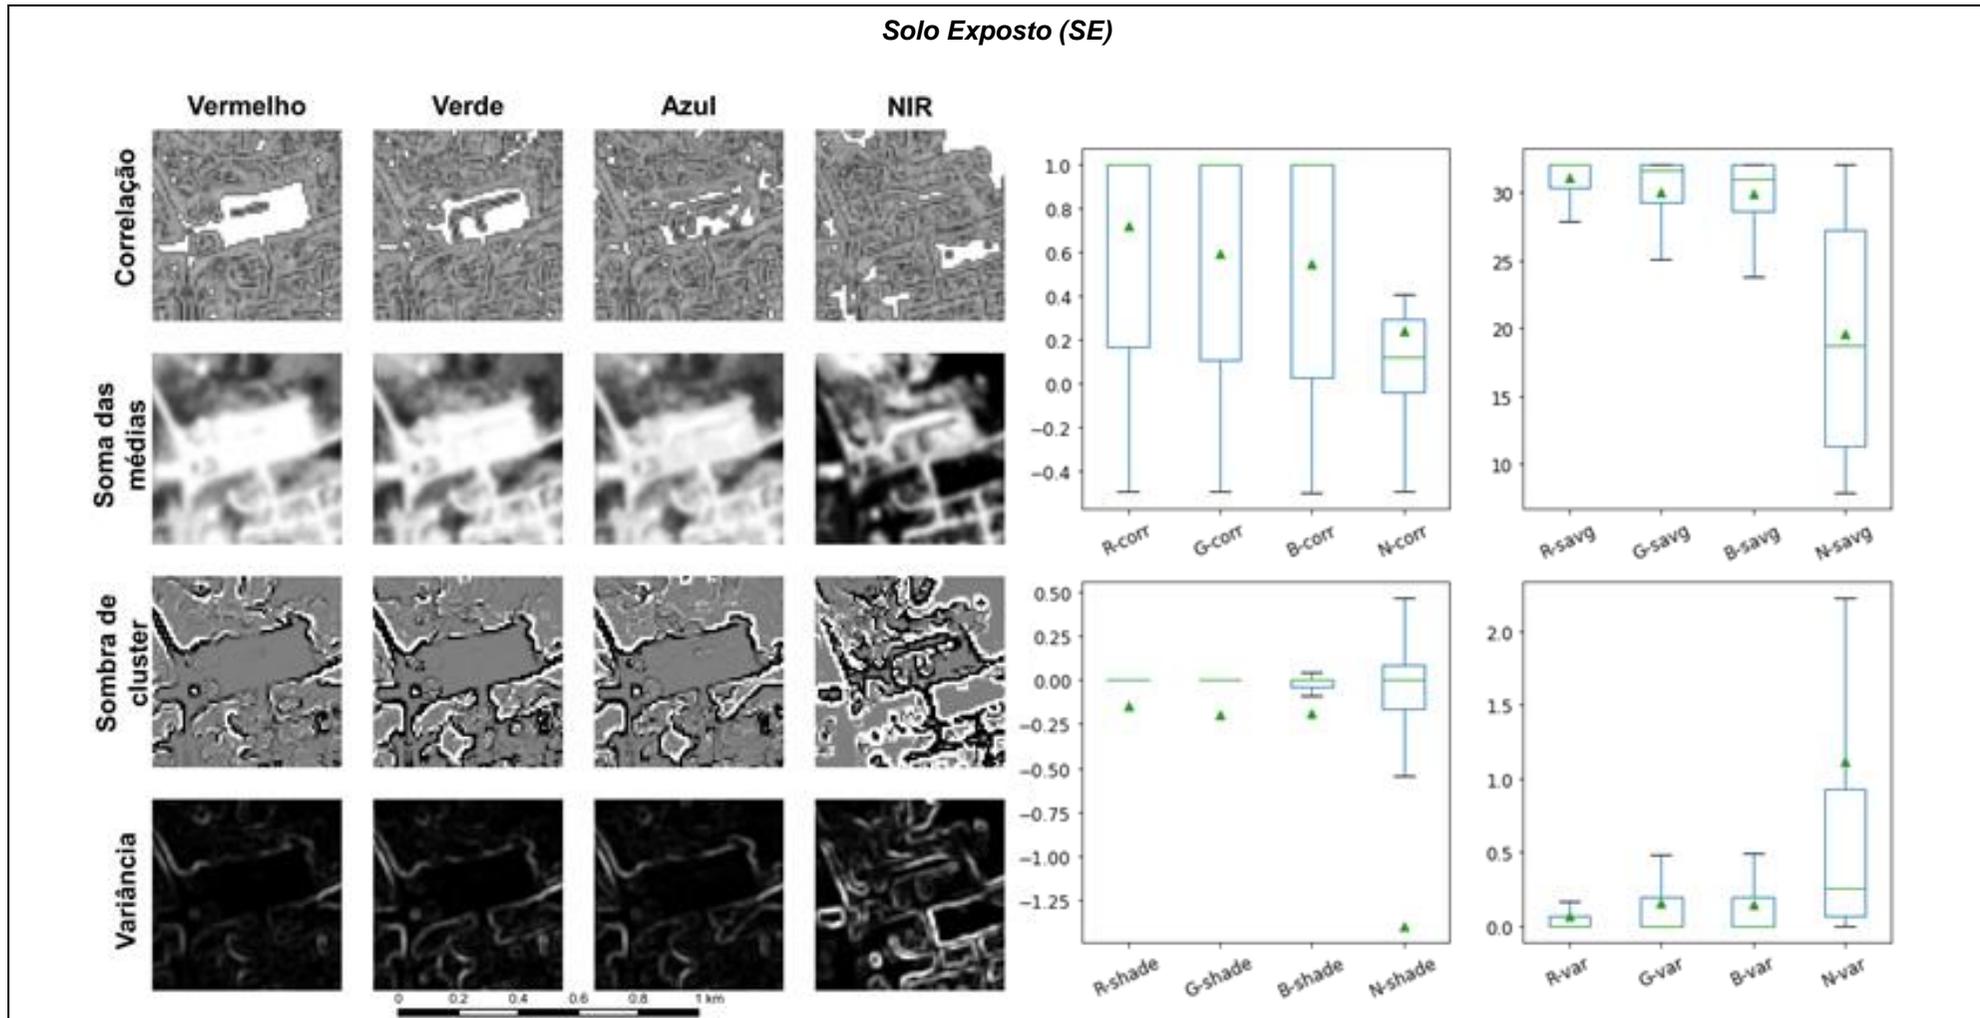
altos (valores maiores que 0,3), as classes SE e AC valores intermediários (entre -0,1 a 0,4) e a classe AG os valores mais baixos (-0,6 a 0). Como o NDWI é um índice voltado para a identificação de corpos d'água apenas a classe AG possui valores maiores que zero.

Figura 4.4- Gráficos *boxplot* das amostras de treinamento de para cada classe nos índices biofísicos (NDVI e NDWI).



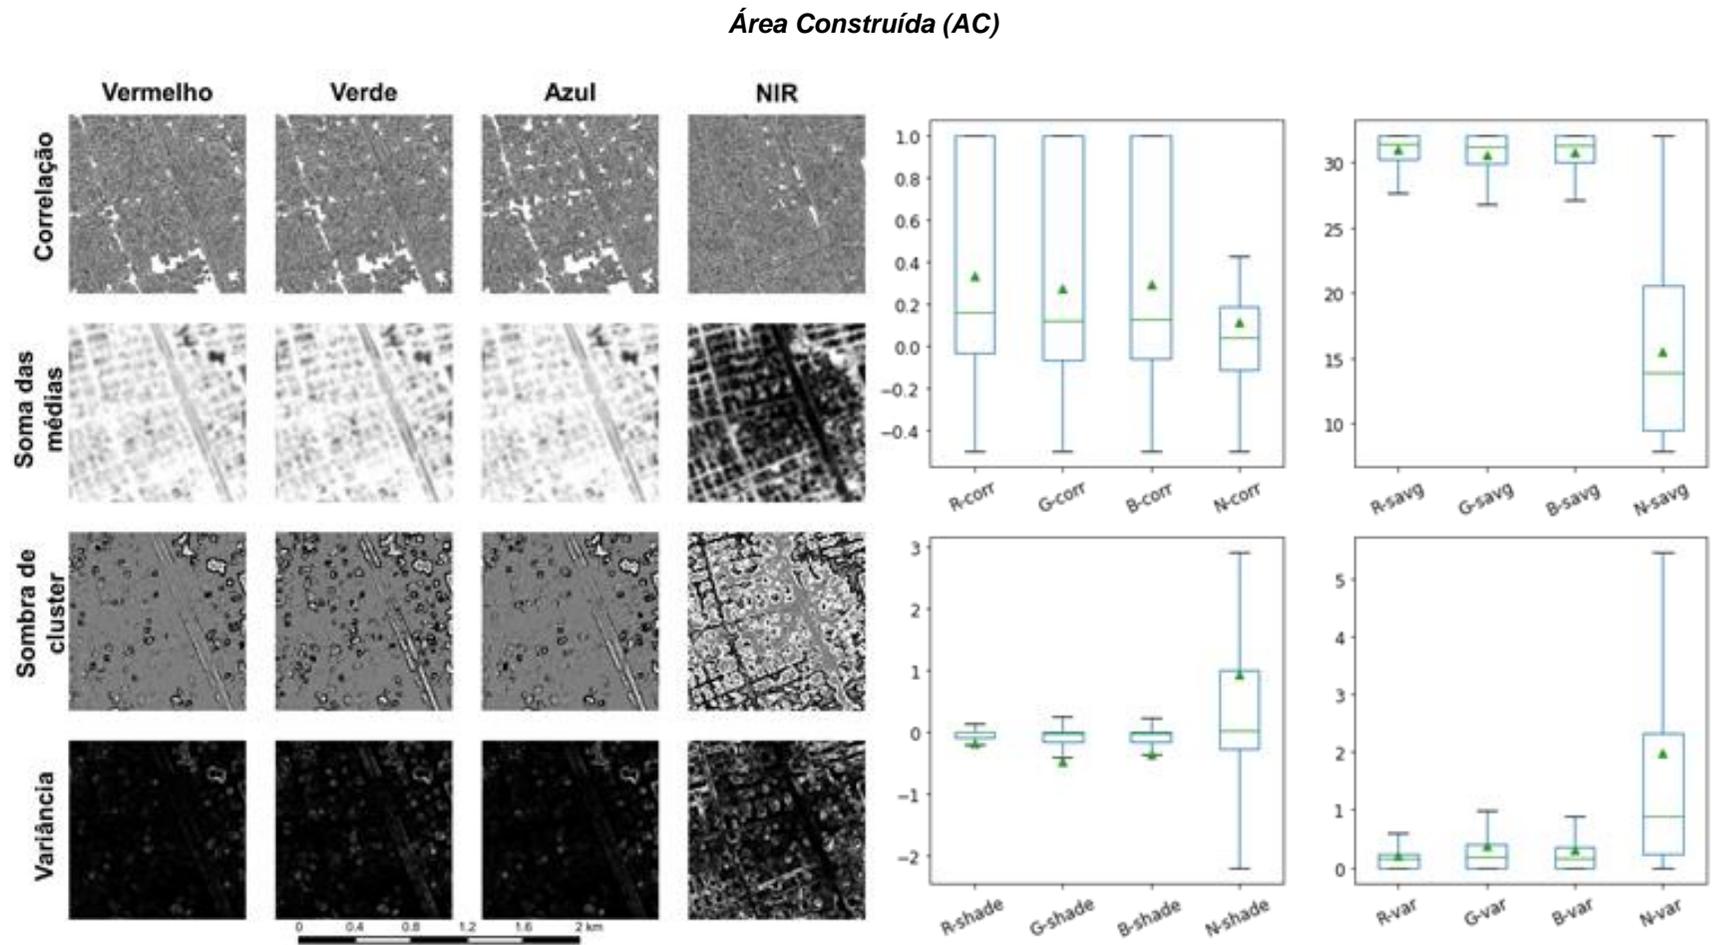
Na Figura 4.5 são apresentados os *boxplots* e as imagens com o comportamento de quatro métricas de textura para cada classe de interesse. Essas quatro métricas apresentaram maior importância na classificação do RF, dentre as 18 descritas na Seção 3.4.2.1. Dessas quatro métricas, uma é do grupo de ordem (sombra de cluster) e as outras três do grupo de estatísticas descritivas (correlação, soma da média e variância).

Figura 4.5 - Gráficos *boxplot* das amostras de treinamento de para algumas métricas texturais.



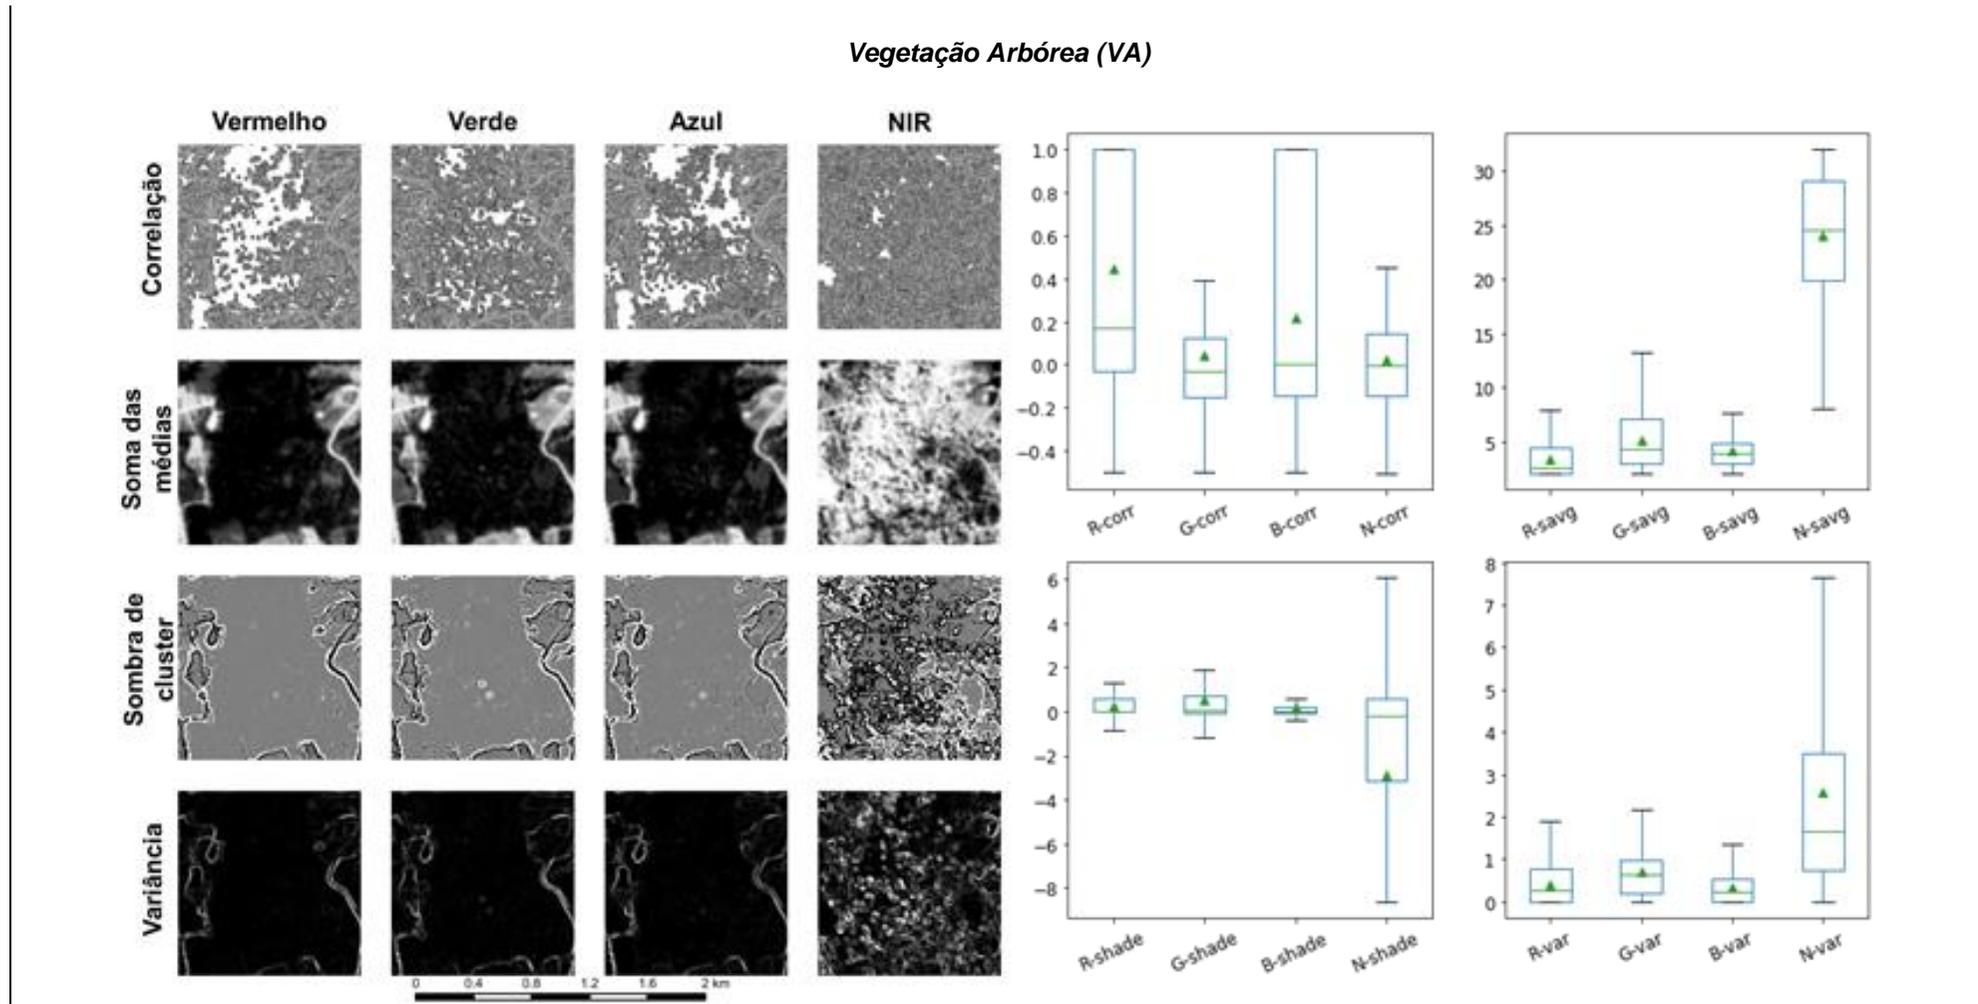
continua

Figura 4.5 – Continuação.



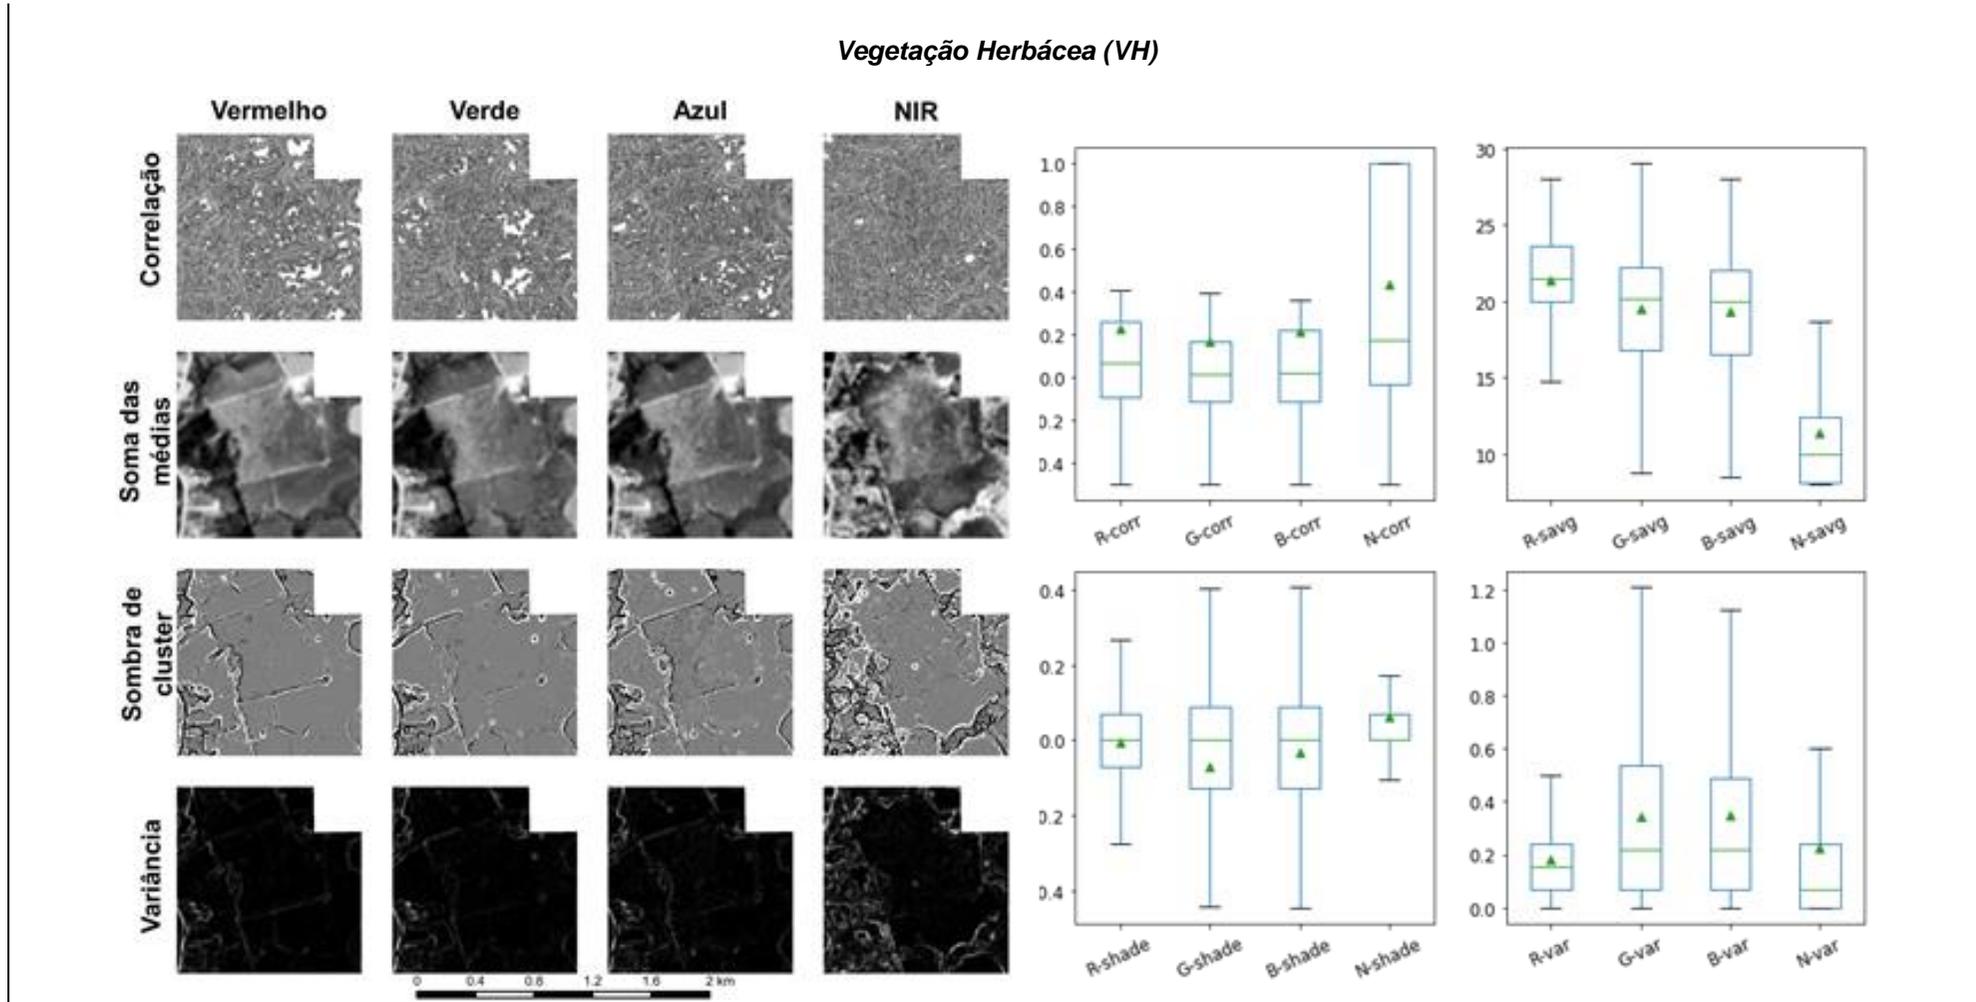
continua

Figura 4.5 – Continuação.



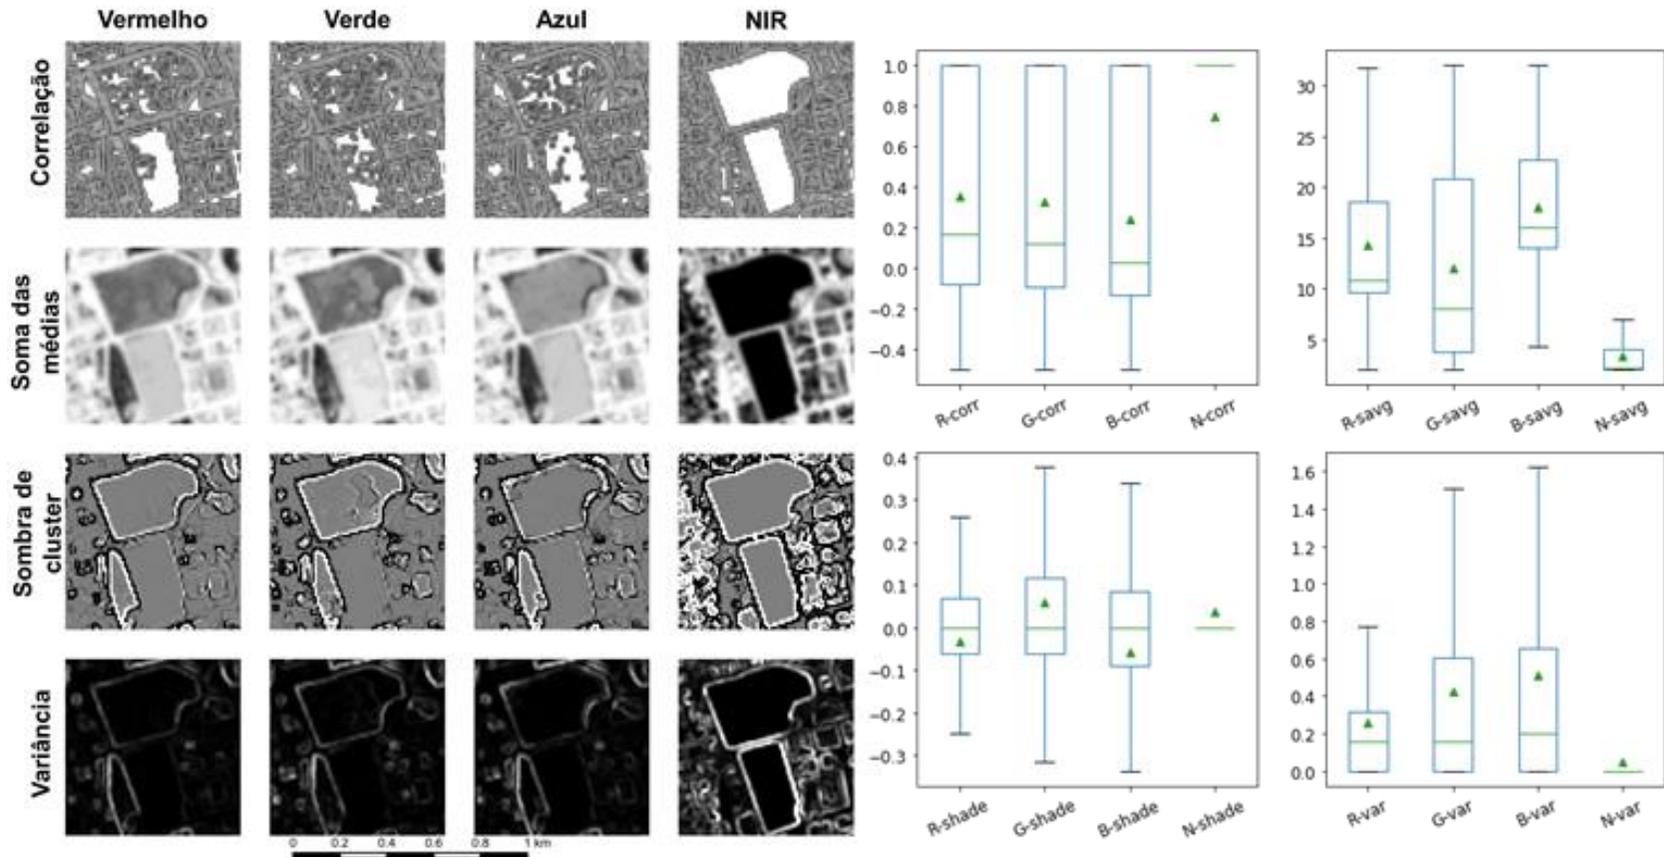
continua

Figura 4.5 – Continuação.



continua

Figura 4.5 – Conclusão.  
 Água (AG)



CORR: Correlação; SAVG: Soma das médias; SHADE: Sombra de cluster; VAR: Variância. R: Banda espectral do vermelho; G: Banda espectral do verde; B: Banda espectral do azul; N: Banda espectral do NIR; CORR: Correlação; SAVG: Soma das médias; SHADE: Sombra de cluster; VAR: Variância.

### 4.3 Avaliação dos parâmetros e critérios para a classificação de áreas construídas

Este item apresenta os resultados dos testes de avaliação da influência dos hiperparâmetros: número de árvores de decisão, número de variáveis por divisão e número máximo de nós; e das 74 variáveis no desempenho do classificador *Randon Forest* (RF). Para essa avaliação, 50% das amostras de treinamento foram utilizadas para o treinamento (*bagging*) e 50% para o cálculo da estimativa de erro *out of bag*.

Em teste com RF, Hastie et al. (2009) observaram que a partir de 200 árvores de decisão a acurácia do método estabiliza. Para esta dissertação, foram testadas 10, 50, 100, 500, 1.000 e 5.000 árvores de decisão, para as quais foram encontradas estimativas de erro do *out of bag* de 24,44%, 20,65%, 12,11%, 4,65% e 3,43%, respectivamente. Observou-se que o aumento do número de árvores resultou na diminuição significativa da estimativa de erro, que tende a estabilizar a partir de 1.000 árvores.

Tradicionalmente no RF, a raiz quadrada do número total de variáveis define o número máximo de variáveis por divisão (*Bootstrapping*) (BREIMAN, 2001; HASTIE; TIBSHIRANI; FRIEDMAN, 2009), limiar utilizado neste trabalho (oito – raiz quadrada aproximada do conjunto de 72 variáveis utilizadas nesse trabalho). Além da raiz quadrada do total de variáveis (8), foram testados também valores maiores e menores, para os quais não foi observada alteração na acurácia.

Para o número máximo de nós, os testes com valores de 5, 10, 15 e 20 resultaram no aumento na estimativa de erro, que passou de 4,65% para 12,08%, 11,55%, 11,29% e 9,89%, respectivamente. Em função disso, optou-se por não definir um limite no número de nós, de modo que o próprio algoritmo defina o ponto onde não seja mais possível a divisão. Assim, árvores foram criadas explorando ao máximo a variância dos dados. Mesmo que leve ao *overfitting* da árvore, a utilização da floresta de árvores de decisão não permite o *overfitting* de todo o RF, visto que o resultado final é a somatória dos votos de todos os modelos (árvores).

Para a abordagem Single Random Forest (SRF), ou seja, uma única árvore para todas as cidades (amostras), analisou-se a importância das 72 variáveis no desempenho do RF. Após a primeira execução, foram removidas as 20 bandas com menor valor de índice de impurezas de GINI (SRIIG). Para esse teste, a estimativa de erro do modelo aumentou de 4,65% para 11,85% em média. Dada a redução da acurácia, uma nova execução do algoritmo foi realizada, removendo as 10 bandas de menor importância, e a estimativa de erro foi de 8,82%. Em seguida, o algoritmo foi executado mais 10 vezes adicionando, gradativamente a cada execução, uma banda, e a estimativa de erro chegou aos 4,65% alcançados com todas as bandas. Estes resultados justificaram a manutenção de todas as variáveis no modelo.

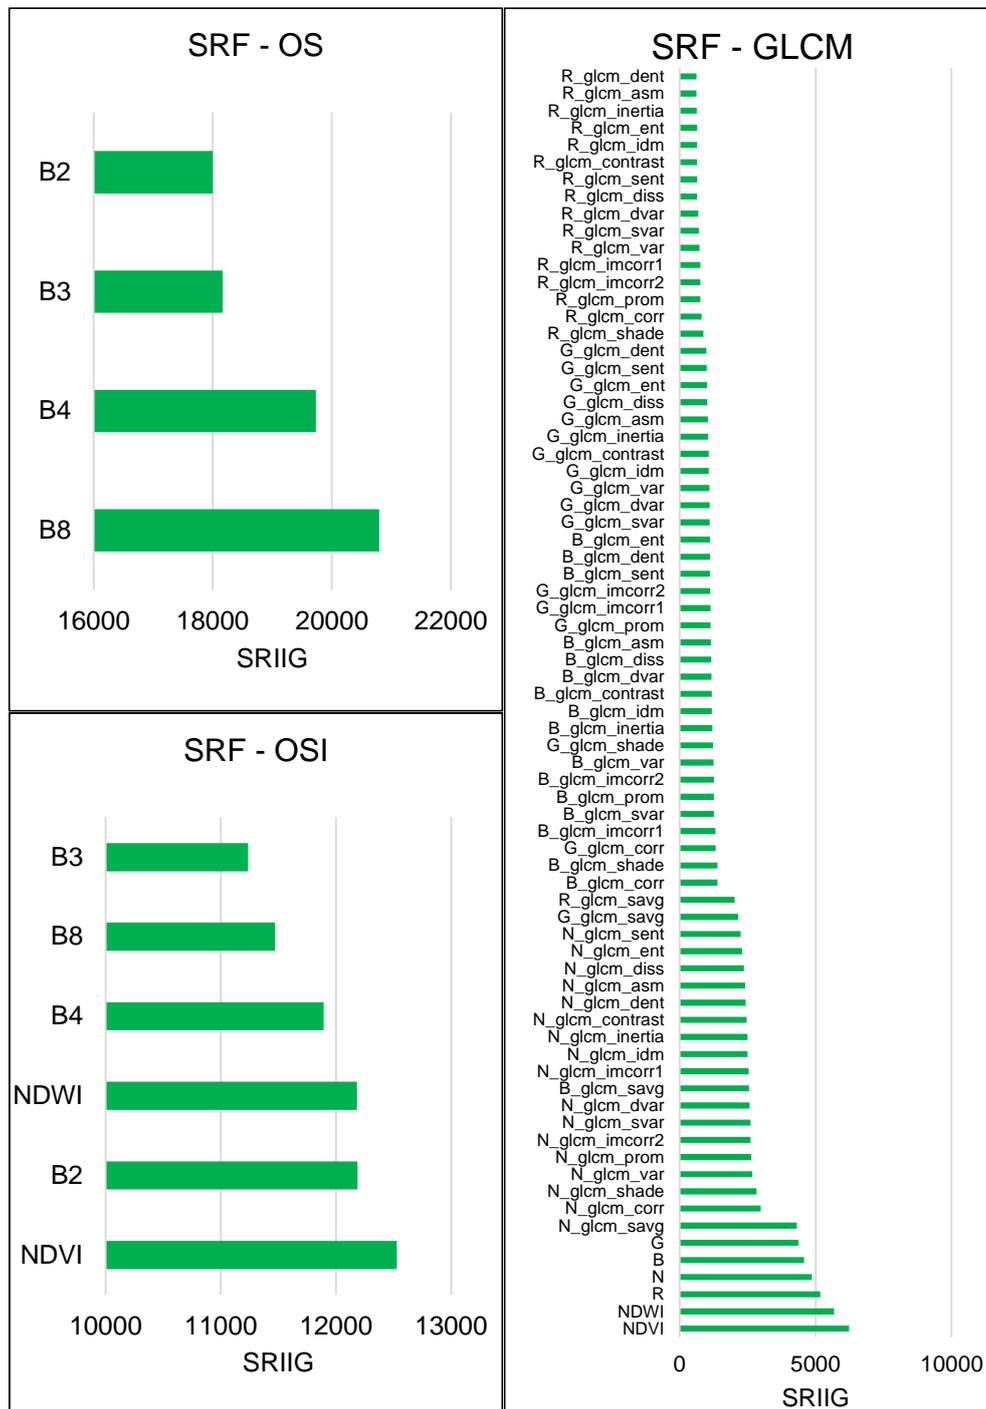
#### **4.3.1 Contribuição das variáveis - bandas espectrais, biofísicas e de textura**

A importância e comportamento das variáveis para a execução do algoritmo RF, no formato de uma única árvore de decisão (SRF), foram analisadas considerando: o uso apenas das bandas espectrais (OS); as bandas espectrais e os índices NDVI e NDWI (OSI); e com a inclusão das métricas de textura (GLCM) (Figura 4.6). Para definir a importância das variáveis em cada método analisado, utilizou-se o valor de SRIIG, que aumenta cada vez que determinada variável foi utilizada no processo decisório.

Na execução do modelo com as quatro bandas espectrais do Sentinel 2 (SRF-OS), a banda do infravermelho próximo (NIR8) foi a mais importante na decisão de qual classe pertenciam os pixels, seguidas pelas bandas R4, G3 e B2, respectivamente. A importância do infravermelho se justifica devido à proporção de pixels com cobertura vegetal (classes VH e VA) presentes nas sedes municipais analisadas. Em contrapartida, quando os índices biofísicos foram incluídos na classificação (SRF-OSI), a banda do NIR é substituída pelo NDVI quanto à importância, seguido pela B2, NDWI, B4, B8NIR e B3, respectivamente. Ao incluir as métricas de textura, o NDVI e NDWI aparecem com maior importância, seguidos das quatro bandas espectrais (B4, B8, B2 e B3,

respectivamente). Em relação às métricas de texturas (SRF-GLCM), observa-se que todas as bandas de texturas determinadas a partir do NIR (N\_GLCM) tiveram maior importância que as calculadas a partir das outras bandas espectrais. Em ordem de importância do GLCM, têm-se: bandas de texturas partir da B2 (B\_GLCM), da B3 (G\_GLCM) e por fim da B4 (R\_GLCM). Vale ressaltar que todas as variáveis foram utilizadas no RF e as bandas de textura foram complementares as bandas espectrais originais. Esse resultado é esperado, haja visto que o método busca a identificação de classes diversas, dependentes das assinaturas espectrais. Na literatura, diversos estudos mostram essa complementariedade das métricas de textura em combinação com variáveis (bandas) espectrais e índices diversos na classificação do uso e cobertura da terra (ZHENG et al., 2017; TAVARES et al., 2019).

Figura 4.6 – Importância das variáveis (SRIIG) para o Randon Forest de árvore única (SRF): somente com dados espectrais (SRF-OS), incluindo índices biofísicos (SRF-OSI), e texturas (SRF-GLCM).

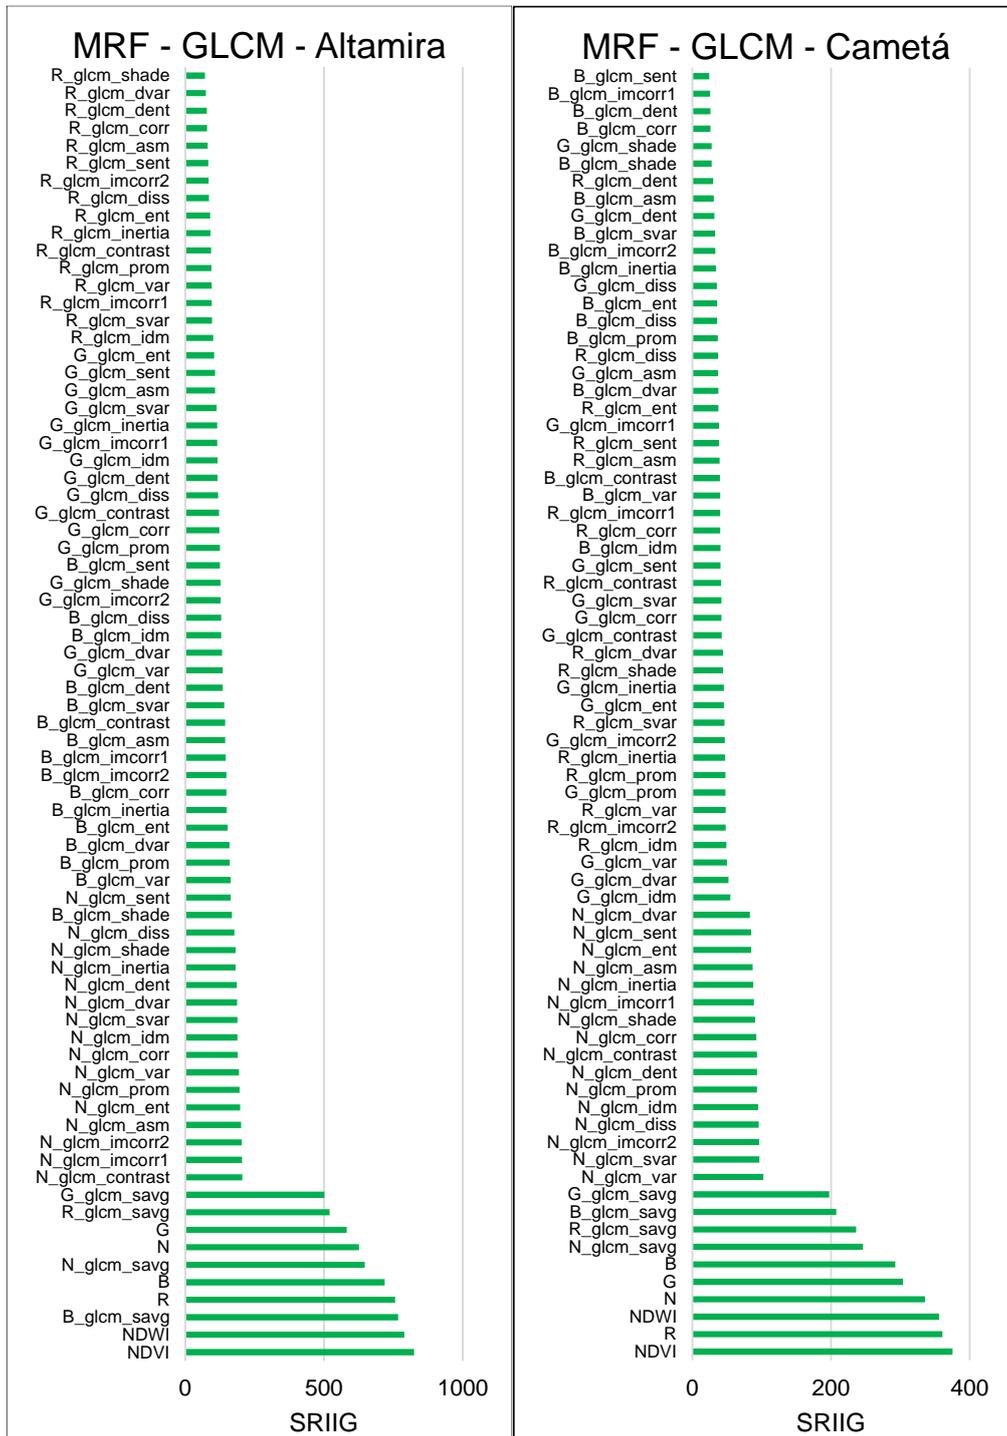


SRF: Floresta de árvores de decisões única para todas as áreas de estudo (*Single Random Forest*) utilizando todas as bandas espectrais, NDWI, NDVI e métricas de textura; OS: Utilizando somente bandas espectrais do S2 (R4-G3-B2-NIR8; *Only Spectral*); OSI: Utilizando as bandas espectrais, NDVI e NDWI (*Only Spectral and Index*).

As Figuras 4.7, 4.8 e 4.9 apresentam o comportamento das variáveis quando o algoritmo considerou uma árvore de decisão para cada uma das seis cidades consideradas, ou seja, no formato Multi-Randon Forest (MRF-GLCM). Em todas as cidades, o NDVI foi a variável mais importante, seguida pelo NDWI, com exceção de Cameté que indicou a B4 como mais importante. Em que pese a importância geral das bandas espectrais do S2, a posição de cada uma, por ordem de importância, difere entre as cidades, embora permaneçam entre as dez variáveis mais importantes.

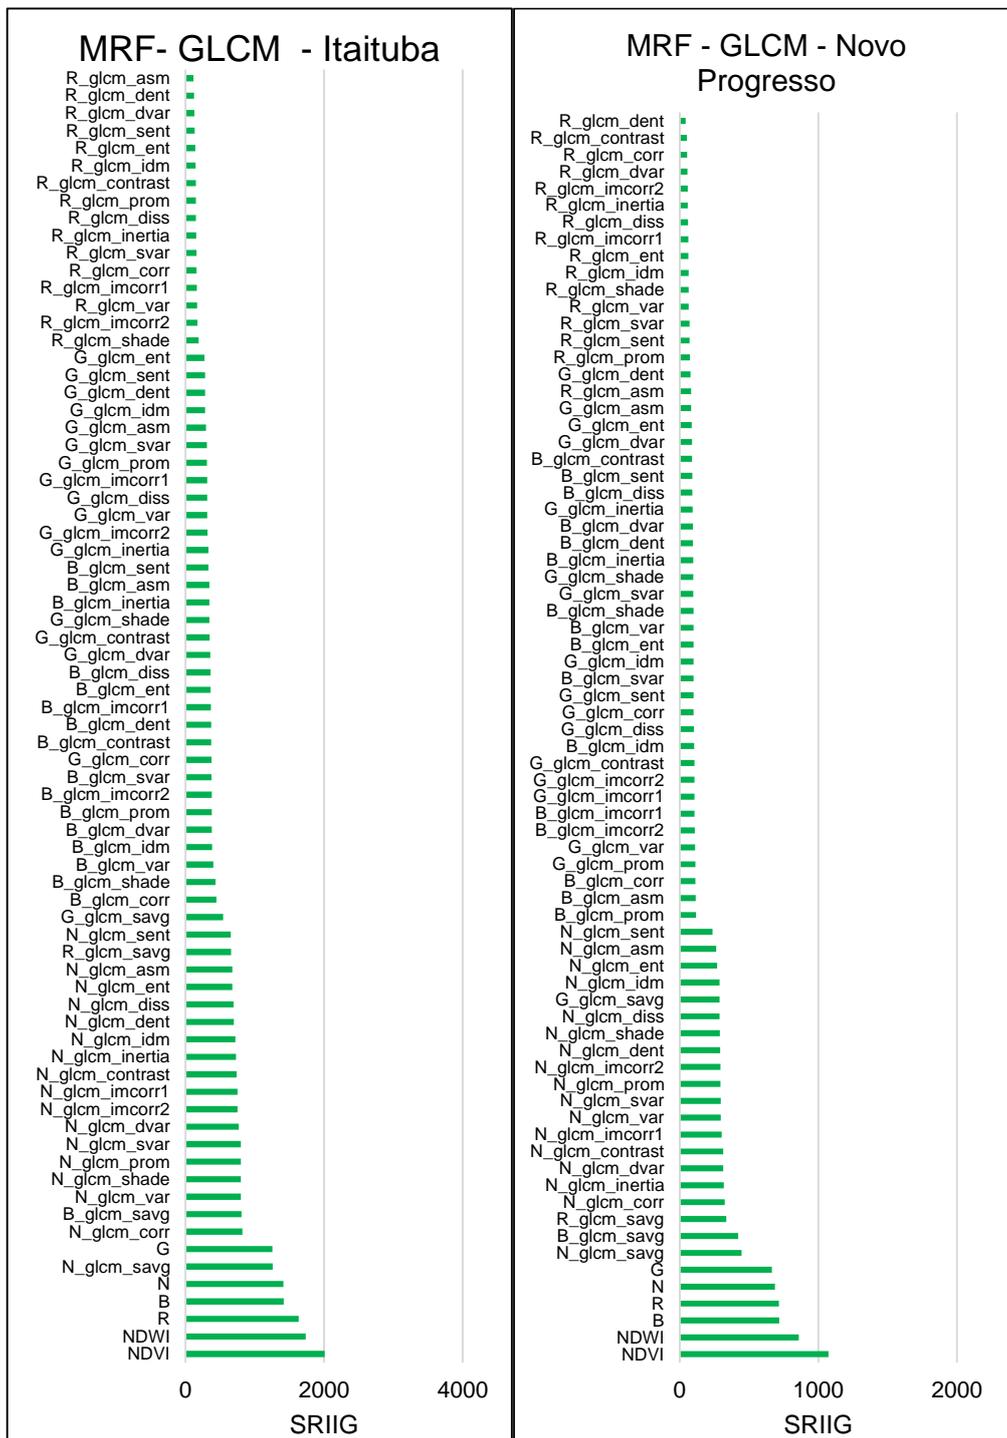
As bandas de textura “soma da média” (SAVG) em todas as seis cidades configuraram dentro as dez primeiras variáveis mais importantes, independente da banda espectral de origem. A ordem da importância das variáveis está associada às características de cada cidade, suas particularidades e contextos socioespaciais de inserção. A heterogeneidade na estruturação e composição dos espaços intraurbanos, em termos de ocupação, traçado e cobertura vegetal, nas seis cidades estudadas, foram observados em Gonçalves et al. (2021), para o ano de 2010. Dal'Asta et al. (2012) ao elencarem os padrões espaciais de ocupação em concentrações populacionais no sudoeste paraense, observaram similaridades e particularidades no arranjo desses padrões coerentes com o observado em Gonçalves et al. (2021).

Figura 4.7 – Importância das variáveis (SRIIG) para o Randon Forest com árvores específicas (MRF-GCLM) para Altamira e Cameté.



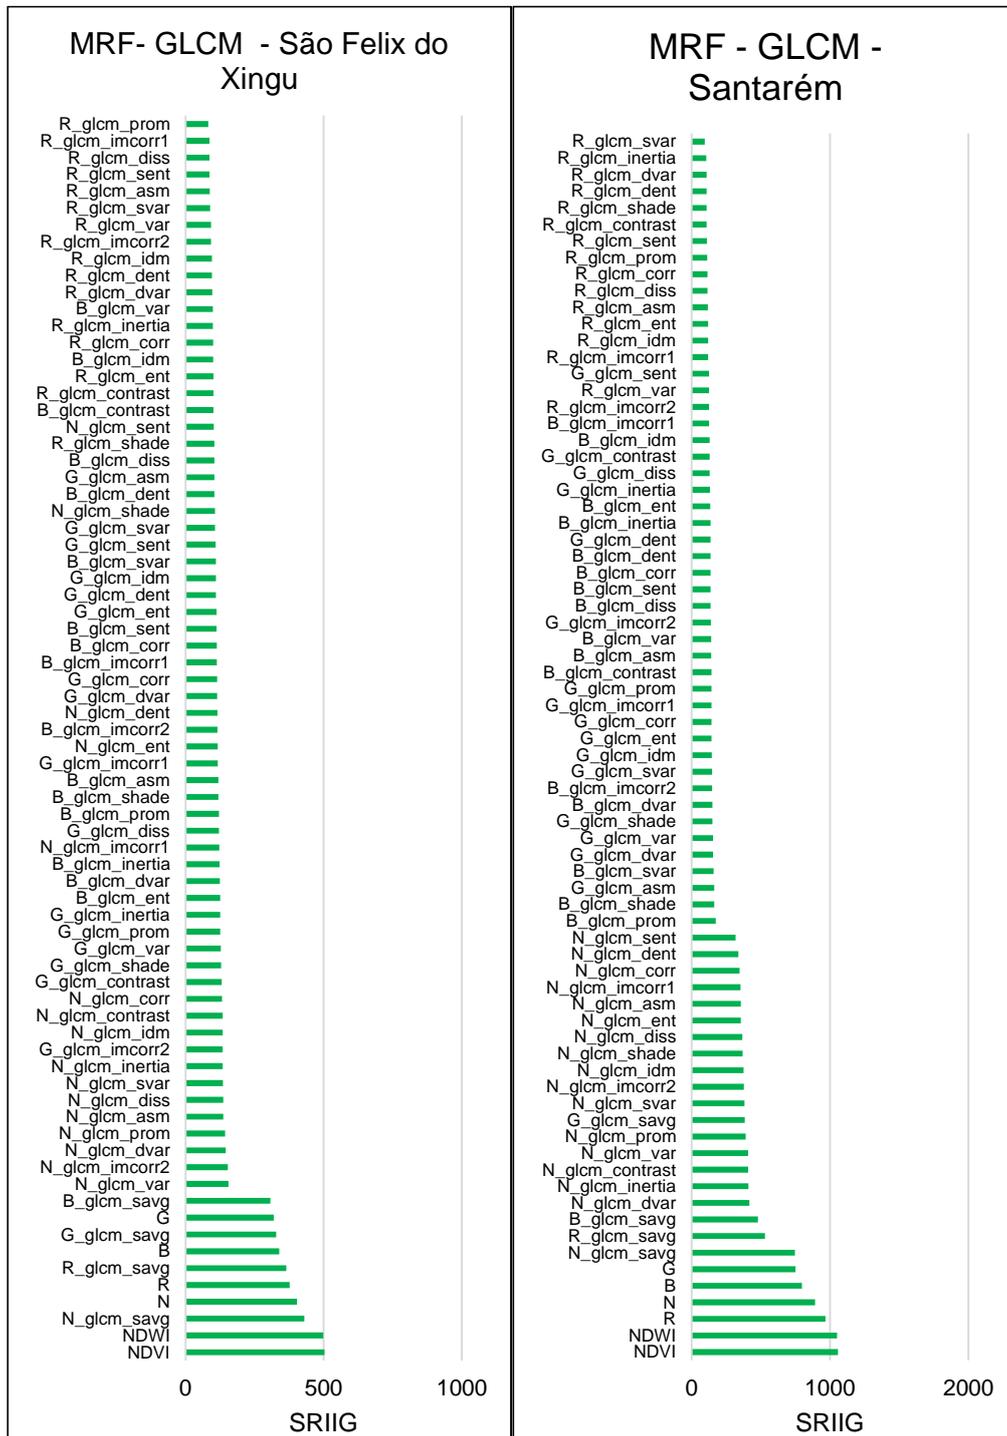
MRF: Uma floresta de árvores de decisões para cada sede municipal (*Multi-Random Forest*) utilizando as bandas espectrais, NDWI, NDVI e métricas de textura.

Figura 4.8 – Importância das variáveis (SRIIG) para o Randon Forest com árvores específicas (MRF-GLCM) para Itaituba e Novo Progresso.



MRF: Uma floresta de árvores de decisões para cada sede municipal (*Multi-Random Forest*) Utilizando As bandas espectrais, NDWI, NDVI e métricas de textura.

Figura 4.9– Importância das variáveis (SRIIG) para o Randon Forest com árvores específicas (MRF-GLCM) para São Félix do Xingu e Santarém.

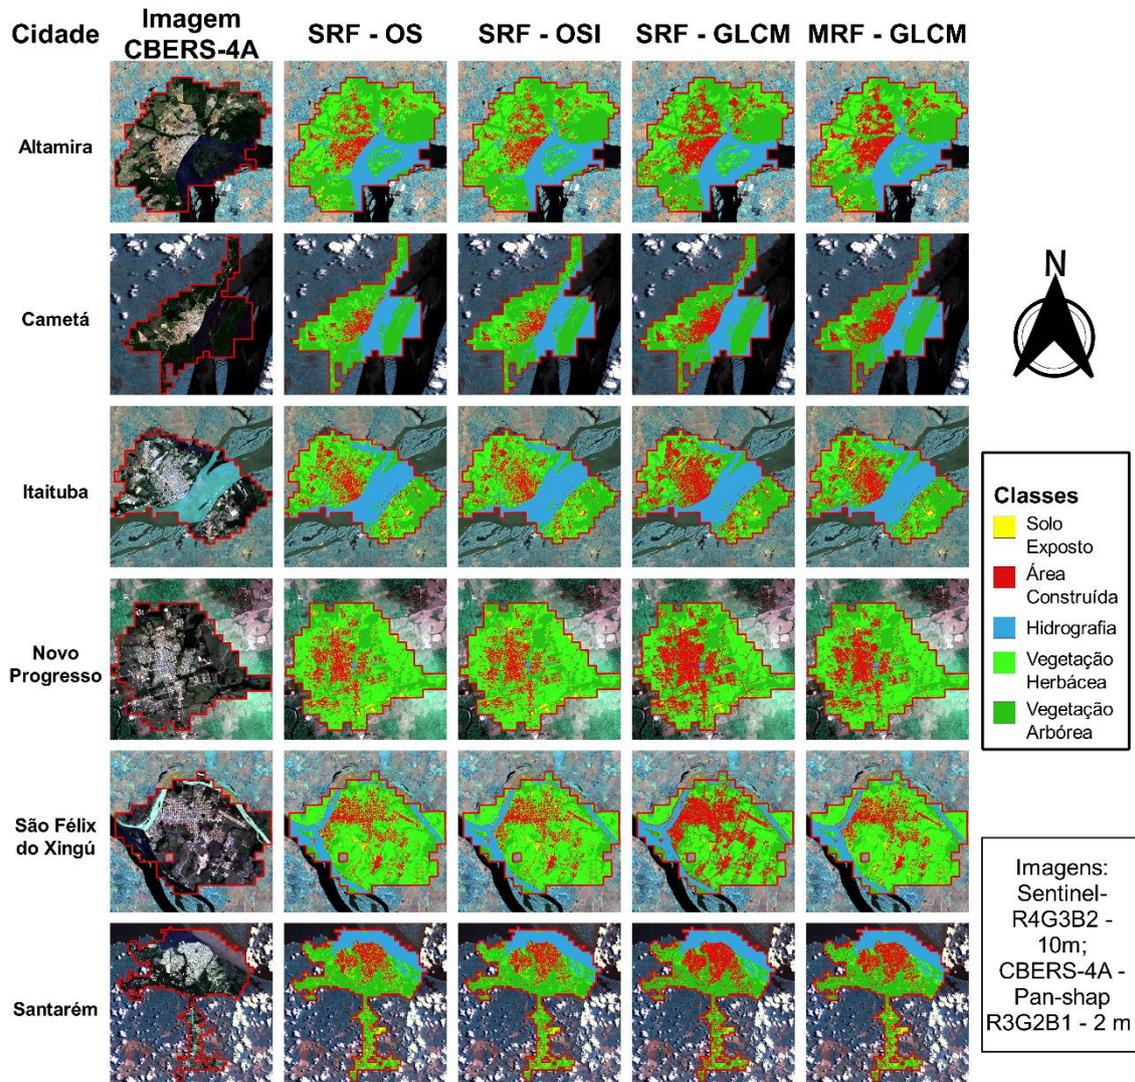


MRF: Uma floresta de árvores de decisões para cada sede municipal (*Multi-Random Forest*) Utilizando As bandas espectrais, NDWI, NDVI e métricas de textura.

#### **4.4 Classificação das áreas construídas das cidades**

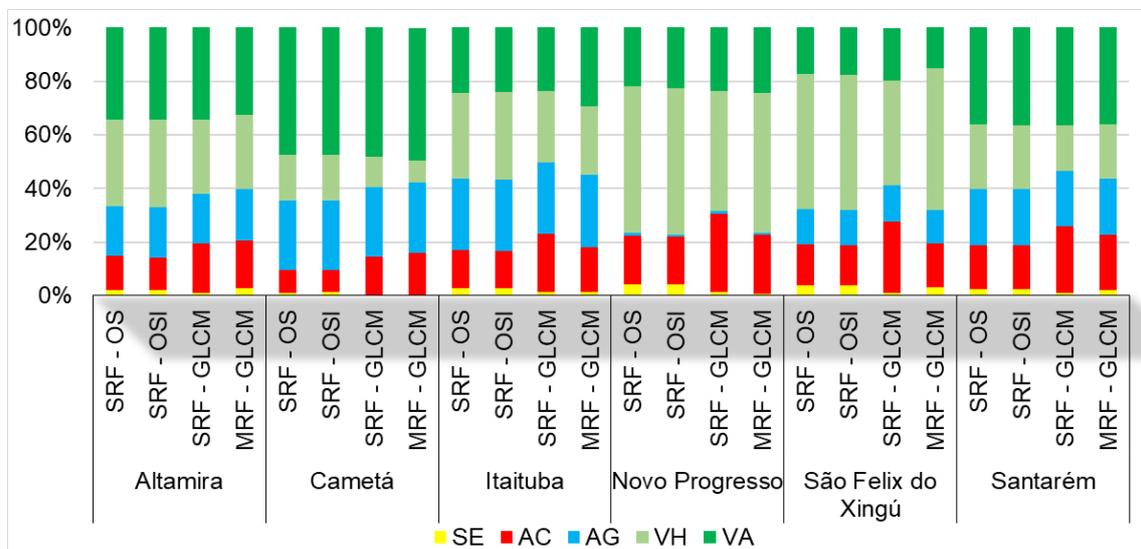
A Figura 4.10 apresenta os resultados das classificações executadas para as seis cidades estudadas considerando os quatro modelos RF utilizados: uma árvore única, considerando apenas as bandas Sentinel originais (SRF-OS), incluindo os índices biofísicos (SRF-OSI), e as bandas de textura (SRF-GLCM); e uma árvore específica para cada cidade com todas as variáveis (MRF - GLCM). De modo geral, nas áreas de processamento das cidades, a participação das classes se assemelha com predomínio das coberturas vegetais, próximo a 60% (Figura 4.11). Em Novo Progresso, a participação dessas coberturas chega a 80%, em detrimento da classe água que, nas cidades ribeirinhas representam em torno de 20% das áreas classificadas. Também próximo a 20% é a participação da classe área construída. Novo Progresso e Cametá são as áreas que apresentaram a maior e menor participação, respectivamente, da classe AC.

Figura 4.10 – Classificações de Altamira, Cameté, Itaituba, Novo Progresso, São Félix do Xingu e Santarém, para o Random Forest de árvore única (SRF): somente com dados espectrais (SRF-OS), incluindo índices biofísicos (SRF-OSI), texturas (SRF-GLCM), e uma árvore para cada cidade com todas as variáveis (MRF-GLCM).



SRF: Floresta de árvores de decisões única para todas as áreas de estudo (*Single Random Forest*); MRF: Uma floresta de árvores de decisões para cada sede municipal (*Multi-Random Forest*) Utilizando As bandas espectrais, NDWI, NDVI e métricas de textura.; OS: Utilizando somente bandas espectrais do S2 (R4-G3-B2-NIR8; *Only Spectral*); OSI: Utilizando as bandas espectrais, NDVI e NDWI (*Only Spectral and Index*); GLCM: Utilizando As bandas espectrais, NDWI, NDVI e métricas de textura.

Figura 4.11 – Proporção das classes no mapa temático predito pelas RF em cada uma das sedes municipais.



SRF: Floresta de árvores de decisões única para todas as áreas de estudo (*Single Random Forest*); MRF: Uma floresta de árvores de decisões para cada sede municipal (*Multi-Random Forest*) utilizando as bandas espectrais, NDWI, NDVI e métricas de textura.; OS: Utilizando somente bandas espectrais do S2 (R4-G3-B2-NIR8; *Only Spectral*); OSI: Utilizando as bandas espectrais, NDVI e NDWI (*Only Spectral and Index*); GLCM: Utilizando As bandas espectrais, NDWI, NDVI e métricas de textura; Global: Matriz de erro com as amostras das seis sedes; AG: Água; VH: Vegetação Herbácea; Vegetação Arbórea. AG: Água; VH: Vegetação Herbácea; Vegetação Arbórea.

Em todas as seis sedes municipais o resultado foi semelhante: a classificação utilizando somente os dados espectrais superestimou a classe solo exposto. Áreas construídas, como arruamentos não-pavimentados e construções com telhados de cerâmica foram associados à classe solo exposto. No segundo modelo RF (SRF-OSI), utilizando os índices de vegetação em conjunto com as bandas espectrais, a classe solo exposta permaneceu sendo superestimada, apresentando contudo, uma melhora na separabilidade entre as classes de vegetação (VH e VA).

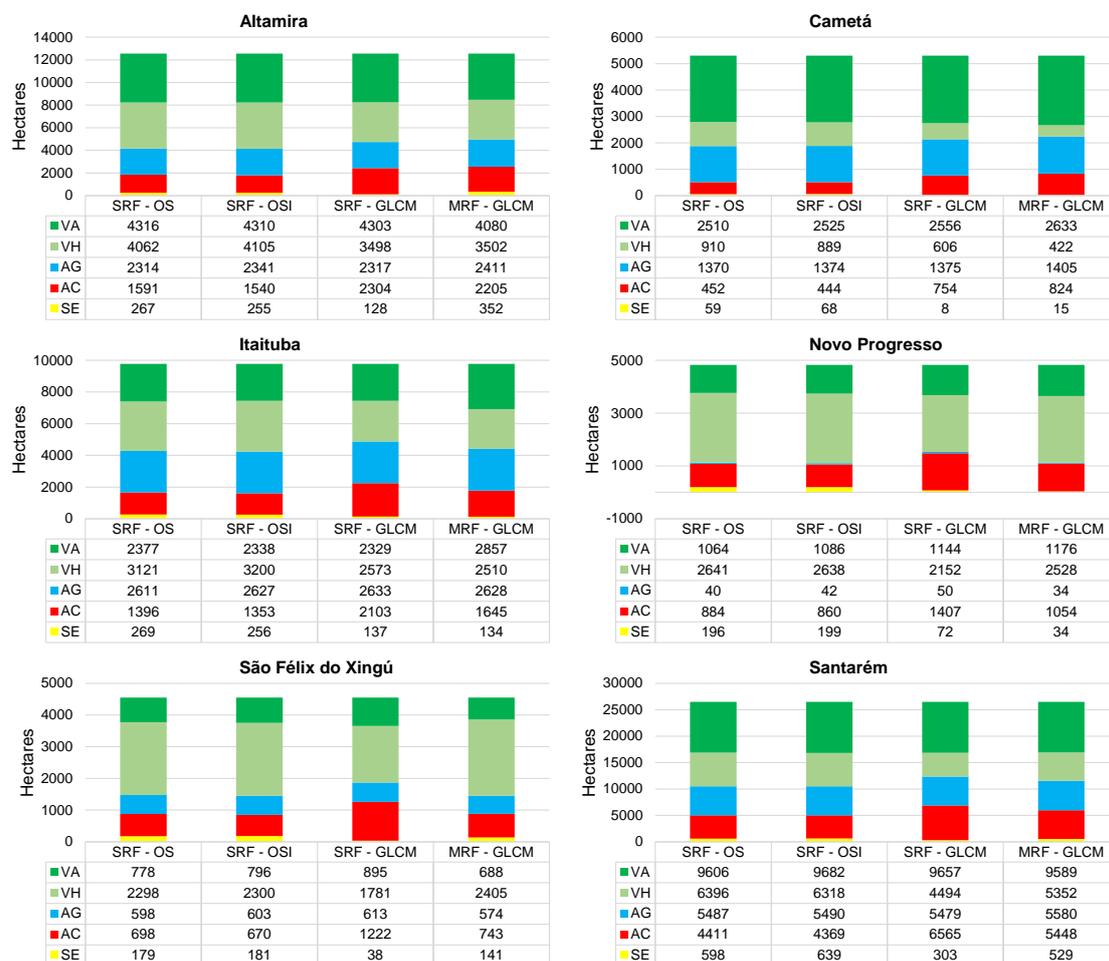
A diferença na classificação quando utilizadas as métricas de textura é visualmente perceptível nas classificações (Figura 4.10). Áreas de solo exposto passam a ser corretamente mapeadas, assim como os arruamentos não pavimentados (ruas de terra), e construções cobertas por telhados de cerâmica. Arruamentos com arborização, devido à mistura espectral, foram mapeados como vegetação nos produtos SRF-OS e SRF-OSI. Quando utilizada as métricas de textura, nos produtos SRF-GLCM, estes arruamentos foram

mapeados como área construída. A identificação dos padrões texturais possibilitou que o modelo (RF) identificasse e rotulasse corretamente os pixels de área construída no espaço intraurbano, complementando as informações espectrais que podem não ser suficientes em mapeamentos com resoluções de 10 metros em cidades amazônicas. Vale ressaltar que arruamentos não pavimentados são bastante comuns em cidades amazônicas, independentemente da extensão espacial da sede municipal. O crescimento das cidades na região historicamente não tem sido acompanhado de implementação de infraestrutura urbana suficiente (BECKER, 1997).

A partir dos gráficos das Figura 4.12, observa-se que a classe com menor proporção de área mapeada foi a classe solo exposto (SE). Em todas as sedes municipais analisadas, ocorreu diminuição dessa classe quando utilizadas métricas de textura. A maior diferença foi observada em Cametá, cuja redução foi próxima a 90%. Isso se deve ao fato, justamente, da sensibilidade do modelo com a inclusão das métricas de textura, classificar arruamentos como áreas construídas (AC).

A vegetação, especialmente a herbácea (VH), também apresentou variação com a inclusão das métricas de textura. Além da redução das confusões entre as classes de VH e VA e de VH com AC, observada em lotes residenciais, essas métricas auxiliaram a correta identificação dos diferentes tipos de vegetação. Áreas vegetadas com distintas estruturas, mas com assinaturas espectrais semelhantes, são distintas quando se incorpora a informação textural. Torna-se possível por exemplo, a distinção de áreas de mata ciliar, ou de agricultura, em diferentes estágios fenológicos (YUAN, 2019).

Figura 4.12 - Área das classes no mapa temático predito pelas RF em cada uma das sedes municipais.



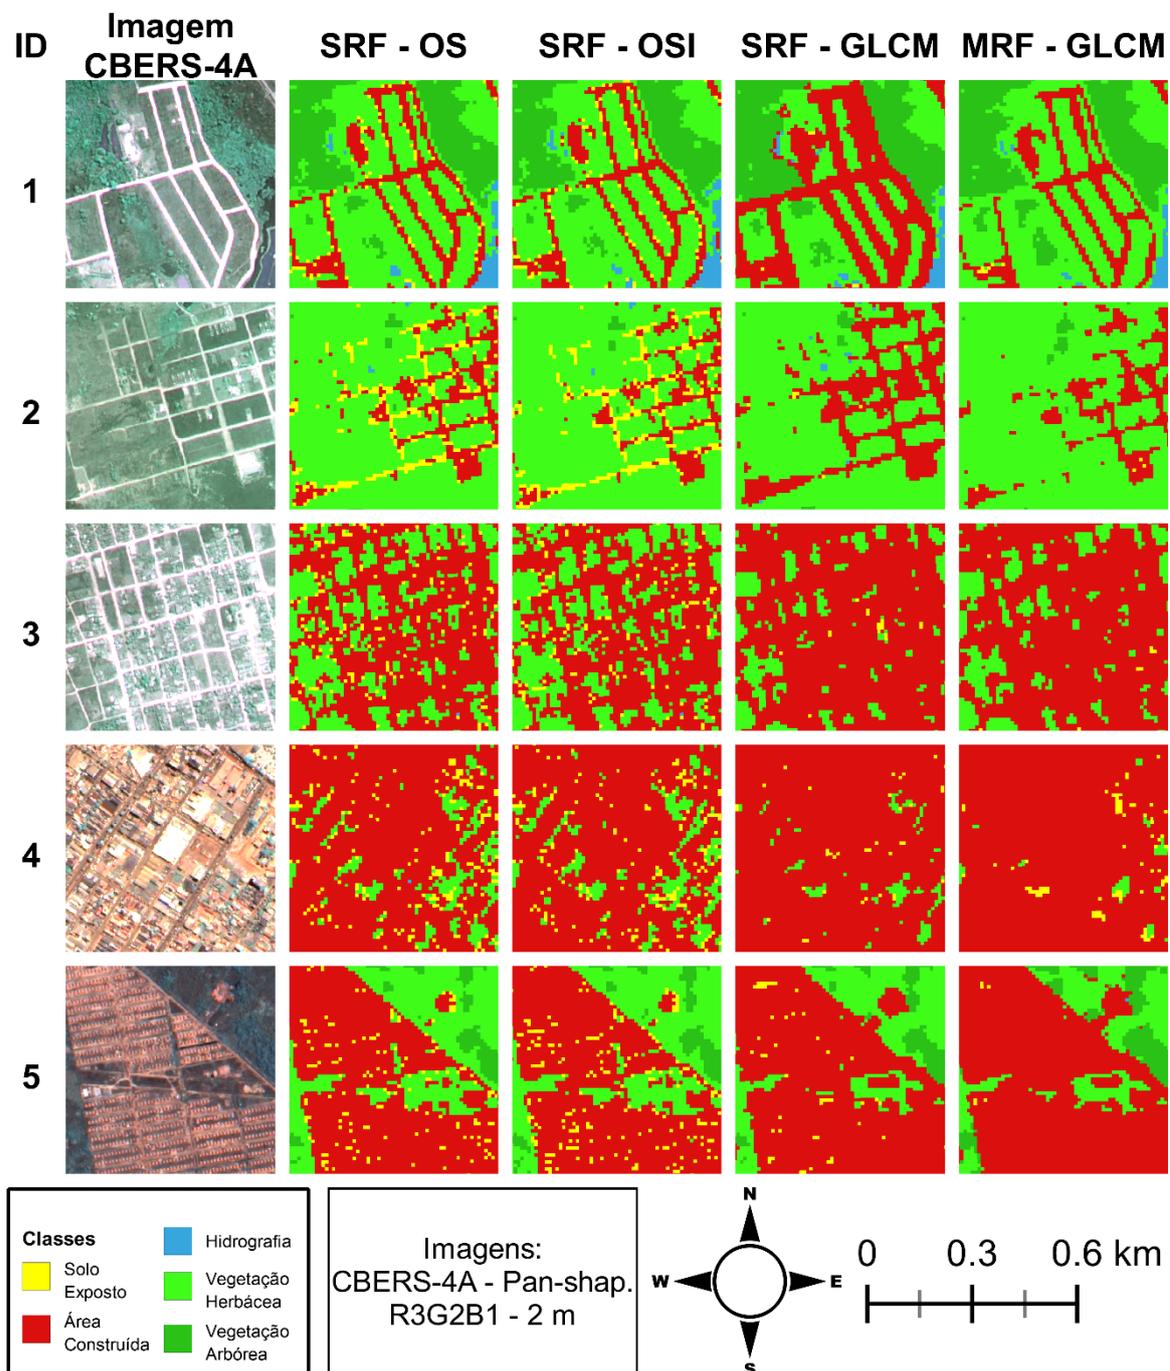
SRF: Floresta de árvores de decisões única para todas as áreas de estudo (*Single Random Forest*); MRF: Uma floresta de árvores de decisões para cada sede municipal (*Multi-Random Forest*) Utilizando As bandas espectrais, NDWI, NDVI e métricas de textura.; OS: Utilizando somente bandas espectrais do S2 (R4-G3-B2-NIR8; *Only Spectral*); OSI: Utilizando as bandas espectrais, NDVI e NDWI (*Only Spectral and Index*); GLCM: Utilizando As bandas espectrais, NDWI, NDVI e métricas de textura; Global: Matriz de erro com as amostras das seis sedes; AG: Água; VH: Vegetação Herbácea; Vegetação Arbórea. AG: Água; VH: Vegetação Herbácea; Vegetação Arbórea.

Entre os métodos com inclusão das métricas texturais, observaram-se diferenças entre os resultados obtidos de uma única floresta de árvores para todas as cidades (SRF-GLCM) e de uma floresta de árvores para cada cidade analisada (MRF-GLCM). Ao adaptar o RF para cada cidade, pode-se definir melhor a real extensão da área urbanizada das cidades, considerando as particularidades locais. Nas cidades analisadas, Gonçalves et al. (2021) identificaram seis padrões espaciais de ocupação urbana, considerando a

densidade de construções, tipo de pavimentação, estrutura e distribuição da cobertura vegetal e configuração das infraestruturas urbanas obtidas a partir de imagens RapidEye. Os referidos autores observaram que o comportamento desses padrões difere entre as cidades, compondo diferentes perfis urbanos. O padrão associado a uma maior consolidação da ocupação urbana, com alta densidade de construções e superfícies impermeáveis, arruamento com cobertura asfáltica e pouca vegetação arbustiva, ocorre apenas em cidades com mais de 50.000 habitantes, notadamente, Santarém, Cametá, Itaituba e Altamira. Por outro lado, nas cidades de Novo Progresso e São Félix do Xingu, o padrão associado à baixa densidade de construções é dominante, compreendendo quase 50% da extensão urbana.

Exemplos desses padrões e os respectivos resultados da classificação são ilustrados na Figura 4.13 e Figura 4.12. Na Figura 4.13 IDs 1 e 2, o arruamento é confundido com solo exposto no SRF-OS e OSI, e superestimado no SRF-GLCM. Por sua vez, em áreas com média e alta densidade de construções, com a inclusão das métricas texturais, a classe área construída (AC) é mais abrangente para capturar algumas especificidades na produção dos espaços construídos das cidades amazônicas (Figura 4.13– ID 3, 4 e 5). Nessas áreas há uma mistura espectral maior no pixel, de modo que, com o uso apenas das variáveis espectrais, o pixel pode ser classificado como vegetação ou solo exposto em função das frações dessas classes na mistura. Assim, com a adição de métricas de textura, a classe AC passa a incorporar pixels classificados nos métodos SRF-OS e SRF-OSI como vegetação herbácea (VH) e solo exposto (SE), mas que possuem contribuição de áreas construídas. Ressalta-se que o recorte da ID 5 representa um conjunto habitacional do programa Minha Casa Minha Vida (PMCMV).

Figura 4.13 - Área das classes no mapa temático predito pelas RF em cada uma das sedes municipais.



#### 4.5 Avaliação da acurácia temática das classificações

A avaliação e acurácia temática permite avaliar analiticamente os resultados dentre as quatro classificações executadas utilizando o RF. Matrizes de erro foram construídas e, a partir delas, calculadas as acurácias do produtor, consumidor e global e o coeficiente de Kappa.

A Figura 4.14 apresenta as matrizes de erro para todas as classificações. De modo geral, os principais erros estão associados às classes solo exposto (SE) e área construída (AC), especialmente nas classificações OS e OSI. A inclusão das métricas texturais no grupo de variáveis preditoras reduziu significativamente esses erros, especialmente no modelo adaptado a cada cidade (MRF-GLCM). Ou seja, dentre as quatro classificações realizadas, a melhor foi o MRF-GLCM, o que também pode se considerar um *overfitting* do modelo a cada sede municipal. Esses resultados são condizentes com o descrito em diversos estudos: a inclusão de métricas texturais resultou na significativa melhora da classificação (ZHENG et al., 2017; TAVARES et al., 2019).

Figura 4.14 - Matrizes de erro para todas as classificações Randon Forest com árvore única (SRF) e múltiplas (MRF).

		Referência						Referência						
		SRF - OS						SRF - OSI						
Classificação	Classe	SE	AC	AG	VH	VA	Total	Classe	SE	AC	AG	VH	VA	Total
	SE	814	257	0	4	0	1075	SE	828	244	0	3	0	1075
	AC	335	2394	1	7	0	2737	AC	289	2442	1	5	0	2737
	AG	2	14	1485	5	0	1506	AG	3	14	1483	6	0	1506
	VH	1	1	1	1653	1	1657	VH	2	3	1	1651	0	1657
	VA	0	0	0	0	4406	4406	VA	0	0	0	0	4406	4406
	<b>Total</b>	1152	2666	1487	1669	4407	10752	<b>Total</b>	1122	2703	1485	1665	4406	10810
	<b>Total de amostras</b>						11381	<b>Total de amostras</b>						11381
		SRF - GLCM						MRF - Global						
Classificação	Classe	SE	AC	AG	VH	VA	Total	Classe	SE	AC	AG	VH	VA	Total
	SE	859	212	0	4	0	1075	SE	966	109	0	0	0	1075
	AC	97	2637	2	1	0	2737	AC	92	2641	2	2	0	2737
	AG	4	13	1485	4	0	1506	AG	0	7	1499	0	0	1506
	VH	0	0	1	1656	0	1657	VH	0	0	2	1655	0	1657
	VA	0	0	0	0	4406	4406	VA	0	0	0	0	4406	4406
	<b>Total</b>	960	2862	1488	1665	4406	11043	<b>Total</b>	1058	2757	1503	1657	4406	11167
	<b>Total de amostras</b>						11381	<b>Total de amostras</b>						11381

SRF: Floresta de árvores de decisões única para todas as áreas de estudo (*Single Random Forest*); MRF: uma floresta de árvores de decisões para cada sede municipal (*Multi- Random Forest*). Utilizando As bandas espectrais, NDWI, NDVI e métricas de textura.; OS: Utilizando somente bandas espectrais do S2 (R4-G3-B2-NIR8; *Only Spectral*); OSI: Utilizando as bandas espectrais, NDVI e NDWI (*Only Spectral and Index*); GLCM: Utilizando As bandas espectrais, NDWI, NDVI e métricas de textura; Global: Matriz de erro com as amostras das seis sedes; AG: Água; VH: Vegetação Herbácea; Vegetação Arbórea.

A Figura 4.15 apresenta as matrizes de erro do MRF-GLCM para cada uma das seis cidades analisadas. Observa-se que independentemente do tamanho e perfil urbano das cidades, os erros estão relacionados às confusões entre as classes solo exposto (SE) e área construída (AC) e ocorrem em magnitudes semelhantes. Dessa forma, pode-se dizer que o método MRF-GLCM é sensível às particularidades das cidades analisadas. Isso é especialmente relevante, haja vista que em um estudo exploratório com bases globais de mapeamento de coberturas urbanas, Gonçalves et al. (2021) observaram que áreas urbanizadas amazônicas com menor adensamento da ocupação e estrutura urbana menos consolidada são subdimensionadas nessas bases.

Figura 4.15 - Matrizes de erro para as classificações Randon Forest em Altamira, Cametá, Itaituba, Novo Progresso, São Félix do Xingu e Santarém.

Referência								Referência							
MRF - Altamira								MRF - Novo Progresso							
Classificação	Classe	SE	AC	AG	VH	VA	Total	Classe	SE	AC	AG	VH	VA	Total	
	SE	149	18	0	0	0	167	SE	128	23	0	0	0	151	
	AC	13	402	0	0	0	415	AC	10	361	0	0	0	371	
	AG	0	0	754	0	0	754	AG	0	0	91	0	0	91	
	VH	0	0	0	376	0	376	VH	0	0	0	233	0	233	
	VA	0	0	0	0	1410	1410	VA	0	0	0	0	685	685	
	<b>Total</b>	162	420	754	376	1410	3091	<b>Total</b>	138	384	91	233	685	1498	
<b>Total de amostras</b>						3122	<b>Total de amostras</b>						1531		
MRF - Cameta								MRF - São Felix do Xingú							
Classificação	Classe	SE	AC	AG	VH	VA	Total	Classe	SE	AC	AG	VH	VA	Total	
	SE	34	4	0	0	0	38	SE	61	9	0	0	0	70	
	AC	1	184	1	0	0	186	AC	2	325	1	1	0	329	
	AG	0	0	55	0	0	55	AG	0	7	217	0	0	224	
	VH	0	0	0	80	0	80	VH	0	0	1	560	0	561	
	VA	0	0	0	0	469	469	VA	0	0	0	0	122	122	
	<b>Total</b>	35	188	56	80	469	822	<b>Total</b>	63	341	219	561	122	1285	
<b>Total de amostras</b>						828	<b>Total de amostras</b>						1306		
MRF - Itaituba								MRF - Santarém							
Classificação	Classe	SE	AC	AG	VH	VA	Total	Classe	SE	AC	AG	VH	VA	Total	
	SE	417	30	0	0	0	447	SE	177	25	0	0	0	202	
	AC	60	454	0	0	0	514	AC	6	915	0	1	0	922	
	AG	0	0	156	0	0	156	AG	0	0	226	0	0	226	
	VH	0	0	1	345	0	346	VH	0	0	0	61	0	61	
	VA	0	0	0	0	1065	1065	VA	0	0	0	0	655	655	
	<b>Total</b>	477	484	157	345	1065	2437	<b>Total</b>	183	940	226	62	655	2034	
<b>Total de amostras</b>						2528	<b>Total de amostras</b>						2066		
<b>Total de amostras</b>								<b>11381</b>							

MRF: Uma floresta de árvores de decisões para cada sede municipal (*Multi- Random Forest*) Utilizando As bandas espectrais, NDWI, NDVI e métricas de textura. AG: Água; VH: Vegetação Herbácea; Vegetação Arbórea

A Figura 4.16 apresenta as acurácias e o coeficiente global obtidos em cada método para cada classe e cidade. De modo geral, há uma sensível melhora da acurácia global (AG) e do coeficiente de Kappa (CK) com o emprego das métricas texturais. Analisado as classes SE e AC, o resultado demonstra significativa melhora do resultado com o emprego das métricas do GLCM. A acurácia do produtor (AP) passa de 71% e 89% (SRF-OS) para quase 90% e 97% (MRF-GLCM) nas classes SE e AC, respectivamente. Nessas classes, a

acurácia do consumidor (AC), passa dos 85% para quase 96%. Assim, as métricas de textura permitiram a melhor separabilidade dessas duas classes, de modo que o modelo seja capaz de tomar decisões mais precisas na existência de nuances espectrais entre feições.

Figura 4.16 - Acurácia do produtor, consumidor, global e coeficiente de Kappa para todas classes e sedes municipais analisadas.

Classe	SE		AC		AG		VH		VA		AG	CK	
	AP	AC	AP	AC	AP	AC	AP	AC	AP	AC			
MRF - GLCM	ALT	89.2%	92.0%	96.9%	95.7%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	99.0%	0.9859
	CAM	89.5%	97.1%	98.9%	97.9%	100.0%	98.2%	100.0%	100.0%	100.0%	100.0%	99.3%	0.9882
	ITA	93.3%	87.4%	88.3%	93.8%	100.0%	99.4%	99.7%	100.0%	100.0%	100.0%	96.4%	0.9505
	NP	84.8%	92.8%	97.3%	94.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	97.8%	0.9694
	SFX	87.1%	96.8%	98.8%	95.3%	96.9%	99.1%	99.8%	99.8%	100.0%	100.0%	98.4%	0.9773
	STR	87.6%	96.7%	99.2%	97.3%	100.0%	100.0%	100.0%	98.4%	100.0%	100.0%	98.5%	0.9771
	Global	89.9%	91.3%	96.5%	95.8%	99.5%	99.7%	99.9%	99.9%	100.0%	100.0%	98.1%	0.9747
SRF	GLCM	79.9%	89.5%	96.3%	92.1%	98.6%	99.8%	99.9%	99.5%	100.0%	100.0%	97.0%	0.9600
	OSI	73.8%	85.6%	90.3%	89.2%	98.5%	99.9%	98.5%	99.2%	100.0%	100.0%	96.3%	0.9508
	OS	71.8%	85.8%	89.8%	88.0%	98.6%	99.9%	99.8%	99.0%	100.0%	100.0%	96.3%	0.9496

AP: Acurácia do produtor; AC: Acurácia do consumidor; AG: Global; Coeficiente de Kappa; SRF: Floresta de árvores de decisões única para todas as áreas de estudo (*Single Random Forest*); MRF: Uma floresta de árvores de decisões para cada sede municipal (*Multi-Random Forest*) Utilizando As bandas espectrais, NDWI, NDVI e métricas de textura.; OS: Utilizando somente bandas espectrais do S2 (R4-G3-B2-NIR8; *Only Spectral*); OSI: Utilizando as bandas espectrais, NDVI e NDWI (*Only Spectral and Index*); GLCM: Utilizando As bandas espectrais, NDWI, NDVI e métricas de textura; Global: Matriz de erro com as amostras das seis sedes. SE: Solo exposto; AC: Área Construída; AG: Água; VH: Vegetação Herbácea; Vegetação Arbórea; ALT: Altamira; CAM: Cameté; ITA: Itaituba; NP: Novo Progresso; São Felix do Xingú; Santarém.

## 5 CONCLUSÕES

Embora algumas iniciativas forneçam uma aproximação da dimensão espacial da urbanização amazônica, metodologias a partir de métodos genéricos podem invisibilizar determinadas feições espaciais (POWELL; ROBERTS, 2008; DAL ASTA; AMARAL; VIEIRA MONTEIRO, 2017) Essa questão é especialmente relevante para a Amazônia, haja visto as inúmeras particularidades do processo de urbanização dessa região (BECKER, 2013).

Este trabalho contribui com a construção de uma metodologia para caracterização das áreas urbanizadas em cidades amazônicas por meio de mapeamento baseado em dados e ferramentas de SR. Ainda que demandem mais testes, os procedimentos propostos para identificação de áreas urbanizadas construídas, com base em imagens de luzes noturnas, bem como todos os algoritmos para composição das imagens mosaicos Sentinel 2, aquisição de amostras, testes de modelo Random Forest e classificação digital das áreas urbanizadas construídas, estão disponíveis para serem aplicados em outras áreas.

Ao classificar a cobertura intraurbana em seis cidades bastante diversas entre si, o método proposto explorou a variabilidade dos alvos presentes nesses espaços, incluindo as particularidades regionais em seu escopo. Para classificar as diferentes coberturas no espaço intraurbano amazônico, a classe Área Construída incluiu não apenas superfícies impermeáveis, como construções e edificações, mas também áreas de movimentação de solo, interior de lotes e arruamentos de solo exposto, comuns nas cidades amazônicas. Essa definição partiu do pressuposto de que esses elementos, juntamente com outras coberturas naturais (vegetação e água), resultantes de atividades humanas moldam o espaço produzido em uma área urbanizada (MAGALHÃES; TOSCANO; BERGAMASCHI, 2013).

Para esta abordagem, desenvolveu-se um procedimento para analisar o potencial de métricas texturais para esta classificação, considerando a classificação por árvore de decisão Random Forest. De modo geral, pode-se

afirmar que o conjunto de métricas texturais testadas trouxe informação complementar às demais variáveis espectrais.

Dentre os modelos RF testados, a inclusão das métricas texturais (GLCM) assegurou uma sensível melhora na detecção das classes de interesse. De modo geral, o SRF-GLCM pode ser considerado o modelo global mais adequado para a classificação da cobertura intraurbana das cidades analisadas, com potencial para emprego em outras cidades amazônicas. As análises das acurácias dos modelos RF de formato únicos, indicaram resultados progressivamente melhores na ordem: apenas com as bandas originais (SRF-OS), com a inclusão dos índices biofísicos, e com a inclusão das métricas de textura (SRF-GLCM).

Ao se ajustar uma floresta de árvores de decisão para cada cidade estudada, os modelos RF no formato múltiplo (MRF-GLCM) apresentaram alteração na ordem de importância das métricas. Esta adaptação do processo de amostragem e classificação para cada cidade resulta também em aumento da acurácia em relação ao SRF-GLCM. Ou seja, ainda que seja factível a aplicação de um único modelo RF para diferentes cidades em escala regional, e neste caso, SRF-GLCM seria o mais indicado, modelos específicos são mais indicados para estudos de uma cidade ou município, em escala mais local.

Considerando-se os resultados obtidos pelo método e o potencial para replicação e expansão para um conjunto maior de cidades amazônicas, sugere-se uma avaliação mais detalhada dos erros e acertos a partir de validação em campo. Além disso, estudos em outras cidades são essenciais para avaliar a abrangência das amostras utilizadas e a construção de uma biblioteca espectral representativa das cidades amazônicas. Dados auxiliares, como os disponibilizados pelo IBGE e OpenStreetMap, também podem ser considerados para um aprimoramento do método proposto.

Por fim, a disponibilidade de diferentes bases de dados de imagens de SR de resolução suficiente para o mapeamento interurbano, associadas a ferramentas que facilitam o acesso e manipulação de grandes volumes de dados, constituem recurso poderoso para testes de metodologia e geração de informação sobre as

áreas urbanizadas. Mapeamentos das coberturas urbanas, como proposto neste trabalho, possibilitam a análise e estudo do fato urbano, em diferentes realidades, permitindo a construção de narrativas que tornem visíveis as particularidades e especificidades locais, como as das cidades amazônicas.

## REFERENCIAS BIBLIOGRAFICAS

ALAHMADI, M.; ATKINSON, P. M.; MARTIN, D. A comparison of small-area population estimation techniques using built-area and height data, Riyadh, Saudi Arabia. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 9, n. 5, p. 1959–1969, 2016.

ALMEIDA, C. A.; COUTINHO, A. C.; ESQUERDO, J. C. DALLA M.; ADAMI, M.; VENTURIERI, A.; DINIZ, C. G.; DESSAY, N.; DURIEUX, L.; GOMES, A. R. High spatial resolution land use and land cover mapping of the Brazilian legal Amazon in 2008 using Landsat-5/TM and MODIS data. **Acta Amazonica**, v. 46, n. 3, p. 291–302, 2016.

ALMEIDA, C. M.; PEREIRA, M. N.; GONÇALVES, C. D. A. B.; SOUZA, Í. M.; MOREIRA, J. C.; MIGLIORANZA, E.; NOVAES JUNIOR, R. A.; FLORENZANO, T. G. O sensoriamento remoto como instrumental para o mapeamento da urbanização dispersa. In: SEMINÁRIO INTERNACIONAL SOBRE URBANIZAÇÃO DISPERSA E MUDANÇAS NO TECIDO URBANO, 2007. **Anais...** 2007.

ALTAMIRA. PREFEITURA MUNICIPAL. **Sobre Altamira**. Disponível em: <<http://altamira.pa.gov.br/site/historia/>>. Acesso em: 6 mar. 2020.

ALVES, P. A.; AMARAL, S.; ESCADA, M. I. S.; MONTEIRO, A. M. V. Explorando as relações entre a dinâmica demográfica, estrutura econômica e mudanças no uso e cobertura da terra no sul do Pará: lições para o distrito florestal sustentável da BR-163. **Geografia (Rio Claro)**, v. 35, n. 1, p. 165–182, 2010.

AMARAL, S. **Geoinformação para estudos demográficos**: representação espacial de dados de população na Amazônia Brasileira. 2003. 166 p. Tese (Doutorado em Engenharia de Transportes) - Universidade de São Paulo, São Paulo, 2003.

AMARAL, S.; CÂMARA, G.; MONTEIRO, A. M. V.; QUINTANILHA, J. A.; ELVIDGE, C. D. Estimating population and energy consumption in Brazilian Amazonia using DMSP night-time satellite data. **Computers, Environment and Urban Systems**, v. 29, n. 2, p. 179–195, 2005.

AMARAL, S.; MEDEIROS DÓRIA, V. E.; DAL'ALASTA, A. P.; MIGUEL, A.; MONTEIRO, V. Luzes noturnas do sensor VIIRS para a identificação de atividades humanas na Amazônia Brasileira: observações de uma região na Transamazônica (PA). In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17., 2015. **Anais....** São José dos Campos; INPE, 2015. p. 2285–2292.

AMARAL, S.; RIBEIRO, R. M.; GONÇALVES, G. C.; DAL'ASTA, A. P. Imagens CBERS para caracterização da expansão urbana na Amazônia. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19., 2019, Santos - Brasil.

**Anais...** São José dos Campos: INPE, 2019. Disponível em:

<<https://proceedings.science/sbsr-2019/trabalhos/imagens-cbers-para-caracterizacao-da-expansao-urbana-na-amazonia?lang=pt-br>>.

ANCHANG, J. Y.; ANANGA, E. O.; PU, R. An efficient unsupervised index based approach for mapping urban vegetation from IKONOS imagery.

**International Journal of Applied Earth Observation and Geoinformation**, v. 50, p. 211–220, 2016.

ANGEL, S.; PARENT, J.; CIVCO, D. Urban sprawl metrics: an analysis of global urban expansion using GIS. **American Society for Photogrammetry and Remote Sensing - ASPRS Annual Conference 2007: Identifying Geospatial Solutions**, v. 1, p. 22–33, 2007.

AWUAH, K. T.; NÖLKE, N.; FREUDENBERG, M.; DIWAKARA, B. N.; TEWARI, V. P.; KLEINN, C. Spatial resolution and landscape structure along an urban-rural gradient: do they relate to remote sensing classification accuracy? – a case study in the megacity of Bengaluru, India. **Remote Sensing Applications: Society and Environment**, v. 12, p. 89–98, 2018.

BARBIERI, A. F. Mobilidade populacional, meio ambiente e uso da terra em áreas de fronteira: uma abordagem multiescalar. **Revista Brasileira de Estudos de População**, v. 24, n. 2, p. 225–246, 2007.

BECKER, B. K. **Amazônia**. 5. ed. [S.l.]: Atica, 1997. 112 p. ISBN 8508036086.

BECKER, B. K. Geopolítica da Amazônia. Conferência do Mês do Instituto de Estudos Avançados da USP proferida pela autora em 27 de abril de. **Estudos Avançados**, v. 19, n. 53, p. 71–86, 2005.

BECKER, B. K. Cidades Amazônicas : surtos econômicos e perspectivas. **Espaço Aberto, PPGG - UFRJ**, v. 3, n. 1, p. 7–18, 2013.

BELGIU, M.; DRĂGU, L. Random forest in remote sensing: a review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 2016.

BHASKARAN, S.; PARAMANANDA, S.; RAMNARAYAN, M. Per-pixel and object-oriented classification methods for mapping urban features using Ikonos satellite data. **Applied Geography**, v. 30, n. 4, p. 15, 2010.

BHATTA, B. **Remote sensing and GIS**. [S.l.]: Oxford University Press, 2008. 685 p. ISBN 9780195692396.

BHATTA, B. **Analysis of urban growth and sprawl from remote sensing data**. Berlin: Springer-Verlag, 2010. ISBN 9783642052989.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, p. 5–32, 2001.

BRIOTTET, X.; CHEHATA, N.; OLTRA-CARRIO, R.; LE BRIS, A.; WEBER, C. Optical remote sensing in urban environments. **Land Surface Remote Sensing in Urban and Coastal Areas**, p. 1–62, 2016.

BRONDIZIO, E. S. The elephant in the room: amazonian cities deserve more attention. **Climate Change and Sustainability Discussions**, p. 15–26, 2016.

CARDOSO, A. C.; CAROLINA, A.; GOMES, T. O urbano contemporâneo na fronteira de expansão do capital : padrões de transformações espaciais em seis cidades do Pará , Brasil. In: CONFERÊNCIA DO PNUM MORFOLOGIA URBANA E OS DESAFIOS DA URBANIDADE, 4., 2016. **Anais...** 2016.

CARDOSO, A. C. D.; FERREIRA LIMA, J. J.; XIMENES PONTE, J. P.; VENTURA NETO, R. S.; RODRIGUES, R. M. Urban morphology of amazonian cities: the experience of the Amazon Cities Research Group of Federal University of Pará. **Urbe**, v. 12, p. 1–18, 2020.

CARDOSO, A. C. D.; LIMA, J. J. F. Tipologias e padrões de ocupação urbana na Amazônia Oriental: para que e para quem? In: CARDOSO, A. C. D. (Org.). **O rural e o urbano na Amazônia: diferentes olhares em perspectivas**. Belém: UFPA, 2006. p. 55–93.

CARDOSO, A. C. D.; PEREIRA, G. DE J. C.; NEGRÃO, M. R. G. Urbanização e estratégias de desenvolvimento no Pará: da ocupação ribeirinha aos assentamentos precários. **Novos Cadernos do NAEA**, v. 16, p. 255–279, 2013.

CARDOSO, A. C.; MELO, A. C.; GOMES, T. O urbano contemporâneo na fronteira de expansão do capital. **Revista de Morfologia Urbana**, v. 4, n. 1, p. 5–28, 2017.

CARDOSO, A.; FERNANDES, D.; BASTOS, A.; SOUSA, C. A Metrópole Belém e sua centralidade na Amazônia oriental Brasileira. **Eure**, v. 41, n. 124, p. 201–223, 2015.

CASTRO, E. **Cidades na floresta**. [S.l.]: Anablume, 2009. 352 p. ISBN 9788574199283.

CHAIRET, R.; BEN SALEM, Y.; AOUN, M. Features extraction and land cover classification using Sentinel 2 data. In: INTERNATIONAL CONFERENCE ON SCIENCES AND TECHNIQUES OF AUTOMATIC CONTROL AND COMPUTER ENGINEERING, 19., 2019. **Proceedings...** 2019. p. 497–500.

CHEN, Y.; XIE, W.; XU, X. Changes of population, built-up land, and cropland exposure to natural hazards in China from 1995 to 2015. **International Journal of Disaster Risk Science**, v. 10, n. 4, p. 557–572, 2019.

CLAUSI, D. A. An analysis of co-occurrence texture statistics as a function of grey level quantization. **Canadian Journal of Remote Sensing**, v. 28, n. 1, p. 45–62, 2002.

COLSTOUN, E. C. B.; HUANG, C.; WANG, P.; TILTON, J. C.; PHILLIPS, J.; NIEMCZURA, S.; LING, P.; WOLFE, R. Documentation for the Global Man-made Impervious Surface (GMIS) dataset from Landsat. **NASA Socioeconomic Data and Applications Center (SEDAC)**, v. 1, n. 2010, p. 1–13, 2017.

CONNERS, R. W.; TRIVEDI, M. M.; HARLOW, C. A. Segmentation of a high-resolution urban scene using texture operators (Sunnyvale, California). **Computer Vision, Graphics, & Image Processing**, v. 25, n. 3, p. 273–310, 1984.

CORREA, R. L. A periodização da rede urbana brasileira. **Revista Brasileira de Geografia Física**, v. 49, n. 3, p. 39–68, 1987.

COSTA, T. D. C. S. **A relação cidade e rio na Amazônia**: mudanças e permanências frente ao processo de urbanização recente, o exemplo de Santarém (PA). 2012. 163p. Dissertação (Mestrado em Planejamento do Desenvolvimento) - Universidade Federal do Pará, Belém, 2012. Disponível em:  
<[http://repositorio.ufpa.br/jspui/bitstream/2011/11030/1/Dissertacao\\_RelacaoCidadeRio.pdf](http://repositorio.ufpa.br/jspui/bitstream/2011/11030/1/Dissertacao_RelacaoCidadeRio.pdf)>.

CRUZ, V. C. **No espelho das águas do Rio Tocantins me Vejo Caboclo**. Belém: Universidade Federal do Pará, 2003.

DAL'ASTA, A. P.; BRIGATTI, N.; AMARAL, S.; ESCADA, M. I. S.; MONTEIRO, A. M. V. Identifying spatial units of human occupation in the Brazilian Amazon using Landsat and CBERS multi-resolution imagery. **Remote Sensing**, v. 4, n. 1, p. 68–87, 2012.

DAL'ASTA, A. P.; SOUZA, A. R.; PINHO, C. M. D.; SOARES, F. R.; REGO, G. F. J.; SIQUEIRA, J. M.; ESCADA, M. I. S.; BRIGATTI, N.; AMARAL, S.; CAMILOTTI, V. L.; DÓRIA, V. E. M.; COSTA, L. C. **As comunidades de terra firme do sudoeste do Pará: população, infraestrutura, serviços, uso da terra e conectividades. expedição de campo 2013 versão atualizada**. São José dos Campos: INPE, 2017. Disponível em: <<http://mtc-m16d.sid.inpe.br/rep/8JMKD3MGP7W/388SBJL>>.

DAL ASTA, P. A.; AMARAL, S.; VIEIRA MONTEIRO, A. M. Um modelo para a representação espaço-temporal do fenômeno urbano na Amazônia Contemporânea. **Políticas Públicas e Cidades**, v. 5, n. 2, p. 17–37, 2017.

DOS SANTOS SILVA, M. P.; CAMARA, G.; ESCADA, M. I. S.; MODESTO DE SOUZA, R. C. Remote-sensing image mining: detecting agents of land-use change in tropical forest areas. **International Journal of Remote Sensing**, v. 29, n. 16, p. 4803–4822, 2008.

ELVIDGE, C. D.; BAUGH, K. E.; ZHIZHIN, M.; HSU, F.-C. Why VIIRS data are superior to DMSP for mapping nighttime lights. In: ASIA-PACIFIC ADVANCED NETWORK, 2013. **Proceedings...** 2013.

EUROPEAN SPACE AGENCY - ESA. **SENTINEL-2**. Disponível em: <<https://sentinel.esa.int/web/sentinel/missions/sentinel-2>>. Acesso em: 6 mar. 2020.

ESCADA, M. I. S.; AMARAL, S.; RENNÓ, C. D.; PINHEIRO, T. F. **Levantamento do uso e cobertura da terra e da rede de infraestruturas no distrito florestal da Br-163**. São José dos Campos: INPE, 2009. Disponível em: <<http://urlib.net/8JMKD3MGP8W/357DD7L%3E>>. Acesso em: 10 mar. 2020.

FENG, Y.; LU, D.; MORAN, E.; DUTRA, L.; CALVI, M.; DE OLIVEIRA, M. Examining spatial distribution and dynamic change of urban land covers in the Brazilian Amazon using multitemporal multisensor high spatial resolution satellite imagery. **Remote Sensing**, v. 9, n. 4, p. 381, 2017.

FERREIRA, J. F.; NETO, J. T. L.; SILVA, W.; SAMANIEGO, A.; SÁ, M. E.; SAVINO, M. **Rede urbana, subsídios para uma política de desenvolvimento regional urbano**. Belém: NANE, 1973.

FLEURY, L. C.; ALMEIDA, J. A construção da usina hidrelétrica de Belo Monte: conflito ambiental e o dilema do desenvolvimento. **Ambiente e Sociedade**, v. 16, n. 4, p. 19, 2013.

FLORCZYK, A. J.; CORBANE, C.; EHRLICH, D.; FREIRE, S.; KEMPER, T.; MAFFENINI, L.; MELCHIORRI, M.; POLITIS, P.; SCHIAVINA, M.; SABO, F.; ZANCHETTA, L. **GHSL data package 2019 public release**. [S.l: s.n.], 2019. ISBN 978-92-76-13186-1.

FRANCO, F. C. O.; FEITOSA, M. L. P. A. M. Desenvolvimento e direitos humanos: marcas de inconstitucionalidade no processo Belo Monte. **Revista Direito GV**, v. 9, n. 1, p. 93–114, 2013.

FUNDAÇÃO AMAZÔNIA DE AMPARO A ESTUDOS E PESQUISAS DO PARÁ. **Estimativas e projeções do PIB Paraense 2015-2020**. Belém, 2017. Disponível em: <http://www.fapespa.pa.gov.br/upload/Arquivo/anexo/1332.pdf?id=1546554944>.

GAO, B. NDWI a normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 266, p. 257–266, 1996.

GLOBO. **Altamira lidera ranking de cidades mais violentas do Brasil, diz IPEA**. Disponível em: <<https://g1.globo.com/pa/para/noticia/altamira-lidera-ranking-de-cidades-mais-violentas-do-brasil-diz-ipea.ghtml>>. Acesso em: 6 mar. 2020.

GOLDBLATT, R.; YOU, W.; HANSON, G.; KHANDELWAL, A. K. Detecting the boundaries of urban areas in India: a dataset for pixel-based image classification in google earth engine. **Remote Sensing**, v. 8, n. 8, 2016.

GONÇALVES, G. C.; ESCADA, M. I. S.; AMARAL, S. Impervious surfaces for population estimate in brazilian cities. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19., 2019. **Anais...** São José dos Campos: INPE, 2019.

GONÇALVES, G. C.; OLIVEIRA, L. M.; DAL'ASTA, A. P.; AMARAL, S. Geoinformação para a visibilidade das áreas urbanas de cidades amazônicas geoinformatics for the visibility of urban areas in the amazon cities. **Revista Georaguia**, p. 1–15, 2021.

GONG, P.; LI, X.; ZHANG, W. 40-Year (1978–2017) human settlement changes in China reflected by impervious surfaces from satellite remote sensing. **Science Bulletin**, 2019.

HAAS, J.; BAN, Y. Sentinel-1A SAR and sentinel-2A MSI data fusion for urban ecosystem service mapping. **Remote Sensing Applications: Society and Environment**, v. 8, p. 41–53, 2017.

HALLADA, W. A.; BLY, B. G.; BOYD, R. K.; COX, S. Using divergence analysis of texture features. In: NATIONAL CONFERENCE ON ENERGY RESOURCE MANAGEMENT, 1., 1982, Marshall. **Proceedings...** Marshall: Marshall University, 1982. Disponível em: <<https://ntrs.nasa.gov/citations/19830017885>>.

HARALICK, R. M.; DINSTEIN, I.; SHANMUGAM, K. Textural features for image classification. **IEEE Transactions on Systems, Man and Cybernetics**, v. 3, n. 6, p. 610–621, 1973.

HARDIN, P. J.; JACKSON, M. W.; OTTERSTROM, S. Mapping, measuring, and modeling urban growth. **Geo-Spatial Technologies in Urban Environments**, v. 2, p. 141–176, 2007.

HARTNETT, M.; NASH, S. High-resolution flood modeling of urban areas using MSN\_Flood. **Water Science and Engineering**, v. 10, n. 3, p. 175–183, 2017.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The elements of statistical learning**: data mining, inference and prediction. 2. ed. [S.l.]: Springer, 2009. 764 p. ISBN 978-0387848570.

HECKENBERGER, M. J.; RUSSELL, J. C.; FAUSTO, C.; TONEY, J. R.; SCHMIDT, M. J.; PEREIRA, E.; FRANCHETTO, B.; KUIKURO, A. Pre-Columbian urbanism, anthropogenic landscapes, and the future of the Amazon. **Science**, v. 321, n. 5893, p. 1214–1217, 2008.

IANOŞ, I.; SÎRODOEV, I.; PASCARIU, G.; HENEBRY, G. Divergent patterns of built-up urban space growth following post-socialist changes. **Urban Studies**, v. 53, n. 15, p. 3172–3188, 2016.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Censo demográfico 2010**. Disponível em: <<http://censo2010.ibge.gov.br/>>. Acesso em: 10 fev. 2020a.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Histórico de Itaituba**. 2010b. Disponível em: <<https://biblioteca.ibge.gov.br/visualizacao/dtbs/para/itaituba.pdf>>.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Cidades**. Disponível em: <<https://cidades.ibge.gov.br/>>. Acesso em: 4 mar. 2020.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS - INPE. **Projeto PRODES digital**: mapeamento do desmatamento da Amazônia com Imagens de Satélite. Disponível em: <<http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes>>. Acesso em: 29 jan. 2020.

JENSEN, J. **Introductory digital image processing**: a remote sensing perspective. New Jersey: Prentice Hall, 2005. 544 p. ISBN 978-0134058160.

JENSEN, J.; COWEN, D. Remote sensing of urban/suburban infrastructure and socio-economic attributes. **American Society for Photogrammetry and Remote Sensing**, v. 65, n. 3, p. 360–362, 1999.

JIANG, X.; LU, D.; MORAN, E.; CALVI, M. F.; DUTRA, L. V.; LI, G. Examining impacts of the Belo Monte hydroelectric dam construction on land-cover changes using multitemporal Landsat imagery. **Applied Geography**, v. 97, p. 35–47, 2018.

LI, G.; LU, D.; MORAN, E.; HETRICK, S. Mapping impervious surface area in the Brazilian Amazon using Landsat Imagery. **GIScience and Remote Sensing**, v. 50, n. 2, p. 172–183, 2013.

LI, X.; GONG, P.; LIANG, L. A 30-year (1984-2013) record of annual urban dynamics of Beijing City derived from Landsat data. **Remote Sensing of Environment**, v. 166, p. 78–90, 2015.

LIU, D.; CHEN, N.; ZHANG, X.; WANG, C.; DU, W. Annual large-scale urban land mapping based on Landsat time series in Google Earth Engine and OpenStreetMap data: a case study in the middle Yangtze River basin. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 159, p. 337–351, 2020.

LIU, X.; HU, G.; CHEN, Y.; LI, X.; XU, X.; LI, S.; PEI, F.; WANG, S. High-resolution multi-temporal mapping of global urban land using Landsat images based on the Google Earth Engine Platform. **Remote Sensing of Environment**, v. 209, p. 227–239, 2018.

LOBO, M. A. A.; TOURINHO, H. L. Z.; COSTA, É. F. N. DA. Urbanização, dispersão urbana e estrutura intraurbana de cidades intermediárias da Amazônia: o caso de Altamira (PA). **Boletim de Geografia**, v. 35, n. 1, p. 43, 2017.

LOPES, R. J. **1499 O Brasil antes de Cabral**. [S.l.]: Harper Collins, 2017. 248 p. ISBN 9788595080324.

LÖW, F.; CONRAD, C.; MICHEL, U. Decision fusion and non-parametric classifiers for land use mapping using multi-temporal RapidEye data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 108, p. 191–204, 2015.

LU, D.; LI, G.; MORAN, E.; BATISTELLA, M.; FREITAS, C. C. Mapping impervious surfaces with the integrated use of Landsat Thematic Mapper and radar data: a case study in an urban-rural landscape in the Brazilian Amazon. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 6, p. 798–808, 2011.

LU, D.; LI, G.; MORAN, E.; DUTRA, L.; BATISTELLA, M. The roles of textural images in improving land-cover classification in the Brazilian Amazon. **International Journal of Remote Sensing**, v. 35, n. 24, p. 8188–8207, 2014.

MACHADO, L. O. Urbanização e mercado de trabalho na Amazônia Brasileira. **Cadernos IPPUR UFRJ**, v. 1, p. 104–133, 1999.

MACIEL, F. B. Assentamentos precários: o caso de Manaus. In: MORAES, M. P.; KRAUSE, C.; LIMA NETO, V. C. (Ed.). **Caracterização e tipologia de assentamentos precários: estudos de caso brasileiros**. Brasília: IPEA, 2016. p. 249–306.

MAGALHÃES, M. A.; TOSCANO, V. N.; BERGAMASCHI, R. B. Área, densidade e população: o caso de áreas urbanas e urbanizadas dos municípios do Espírito Santo. **Planejamento e Políticas Públicas**, n. 40, 2013.

MARCEAU, D. J.; HOWARTH, P. J.; DUBOIS, J. M. M.; GRATTON, D. J. Evaluation of the grey-level co-occurrence matrix method for land-cover classification using SPOT imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 28, n. 4, p. 513–519, 1990.

MARTINUZZI, S.; GOULD, W. A.; RAMOS GONZÁLEZ, O. M. Land development, land use, and urban sprawl in Puerto Rico integrating remote sensing and population census data. **Landscape and Urban Planning**, v. 79, n. 3–4, p. 288–297, 2007.

MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing**, v. 17, n. 7, p. 1425–1432, 1996.

MESEV, V. Identification and characterisation of urban building patterns using IKONOS imagery and point-based postal data. **Computers, Environment and Urban Systems**, v. 29, n. 5, p. 541–557, 2005.

MONTE-MÓR, R. L. **Modernities in the Jungle**: extended urbanization in the brazilian Amazonia. [S.l.]: Universidade da California, 2004.

NEGRÃO, M.; BASTOS, A.; CARDOSO, A. Transformações urbanas na Amazônia : um estudo de caso sobre Altamira. In: CONFERÊNCIA DO PNUM MORFOLOGIA URBANA E OS DESAFIOS DA URBANIDADE, 4., 2015, Brasília. **Anais...** Brasília, 2015. Disponível em: <[https://pnum.fe.up.pt/en-gb/assets/pdf/conferences/pnum-2015\\_anais\\_st1-parte-2.pdf](https://pnum.fe.up.pt/en-gb/assets/pdf/conferences/pnum-2015_anais_st1-parte-2.pdf)>.

NOURANI, V.; ROUSHANGAR, K.; ANDALIB, G. An inverse method for watershed change detection using hybrid conceptual and artificial intelligence approaches. **Journal of Hydrology**, v. 562, p. 371–384, 2018.

NOVO PROGRESSO. PREFEITURA MUNICIPAL. **História**. Disponível em: <<https://novoprogresso.pa.gov.br/o-municipio/historia/>>. Acesso em: 6 mar. 2020.

OLIVEIRA, J. A. Tempo e espaço urbano na Amazônia no período da borracha. **Scripta Nova - Revista Electrónica de Geografía y Ciencias Sociales**, v. 10, 2006.

OLIVEIRA, J. M. G. C. Expansão urbana e periferização de santarém-pa, brasil: questões para o planejamento urbano. In: COLOQUIO INTERNACIONAL DE GEOCRÍTICA, 10., 2008, Barcelona. **Anais...** Barcelona, 2008. Disponível em: <<http://www.ub.edu/geocrit/-xcol/268.htm>>.

OLIVEIRA, T. N.; BRANDÃO, L. P.; PENA, H. W. A. Análise da dinâmica da estrutura produtiva do município de Camtá, Amazônia-Brasil. **Observatorio de la Economía**, p. 1–16, 2014.

OU, J.; LIU, X.; LIU, P.; LIU, X. Evaluation of LuoJia 1-01 nighttime light imagery for impervious surface detection: a comparison with NPP-VIIRS nighttime light data. **International Journal of Applied Earth Observation and Geoinformation**, v. 81, p. 1–12, 2019.

OUYANG, Z.; LIN, M.; CHEN, J.; FAN, P.; QIAN, S. S.; PARK, H. Improving estimates of built-up area from night time light across globally distributed cities through hierarchical modeling. **Science of the Total Environment**, v. 647, p. 1266–1280, 2019.

PINHO, C. M. D.; MEDEIROS, L. C. C.; LOBO, F. L.; SILVA, M.; ESCADA, M. I. S.; AMARAL, S. **Infraestrutura, conectividade e padrões de ocupação no sul do Pará - pesquisa de campo setembro de 2009**. São José dos Campos: INPE, 2010. Disponível em: <<http://mtc-m16d.sid.inpe.br/rep/8JMKD3MGP7W/388SBJL>>.

PINHO, G. F.; CARDOSO, A. C. D. O legado das colonizações da Amazônia oriental: redes de aglomerados rurais ou redes proto-urbanas? **PARC Pesquisa em Arquitetura e Construção**, v. 7, n. 1, p. 35, 2016.

POK, S.; MATSUSHITA, B.; FUKUSHIMA, T. An easily implemented method to estimate impervious surface area on a large scale from MODIS time-series and improved DMSP-OLS nighttime light data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 133, p. 104–115, 2017.

PONTIUS, R. G.; MILLONES, M. Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal of Remote Sensing**, v. 32, n. 15, p. 4407–4429, 2011.

POWELL, R. L.; ROBERTS, D. A. Characterizing variability of the urban physical environment for a suite of cities in Rondônia, Brazil. **Earth Interactions**, v. 12, n. 13, p. 1–32, 2008.

PREFEITURA DE ITAITUBA. **Apresentação**. Disponível em: <<http://www.itaituba.pa.gov.br/paginas/apresentacao>>. Acesso em: 5 mar. 2020.

PRIEM, F.; OKUJENI, A. VAN DER LINDEN, S.; CANTERS, F. Comparing map-based and library-based training approaches for urban land-cover fraction mapping from Sentinel-2 imagery. . **International Journal of Applied Earth Observation and Geoinformation**, v. 78, p. 295–305, 2019.

RICHTER, R. **Atmospheric / Topographic Correction for Satellite Imagery: ATCOR - 2/3 user guide**. [S.l.: s.n.], 2007.

ROSENRETER, J.; HAGENSIEKER, R.; WASKE, B. Towards large-scale mapping of local climate zones using multitemporal Sentinel 2 data and convolutional neural networks. **Remote Sensing of Environment**, v. 237, 1 fev. 2020.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. . Monitoring vegetation systems in the great plains with ERTS. In: EARTH RESOURCES TECHNOLOGY SATELLITE-1 SYMPOSIUM, 3., 1974. **Proceedings...** 1974. Disponível em:  
<<https://ui.adsabs.harvard.edu/abs/1974NASSP.351..309R/abstract>>.

ROY CHOWDHURY, P. K.; BHADURI, B. L.; MCKEE, J. J. Estimating urban areas: New insights from very high-resolution human settlement data. **Remote Sensing Applications: Society and Environment**, v. 10, p. 93–103, 2018.

SANTARÉM. PREFEITURA MUNICIPAL. **Sobre a cidade**. Disponível em:  
<[http://www.santarem.pa.gov.br/pagina.asp?id\\_pagina=24](http://www.santarem.pa.gov.br/pagina.asp?id_pagina=24)>. Acesso em: 5 mar. 2020.

SÃO FELIX DO XINGU. PREFEITURA MUNICIPAL. **São Félix do Xingú, um pouco da nossa história**. Disponível em:  
<<https://sfxingu.pa.gov.br/web/pag.php?pg=blog/view&tag=saofelixdoxinguumpoucodanossahistoria>>. Acesso em: 6 mar. 2020.

SIDIKE, P.; ASARI, V. K.; SAGAN, V. Progressively Expanded Neural Network (PEN Net) for hyperspectral image classification: a new neural network paradigm for remote sensing image analysis. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 146, p. 161–181, 2018.

SOH, L. K.; TSATSOULIS, C. Texture analysis of sar sea ice imagery using gray level co-occurrence matrices. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, n. 2 I, p. 780–795, 1999.

SOUZA, C. M.; SHIMBO, J. Z.; ROSA, M. R.; PARENTE, L. L.; ALENCAR, A. A.; RUDORFF, B. F. T.; HASENACK, H.; MATSUMOTO, M.; FERREIRA, L. G.; SOUZA-FILHO, P. W. M.; DE OLIVEIRA, S. W.; ROCHA, W. F.; FONSECA, A. V.; MARQUES, C. B.; DINIZ, C. G.; COSTA, D.; MONTEIRO, D.; ROSA, E. R.; VÉLEZ-MARTIN, E.; WEBER, E. J.; LENTI, F. E. B.; PATERNOST, F. F.; PAREYN, F. G. C.; SIQUEIRA, J. V.; VIERA, J. L.; NETO, L. C. F.; SARAIVA, M. M.; SALES, M. H.; SALGADO, M. P. G.; VASCONCELOS, R.; GALANO, S.; MESQUITA, V. V.; AZEVEDO, T. Reconstructing three decades of land use and land cover changes in brazilian biomes with landsat archive and earth engine. **Remote Sensing**, v. 12, n. 17, 2020.

SOUZA, A. R.; ADORNO, B. V.; GONÇALVES, G. C.; BRAGION, G. R.; OLIVEIRA, K. D.; ESCADA, M. I. S.; REIS, M. S.; SANT'ANNA, S. J. S.; AMARAL, S. **Paisagens e uso da terra em núcleos populacionais e estabelecimentos rurais da região do baixo Tocantins - Pará: relatório técnico de atividade de campo de 2018 e 2019.** São José dos Campos: INPE, 2021. Disponível em: <<http://mtc-m21d.sid.inpe.br/rep/8JMKD3MGP3W34T/44STMLE>>.

STEHMAN, S. V. Selecting and interpreting measures of thematic classification accuracy. **Remote Sensing of Environment**, v. 62, n. 1, p. 77–89, 1997.

TAVARES, P. A.; BELTRÃO, N. E. S.; GUIMARÃES, U. S.; TEODORO, A. C. Integration of sentinel-1 and sentinel-2 for classification and LULC mapping in the urban area of Belém, eastern Brazilian Amazon. **Sensors (Switzerland)**, v. 19, n. 5, 2019.

TELUGUNTLA, P.; THENKABAIL, P.; OLIPHANT, A.; XIONG, J.; GUMMA, M. K.; CONGALTON, R. G.; YADAV, K.; HUETE, A. A 30-m landsat-derived cropland extent product of Australia and China using random forest machine learning algorithm on Google Earth Engine cloud computing platform. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 144, p. 325–340, 2018.

THENKABAIL, P. S.; ENCLONA, E. A.; ASHTON, M. S.; VAN DER MEER, B. Accuracy assessments of hyperspectral waveband performance for vegetation analysis applications. **Remote Sensing of Environment**, v. 91, n. 3–4, p. 354–376, 2004.

THITAWADEE, S.; YOSHIHISA, M. Urban growth prediction of special economic development zone in Mae Sot district, Thailand. **Engineering Journal**, v. 22, n. 3, p. 269–277, 2018.

TIGGES, J.; LAKES, T.; HOSTERT, P. Urban vegetation classification: benefits of multitemporal RapidEye satellite data. **Remote Sensing of Environment**, v. 136, p. 66–75, 2013.

TRINDADE JÚNIOR, S.-C. C.; ROSÁRIO, B. A.; COSTA, G. K. G.; LIMA, M. M. Espacialidades e temporalidades urbanas na Amazônia ribeirinha: mudanças e permanências a jusante do rio Tocantins. **Revista ACTA Geográfica**, n. 1994, p. 117–133, 2011.

TRINDADE JÚNIOR, S.-C.; CARVALHO, G.; MOURA, A.; GOMES NETO, J. **Pequenas e médias cidades na Amazônia.** Belém: ICSA - UFPA, 2009. 359 p. ISBN 9788586471476.

TRIPATHY, P.; KUMAR, A. Monitoring and modelling spatio-temporal urban growth of Delhi using Cellular Automata and geoinformatics. **Cities**, v. 90, p. 52–63, 2019.

WENG, Q. Remote sensing of impervious surfaces in the urban areas: requirements, methods, and trends. **Remote Sensing of Environment**, v. 117, p. 34–49, 2012.

WENG, Q.; LU, D. A sub-pixel analysis of urbanization effect on land surface temperature and its interplay with impervious surface and vegetation coverage in Indianapolis, United States. **International Journal of Applied Earth Observation and Geoinformation**, v. 10, n. 1, p. 68–83, 2008.

XIE, Y.; WENG, Q.; FU, P. Temporal variations of artificial nighttime lights and their implications for urbanization in the conterminous United States, 2013–2017. **Remote Sensing of Environment**, v. 225, p. 160–174, 2019.

YOO, C.; HAN, D.; IM, J.; BECHTEL, B. Comparison between convolutional neural networks and random forest for local climate zone classification in mega urban areas using Landsat images. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 157, p. 155–170, 2019.

YUAN, W. **A multi-sensor phenotyping system**: applications on wheat height estimation and soybean trait early prediction. [S.l.]: University of Nebraska, 2019.

ZHAO, W.; BO, Y.; CHEN, J.; TIEDE, D.; THOMAS, B.; EMERY, W. J. Exploring semantic elements for urban scene recognition: deep integration of high-resolution imagery and OpenStreetMap (OSM). **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 151, p. 237–250, 2019.

ZHENG, H.; DU, P.; CHEN, J.; XIA, J.; LI, E.; XU, Z.; LI, X.; YOKOYA, N. Performance evaluation of downscaling sentinel-2 imagery for land use and land cover classification by spectral-spatial features. **Remote Sensing**, v. 9, n. 12, 2017.

ZIGH, E.; BELBACHIR, M. F. Soft computing strategy for stereo matching of multi spectral urban very high resolution IKONOS images. **Applied Soft Computing Journal**, v.12, n.8, p.2156-2467, 2012.

## **APENDICE A - BREVE HISTÓRICO DE CRIAÇÃO DAS CIDADES**

Apresenta-se a seguir, um breve histórico da formação das cidades selecionadas para a avaliação do mapeamento.

### **Santarém**

A cidade de Santarém foi fundada em 22 de junho de 1661 pelo padre português João Felipe Bettendorf, que em expedição jesuíta, entrou em contato com índios da aldeia Tapajós, chegando ao local onde hoje se situa a cidade. Em 1758 foi elevada à categoria de vila, pelo então governador da província Grão-Pará o capitão Francisco Xavier de Mendonça Furtado. Em 24 de outubro de 1848 foi finalmente elevada à categoria de cidade, consequência do desenvolvimento da região devido à exploração de borracha.

O Município ocupa 17.898 km<sup>2</sup>, às margens da foz do rio Tapajós (PREFEITURA DE SANTARÉM, 2018) e possui uma economia baseada no comércio, prestação de serviços, ecoturismo, e indústrias leves e de beneficiamento, principalmente associadas ao setor agropecuário. Deve-se ressaltar também a importância da pesca, produção madeireira, agricultura familiar e pecuária para a economia local (PREFEITURA DE SANTARÉM, 2018).

### **Itaituba**

O primeiro colonizador a chegar ao território onde hoje se situa a cidade de Itaituba foi o Capitão Pedro Teixeira em 1626. Logo os Jesuítas chegaram e fundaram diversos aldeamentos. Os aldeamentos se desenvolveram, e em 1754 o Capitão Geral Francisco Xavier de Mendonça Furtado, como governador civil, elevou à categoria de vila com o nome Santarém da Aldeia. Em 1812, o local já existia com o nome de Itaituba, mas somente em 1900 a Vila Itaituba foi elevada ao foro de município com uma área de 62.040,947 km<sup>2</sup> (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE, 2010b).

Os principais setores da economia de Itaituba são: indústria, mineração e agropecuária. No setor industrial, destacam-se as empresas beneficiadoras de calcário, mineral abundante na região, que originaram diversas fábricas de cimento, tornando a cidade uma das principais produtoras de cimento do país.

No setor de mineração, o destaque é a exploração de ouro no Vale do Tapajós. Diversos conglomerados do setor de mineração se instalaram no município que passou a 14º maior PIB do setor no Brasil. No setor agropecuário, destacam-se a agricultura familiar e a criação de gado de corte (PREFEITURA DE ITAITUBA, 2017).

### **Novo Progresso**

Novo Progresso é uma cidade recente, cuja origem associa-se à construção da BR-163 (Cuiabá-Santarém) em 1973. Em 1983 já existia um pequeno povoado com igreja e um campo de futebol. Em 1984 a descoberta de uma jazida de ouro atraiu milhares de pessoas para o local resultando em grandes mudanças no povoado. Em 1985 uma comissão pró-emancipação foi criada e em 1991, através da lei estadual nº 5.700 de 13 de dezembro de 1991, o local teve o título de município, emancipando de Itaituba.

O município de Novo Progresso abrange 38.162 km<sup>2</sup> e a principal atividade econômica é a pecuária. A atividade garimpeira também possui relevância na economia local, assim como a construção civil, que teve grande crescimento após o asfaltamento da BR-163 (PREFEITURA DE NOVO PROGRESSO, 2015).

### **Altamira**

A origem da ocupação de Altamira ocorreu com a chegada de jesuítas na região no século XVIII, que na época integrava o município de Souzel (atual Senador José Porfírio). O primeiro registro de colonização nesse território foi do Jesuíta Roque de Hunderfund, às margens do Igarapé das Panelas, em missão catequética aos índios da região. No início, os índios auxiliaram na construção do local, porém com a regulamentação do trabalho escravo na região, a mão de obra escrava acelerou o processo. Em 6 de novembro de 1911, através da Lei estadual nº 1.234, foi fundado o município de Altamira. Na década de 1970, com a construção da BR-230 (Rodovia Transamazônica) pelo presidente militar Emílio Garrastazu Médici, houve um significativo processo migratório para o município, aquecendo a economia local e conectando-a com o resto do país. Somente em 1998 a energia elétrica por linha de transmissão chegou ao local,

oriunda da usina hidroelétrica de Tucuruí. Hoje, o município é ponto de apoio às cidades de Uruará, Brasil Novo, Medicilândia, Vitória do Xingu e Senador José Porfírio. Por sua extensão territorial (159.533 km<sup>2</sup>), Altamira possui vilas e comunidades distantes mais de 1.000 km da sede municipal (PREFEITURA DE ALTAMIRA, 2012).

A economia de Altamira tem como principal setor a pecuária, mas a agricultura de arroz, cacau, feijão e pimenta-do-reino também têm grande importância, assim como a extração de castanha-do-pará e borracha (PREFEITURA DE ALTAMIRA, 2012). Em 2010 iniciou-se a construção da Usina Hidroelétrica de Belo Monte, que resultou em alterações na paisagem e na dinâmica local. A expectativa de empregos, devido ao grande porte da obra, fez com que milhares de trabalhadores migrassem para o município em busca de trabalho. Entretanto, a expectativa foi incompatível com a realidade: além do prejuízo aos povos tradicionais (FLEURY; ALMEIDA, 2013), as obras não suprimiram a oferta de força de trabalho, deixando centenas de trabalhadores desempregados. Adicionalmente, a infraestrutura de Altamira e os municípios adjacentes não foi preparada para receber este contingente migratório, resultando em condições precárias de habitação (FRANCO; FEITOSA, 2013). Todos estes fatores contribuíram para colocar Altamira no primeiro lugar no ranking de cidades mais violentas do país, com mais de 100 mil habitantes (GLOBO, 2017).

### **São Felix do Xingu (SFX)**

A fundação do município de SFX está intrinsecamente relacionada à história de Altamira. Em 14 de abril de 1874, pela lei nº 811, foi fundado o município de Souzel, do qual Altamira fazia parte. No início do século XX, o território foi desmembrado criando o município do Xingu, com sede em Altamira. Em 1936, o território de Xingu continha 11 distritos, Altamira, Novo Horizonte, São Félix, Porto de Moz, Tapará, Vilarinho do Monte, Veiros, Aquiqui, Souzel, Alto Xingu e Iriri. Em 1938, pelo decreto nº 2972, o nome Xingu foi mudado para Altamira, que passou a ser formado por dois distritos, Altamira e Novo Horizonte. Em 1961 durante o governo de Aurélio do Carmo, através da Lei nº 2460, foi criado o

município de São Félix do Xingu, com 84. 212 km<sup>2</sup>, desmembrados do município de Altamira (PREFEITURA DE SÃO FELIX DO XINGU, 2016).

A economia de SFX tem como principal setor a pecuária de corte (PREFEITURA DE SÃO FELIX DO XINGU, 2016). Em 2014, conforme dados do (FUNDAÇÃO AMAZÔNIA DE AMPARO A ESTUDOS E PESQUISAS DO PARÁ, 2017), o município possuía o maior rebanho bovino do país (2,213 milhões de cabeças). O setor agrícola também é relevante, principalmente com a produção de banana, cacau, milho, feijão e mandioca. No setor industrial, tem destaque a mineração industrial, com a extração de cassiterita, níquel e cobalto. O garimpo de ouro também contribui para a economia de SFX (PREFEITURA DE SÃO FELIX DO XINGU, 2016).

### **Cametá**

Em 1635, Felício Coelho de Carvalho aportou na aldeia do povo Camutá, já pacificados pelo Frei Cristóvão de São José, e fundou a vila Viçosa de Santa Cruz do Camutá. Esta foi a primeira vila do Baixo Tocantins, que veio a se tornar o principal porto do Pará, cerca de três séculos mais tarde. Foi elevada à categoria de município em 1848, pela lei nº 145, e em 1930 teve sua condição de município confirmada (CRUZ, 2003). Ao longo da História, Cametá desempenhou uma importante trajetória no Baixo Tocantins, devido sua localização estratégica às margens do Tocantins, facilitando o acesso fluvial. Após a criação da barragem de Tucuruí, a precarização dos serviços fluviais forçou o desenvolvimento rodoviário e ferroviário da região (CASTRO, 2009). Cametá é um importante polo urbano da região, que permite uma dinâmica econômica entre cidades, vilas, comunidades e localidades (FERREIRA et al., 1973).

Cametá como cidade ribeirinha, localizada em região de várzeas, possui uma economia voltada para a pesca. Adicionalmente, de agosto a dezembro ocorre a safra de açaí, de extrema importância para a alimentação da população e para a economia local. Basicamente a economia de Cametá se concentra na

agricultura familiar, pesca e extrativismo vegetal (OLIVEIRA; BRANDÃO; PENA, 2014).

## APENDICE B – MAPAS DE NDVI E NDWI

Figura B.1 - Mapas contendo o NDVI calculado para as seis sedes municipais.

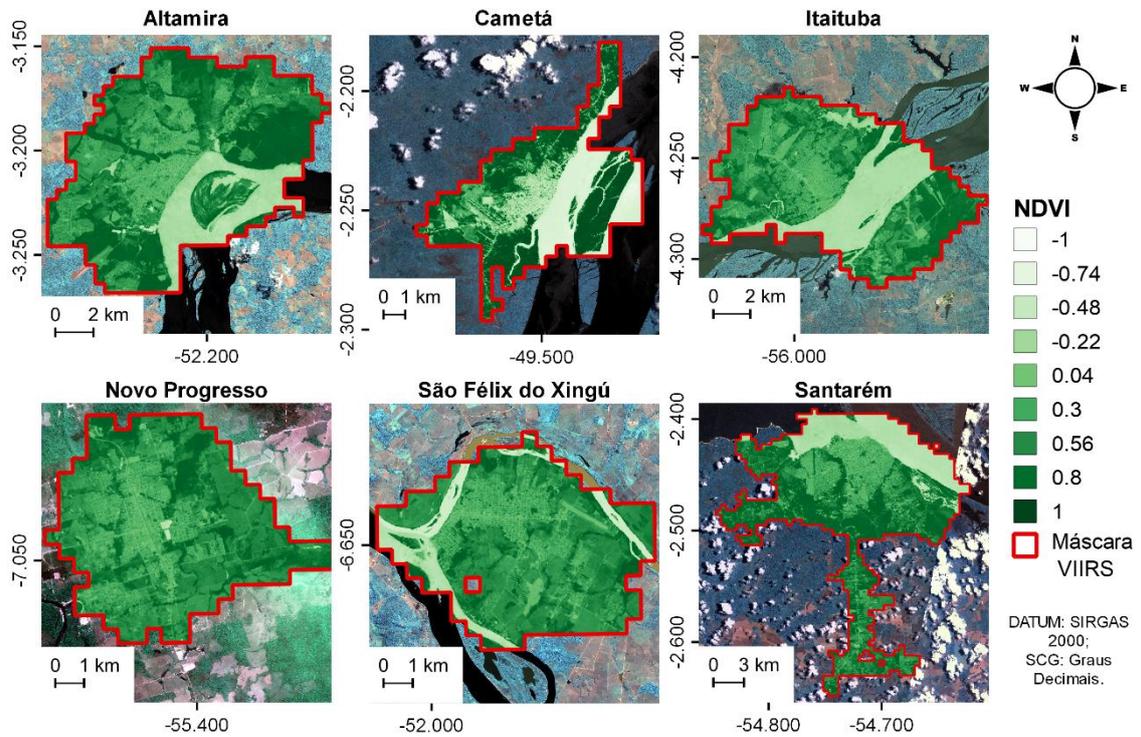
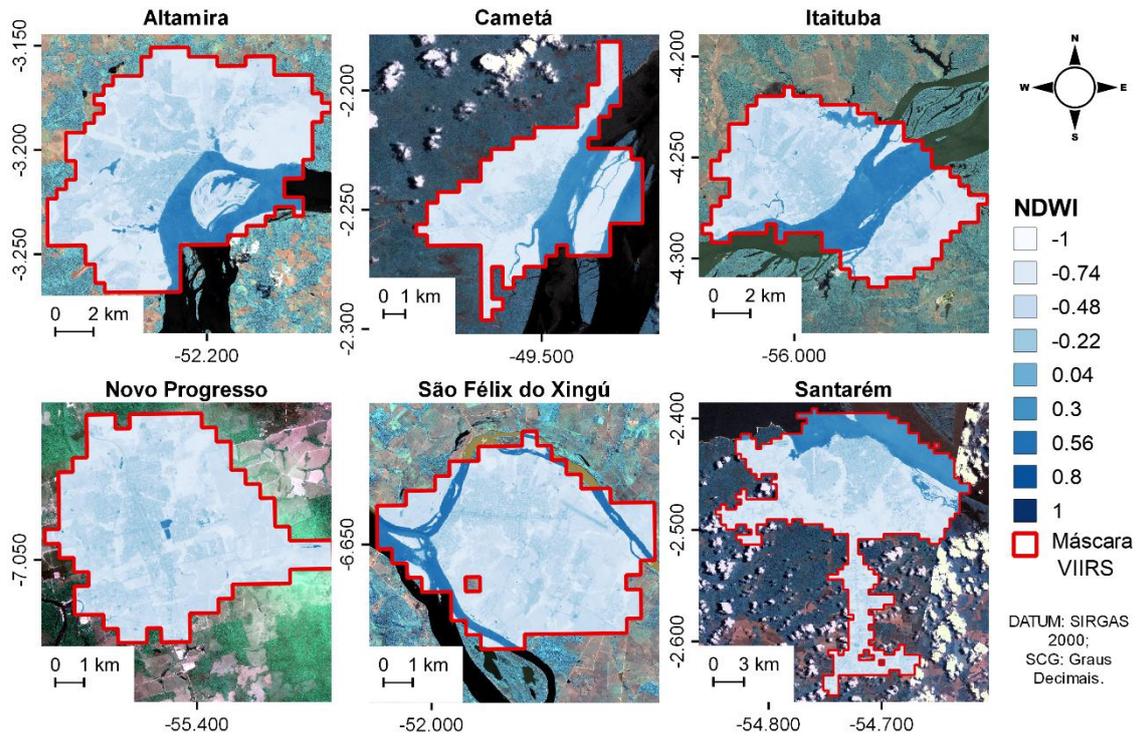


Figura B. 2- Mapas contendo o NDWI calculado para as seis sedes municipais.



## APENDICE C – MAPAS COM RESULTADOS DA CLASSIFICAÇÃO EM MAIOR ESCALA

Figura C.1 – Mapas temáticos resultantes para Altamira.

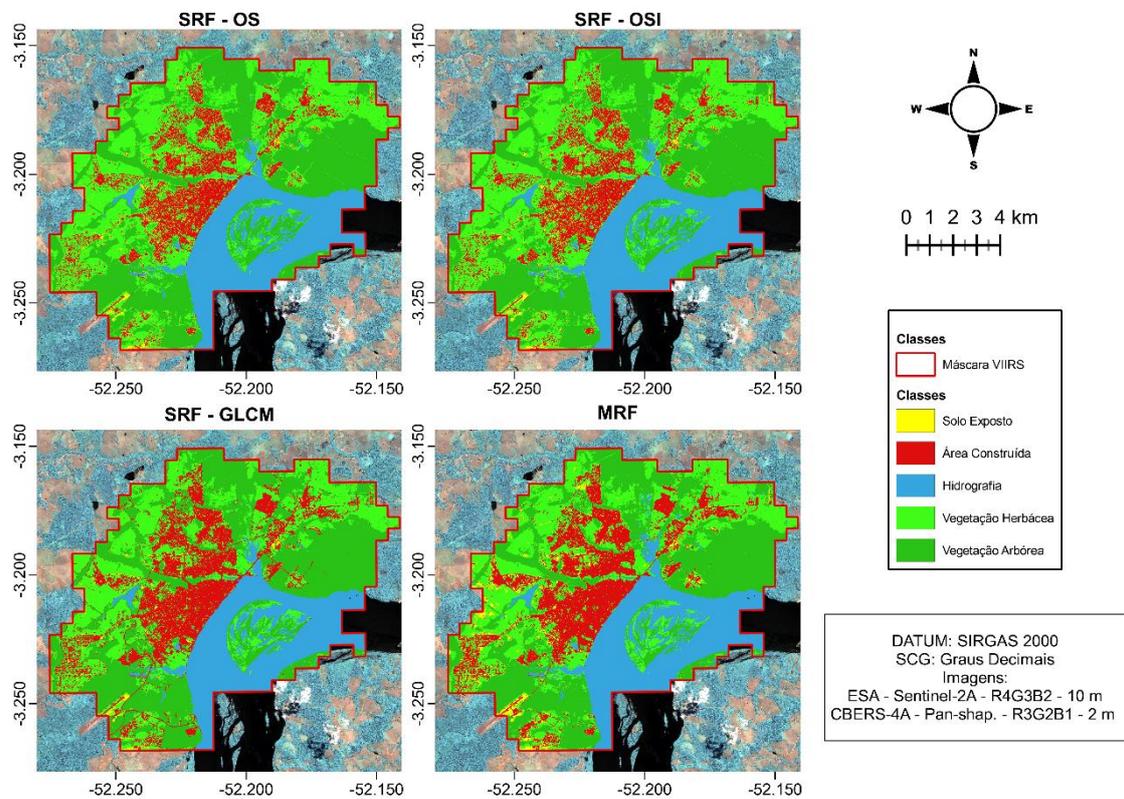


Figura C.2 – Mapas temáticos resultantes para Cametá.

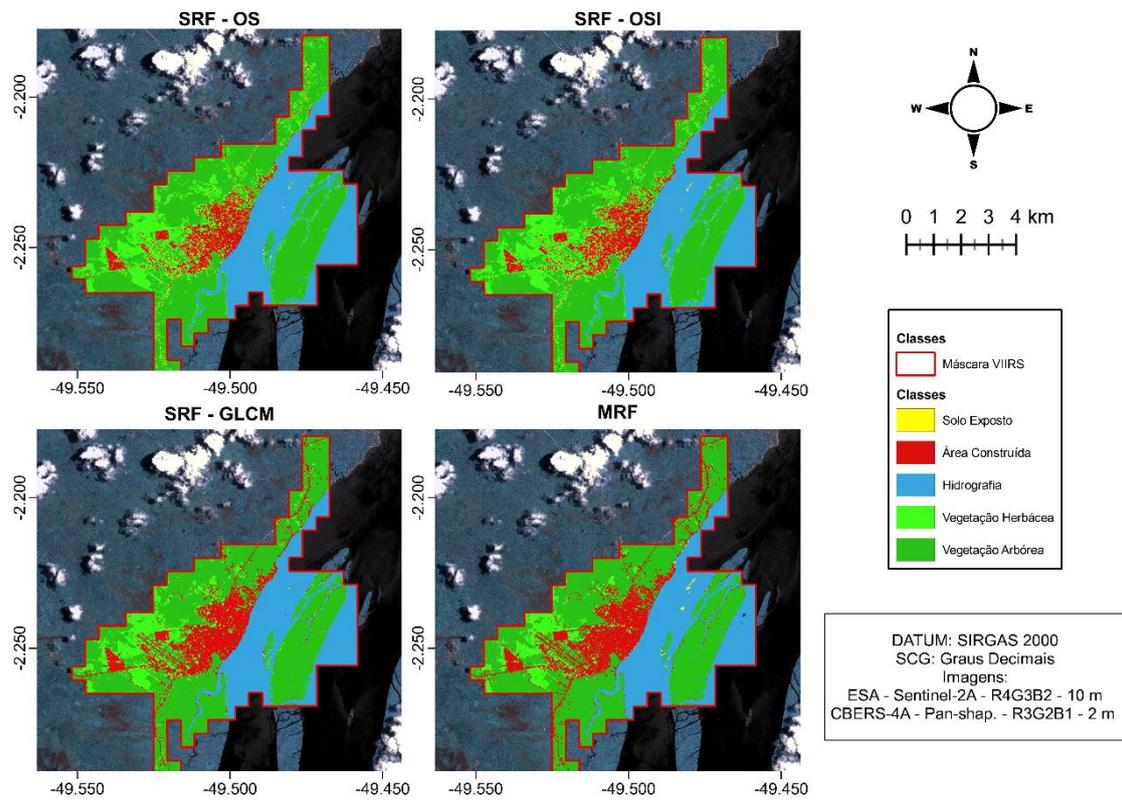


Figura C.3 – Mapas temáticos resultantes para Itaituba.

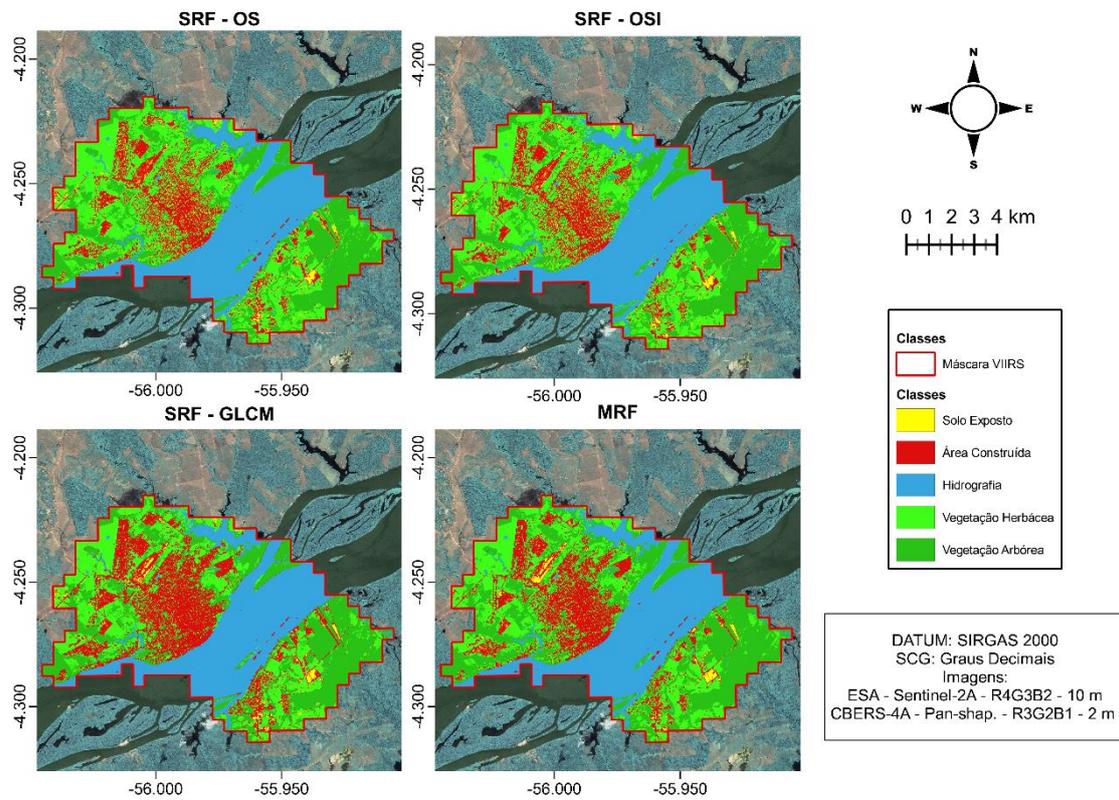


Figura C.4 – Mapas temáticos resultantes para Novo Progresso.

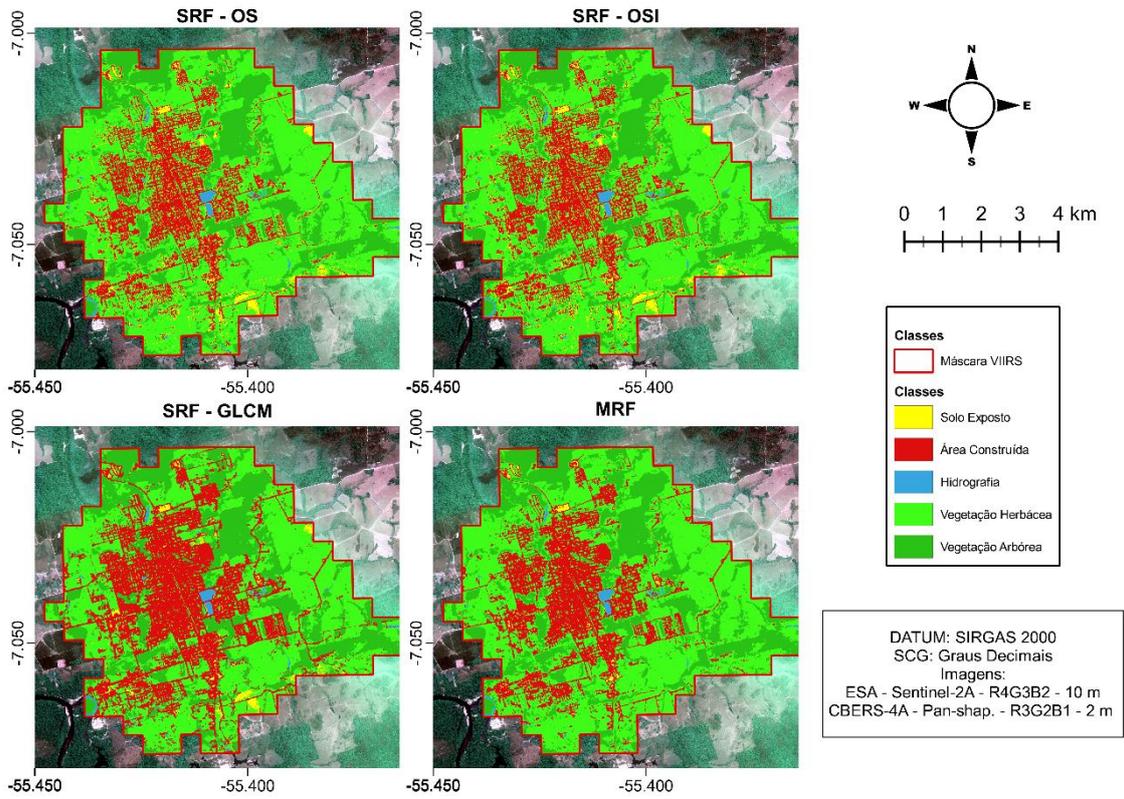


Figura C.5 – Mapas temáticos resultantes para São Félix do Xingú.

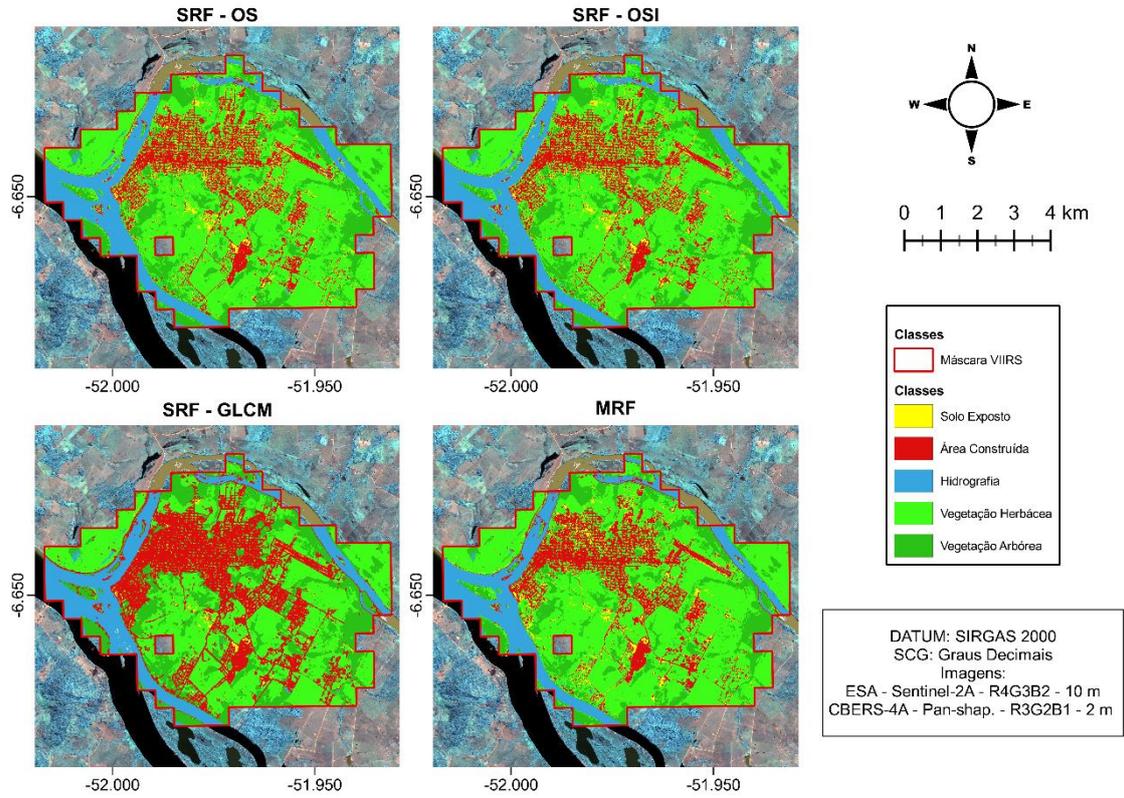


Figura C.6 -- Mapas temáticos resultantes para Santarém.

