



MINISTÉRIO DA  
CIÊNCIA, TECNOLOGIA  
E INOVAÇÕES



sid.inpe.br/mtc-m21c/2020/12.29.13.22-TDI

**MÉTODOS DE ESTIMATIVA DE CLASSES DE USO E  
COBERTURA DA TERRA EM ÁREAS COM  
COBERTURA DE NUVEM BASEADOS NA  
DISTRIBUIÇÃO ESPAÇO-TEMPORAL DE CLASSES**

Izak Francisco Justi

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Sensoriamento Remoto, orientada  
pelos Drs. Luciano Vieira Dutra e  
Sidnei João Siqueira Sant'Anna,  
aprovada em 15 de dezembro de  
2020.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/43S5ES8>>

INPE  
São José dos Campos  
2020

## **PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GBDIR)

Serviço de Informação e Documentação (SESID)

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 INTELECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):**

### **Presidente:**

Dra. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos Climáticos (CGCPT)

### **Membros:**

Dra. Carina Barros Mello - Coordenação de Laboratórios Associados (COCTE)

Dr. Alisson Dal Lago - Coordenação-Geral de Ciências Espaciais e Atmosféricas (CGCEA)

Dr. Evandro Albiach Branco - Centro de Ciência do Sistema Terrestre (COCST)

Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia e Tecnologia Espacial (CGETE)

Dr. Hermann Johann Heinrich Kux - Coordenação-Geral de Observação da Terra (CGOBT)

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação - (CPG)

Silvia Castro Marcelino - Serviço de Informação e Documentação (SESID)

### **BIBLIOTECA DIGITAL:**

Dr. Gerald Jean Francis Banon

Clayton Martins Pereira - Serviço de Informação e Documentação (SESID)

### **REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

Simone Angélica Del Ducca Barbedo - Serviço de Informação e Documentação (SESID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SESID)

### **EDITORAÇÃO ELETRÔNICA:**

Ivone Martins - Serviço de Informação e Documentação (SESID)

Cauê Silva Fróes - Serviço de Informação e Documentação (SESID)



MINISTÉRIO DA  
CIÊNCIA, TECNOLOGIA  
E INOVAÇÕES



sid.inpe.br/mtc-m21c/2020/12.29.13.22-TDI

**MÉTODOS DE ESTIMATIVA DE CLASSES DE USO E  
COBERTURA DA TERRA EM ÁREAS COM  
COBERTURA DE NUVEM BASEADOS NA  
DISTRIBUIÇÃO ESPAÇO-TEMPORAL DE CLASSES**

Izak Francisco Justi

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Sensoriamento Remoto, orientada  
pelos Drs. Luciano Vieira Dutra e  
Sidnei João Siqueira Sant'Anna,  
aprovada em 15 de dezembro de  
2020.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/43S5ES8>>

INPE  
São José dos Campos  
2020

Dados Internacionais de Catalogação na Publicação (CIP)

---

Justi, Izak Francisco.

J983m Métodos de estimativa de classes de uso e cobertura da terra em áreas com cobertura de nuvem baseados na distribuição espaço-temporal de classes / Izak Francisco Justi. – São José dos Campos : INPE, 2020.

xxvii + 160 p. ; (sid.inpe.br/mtc-m21c/2020/12.29.13.22-TDI)

Dissertação (Mestrado em Sensorimento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2020.

Orientadores : Drs. Luciano Vieira Dutra e Sidnei João Siqueira Sant'Anna.

1. Valores faltantes. 2. Nuvens. 3. Sombra de nuvens. 4. Uso e cobertura da terra. 5. Estimativa de classes. I. Título.

CDU 528.8:332.3

---



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  
Pós-Graduação em Sensoriamento Remoto

### DEFESA FINAL DE DISSERTAÇÃO DE IZAK FRANCISCO JUSTI

No dia 15 de dezembro de 2020, às 09h 30min, 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: "MÉTODOS DE ESTIMATIVA DE CLASSES DE USO E COBERTURA DA TERRA EM ÁREAS COM COBERTURA DE NUVEM BASEADOS NA DISTRIBUIÇÃO ESPAÇO-TEMPORAL DE CLASSES"**

Eu, Thales Sehn Körting, como Presidente da Banca Examinadora, assino esta ATA em nome de todos os membros.

#### Membros da Banca

Dr. Thales Sehn Körting - Presidente - INPE

Dr. Luciano Vieira Dutra - Orientador - INPE

Dr. Sidnei João Siqueira Sant'Anna - Orientador - INPE

Dra Ieda Del' Arco Sanches - Membro da Banca - INPE

Dra Sandra Maria Fonseca da Costa - Convidada - UNIVAP



Documento assinado eletronicamente por **Thales Sehn Korting, Pesquisador**, em 18/12/2020, às 08:28 (horário oficial de Brasília), com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site <http://sei.mctic.gov.br/verifica.html>, informando o código verificador **6258840** e o código CRC **BA99F1A8**.



A meus pais Alvelina Lemos Martins Justi e Inazio Justi, por sempre acreditarem em mim.





## AGRADECIMENTOS

Agradeço, primeiramente, a meus pais que sempre confiaram em mim e me apoiaram em todas as fases e decisões da minha vida.

Agradeço pela atenção que sempre tiveram e todo o amor com que zelam não só por mim, mas também um pelo outro.

Agradeço aos meus orientadores, Dr. Luciano Vieira Dutra e Dr. Sidnei João Siqueira Sant'Anna, por serem um exemplo de cientistas que apesar das dificuldades enfrentadas pela carreira no país ainda enxergam a importância da pesquisa e continuam com um trabalho exemplar. Agradeço por me ensinarem e compartilharem muitas vezes o conhecimento científico. Agradeço a paciência e compreensão que, por muitas vezes, demonstraram. Agradeço a preocupação que tiveram comigo não só academicamente, mas pessoalmente.

Agradeço a Mariane Souza Reis, Maria Antônia Falcão, Bruna Cristina Braga, Sabrina Paes Leme, Noeli Aline Particcelli, Matheus Coldibelli e Willian Vieira de Oliveira que compartilharam não só a sala comigo no INPE, mas também o conhecimento, experiência e apoio durante o desenvolvimento da pesquisa.

Agradeço a todos colegas de trabalho que me incentivaram a ir atrás do meu sonho do mestrado. Em especial àqueles que, com orgulho, se tornaram meus amigos. Ao Giuliano Grigolin e à Fabiana Giacomini Rampinelli, que sempre acreditaram em mim, até quando eu mesmo não acreditava. E ao Carlos Fernando Pimenta, por me incentivar e sempre estar presente quando eu mais precisava. Ao Ivan, Vanessa e Jéssica, por me animarem e me lembrarem de que eu era capaz.

Agradeço aos colegas de turma e companheiros de trabalho que sempre se mostraram dispostos a ajudar. Em especial à Ana Lígia Nascimento, Daiane Vaz, Kátia Ferreira e Amanda Lopes que sempre reservavam tempo para estudarmos e estavam dispostas a ajudar seja na pesquisa ou nos meus problemas do dia a dia.

Agradeço a todos os meus amigos que confiaram em mim nessa jornada. Especialmente, à Ana Luiza Mesquita de Souza que, pacientemente, dividiu casa comigo e à Morgana Sigmaringa Zamprogno que sempre me ajudava com seu apoio mesmo à distância. Agradeço por terem dividido tantos momentos bons e ruins, terem me aconselhado diversas vezes e me apoiado sempre.

Agradeço também aos amigos que fiz fora do INPE durante os anos dessa jornada. Em especial ao Guilherme Brangioni, Luiz Eduardo Diniz, Dylan

Nascimento e todos aqueles que me apoiavam nos momentos difíceis com uma simples ligação ou mensagem.

Agradeço aos doutores Thales Sehn Körting, Ieda Del'Arco Sanches e Sandra Maria Fonseca da Costa que prontamente aceitaram compor a banca e contribuíram com sugestões e opiniões muito valiosas para enriquecimento do trabalho.

Agradeço também a todos funcionários do INPE (biblioteca, limpeza, manutenção, entre outros) que ajudam diariamente com dedicação e competência a manter o centro de pesquisa vivo.

E agradeço ao CNPq pela bolsa fornecida e incentivo à ciência, tecnologia e inovação que são capazes de mover o mundo.

## RESUMO

Mapas de uso e cobertura da terra são um dos principais produtos oriundos de dados de sensoriamento remoto. Eles são utilizados como base para diversos estudos da dinâmica terrestre. Entretanto, dados de sensoriamento remoto estão sujeitos a ruídos podendo afetar parcial ou totalmente a disponibilidade de dados em algumas regiões gerando os chamados valores faltantes e comprometendo a obtenção de mapas de uso e cobertura da terra. Muitas podem ser as causas desses ruídos, porém as condições atmosféricas, particularmente a presença de nuvens e sombras de nuvens, ainda são os principais obstáculos na aquisição contínua de dados. Dessa forma, a primeira etapa para trabalhar com dados afetados por esse tipo ruído é sua identificação. A partir da delimitação das áreas cobertas por nuvens e suas sombras, é possível iniciar o tratamento dos valores faltantes. Existem diversas metodologias na literatura capazes de estimar ou reconstruir esses valores. Basicamente, essas técnicas utilizam contexto espacial, temporal ou espaço-temporal entre pixels próximos para estimar ou reconstruir valores. Entretanto, esses métodos consideram os valores radiométricos nas estimativas que são normalmente os valores de reflectância ou índices radiométricos sendo necessária a posterior classificação dos dados. Neste contexto, o presente trabalho aborda métodos pós-classificação que estimam as classes de uso e cobertura da terra e calculam as incertezas dessas estimativas. No trabalho são introduzidos dois novos métodos para estimar as classes baseados na análise espaço-temporal de classes em pixels com valores válidos denominados Análise de Transições (ATRANS) e Análise de Trajetórias (ATRAJ). O método ATRANS utiliza os transiogramas de classes entre duas imagens para basear as estimativas em áreas com valores faltantes. Enquanto o método ATRAJ utiliza as trajetórias de classes para basear as estimativas. Ambos os métodos realizam um levantamento das mudanças de classes a partir de uma análise pixel a pixel em áreas com valores válidos, ou seja, áreas não afetadas pela cobertura de nuvens e sombras de nuvens. As técnicas propostas foram aplicadas e validadas em dois estudos de caso com classificações obtidas de imagens Sentinel-2/MSI e Landsat-5/TM. Foram aplicadas as classificações da Máxima Verossimilhança, *Random Forest* e *Support Vector Machine* para geração das classificações de referência. Os resultados obtidos mostram pouca diferença entre os resultados tanto variando os métodos quanto as classificações. Entre as vantagens dos métodos estão a efetividade quando aplicados a séries temporalmente curtas e a possibilidade do cálculo das incertezas de estimativas. Entretanto, o método ATRAJ possui uma menor taxa de pixel não estimados. Além disso, os métodos mostram-se eficiente quando aplicados a classificações de referência com baixa taxas de erros por comissão e omissão.

Palavras-chave: Valores faltantes. Nuvens. Sombra de nuvens. Uso e cobertura da terra. Estimativa de classes.



# **METHODS FOR LAND USE LAND COVER CLASS ESTIMATION IN CLOUD COVERED AREAS BASED ON SPATIO-TEMPORAL CLASS DISTRIBUTION**

## **ABSTRACT**

Land use and land cover maps are one of the main products derived from remote sensing data. They are used in several studies of terrestrial dynamics. However, remote sensing data is still subject to noise, which may partially or totally affect data availability in some regions, generating missing values and compromising the production of land use and land cover maps. These noises can be caused by a variety of reasons, but atmospheric conditions, particularly the presence of clouds and cloud shadows, are still the main obstacles in the continuous acquisition of data. Thus, the first step in working with data affected by this type of noise is its identification. By delimitating the areas covered by clouds and their shadows, it is possible to start the treatment of missing values. There are several methodologies available in the literature capable of estimating or reconstructing these values. Basically, these techniques use spatial, temporal or spatio-temporal context among nearby pixels to estimate or reconstruct values. However, these methods consider only radiometric values when estimating and they are usually applied on the reflectance values or on radiometric indices, requiring subsequent classification over estimated data. In this context, the present work introduces post-classification methods to estimate land use and land cover classes and calculate their uncertainties. The work presents two new methods to estimate classes based on the spatio-temporal analysis of classes in pixels with valid values called Transition Analysis (ATRANS) and Trajectory Analysis (ATRAJ). The ATRANS method uses class transiograms between two classified images to estimate classes of pixels on areas with missing values. While ATRAJ method uses class trajectories to estimate classes of pixels on areas with missing values. Both methods perform a survey of class changes based on a pixel-by-pixel analysis in areas with valid values, in other words, areas not affected by cloud cover and cloud shadows. Among the advantages of the methods are the effectiveness when applied to short time series and the possibility of calculating uncertainty values. The proposed techniques were applied and validated in two case studies with Sentinel-2/MSI and Landsat-5/TM images. The Maximum Likelihood, Random Forest and Support Vector Machine classifications were applied to these images to generate classification references. The results obtained show small differences between results when varying both methods and classifications. However, ATRAJ method present a lower rate of non-estimated pixels. In addition, both methods prove to be efficient when applied to classifications references with low error rates by commission and omission.

Keywords: Missing value. Cloud. Cloud shadow. Land use and land cover. Class estimation.



## LISTA DE FIGURAS

	<u>Pág.</u>
Figura 1.1 - Exemplos de valores faltantes em sensoriamento remoto oriundos da característica de aquisição, defeitos do sistema imageador e condições atmosféricas. ....	3
Figura 2.1 - Exemplos de transições de uso e cobertura da terra. ....	10
Figura 2.2 - Exemplos de trajetórias de uso e cobertura da terra. ....	11
Figura 2.3 - Exemplos de respostas espectrais similares em composições colorida verdadeira (R4G3B2) e falsa-cor (R6G5B4). ....	18
Figura 3.1 - Metodologia adotada no trabalho. ....	27
Figura 3.2 - Mapa de localização da área de estudo. ....	29
Figura 3.3 - Imagens Sentinel-2/MSI selecionadas. ....	32
Figura 3.4 - Imagens Landsat-5/TM selecionadas. ....	35
Figura 3.5 – Pré-processamento aplicado às imagens Sentinel-2. ....	37
Figura 3.6 - Amostras das classes de uso e cobertura da terra, sobrepostas às composições R4G3B2 das imagens Sentinel-2/MSI. ....	42
Figura 3.7 - Amostras das classes de uso e cobertura da terra, sobrepostas às composições R5G4B2 das imagens Landsat-5/TM. ....	43
Figura 3.8 - Simulações de nuvens geradas. ....	46
Figura 3.9 - Organização do método ATRANS. ....	49
Figura 3.10 - Fluxograma para geração dos transiogramas. ....	50
Figura 3.11 - Exemplo da estimativa de classes realizada pelo método da Análise de Transições (ATRANS). ....	54
Figura 3.12 - Organização do método ATRAJ. ....	56
Figura 3.13 - Exemplo da estimativa de classes realizada pelo método da Análise de Trajetórias (ATRAJ). ....	59
Figura 3.14 - Fluxograma geral da metodologia de avaliação dos métodos. ...	60
Figura 4.1 – Exemplo de área com pixels não estimados pelo método ATRAJ em imagens classificadas do Sentinel-2/MSI. ....	65
Figura 4.2 - Exemplo de área com pixels não estimados pelo método ATRANS em imagens classificadas do Sentinel-2/MSI. ....	66

Figura 4.3 - Concordância parcial para as estimativas realizadas sobre imagens classificadas pelo método MAXVER para imagens Sentinel-2/MSI. ....	74
Figura 4.4 - Concordância parcial para as estimativas realizadas sobre imagens classificadas pelo método RF para imagens Sentinel-2/MSI.....	74
Figura 4.5 – Concordância parcial para as estimativas realizadas sobre imagens classificadas pelo método SVM para imagens Sentinel-2/MSI. ....	75
Figura 4.6 - Índice de desacordo para as estimativas realizadas sobre imagens classificadas pelo método MAXVER para imagens Sentinel-2/MSI. ....	75
Figura 4.7 - Índice de desacordo para as estimativas realizadas sobre imagens classificadas pelo método RF para imagens Sentinel-2/MSI.....	76
Figura 4.8 - Índice de desacordo para as estimativas realizadas sobre imagens classificadas pelo método SVM para imagens Sentinel-2/MSI.....	76
Figura 4.9 – Comparação entre as estimativas ATRANS e ATRAJ e suas respectivas incertezas nas imagens Sentinel-2/MSI classificadas. ....	78
Figura 4.10 – Exemplo de área com pixels não estimados pelo método ATRAJ em imagens classificadas do Landsat-5/TM.....	80
Figura 4.11 – Exemplo de área com pixels não estimados pelo método ATRANS em imagens classificadas do Landsat-5/TM. ....	81
Figura 4.12 – Concordância parcial para as estimativas realizadas sobre imagens classificadas pelo método MAXVER para imagens Landsat-5/TM. ...	88
Figura 4.13 - Concordância parcial para as estimativas realizadas sobre imagens classificadas pelo método RF para imagens Landsat-5/TM. ....	88
Figura 4.14 - Concordância parcial para as estimativas realizadas sobre imagens classificadas pelo método SVM para imagens Landsat-5/TM.....	89
Figura 4.15 – Índice de desacordo para as estimativas realizadas sobre imagens classificadas pelo método MAXVER para imagens Landsat-5/TM. ...	89
Figura 4.16 - Índice de desacordo para as estimativas realizadas sobre imagens classificadas pelo método RF para imagens Landsat-5/TM. ....	90
Figura 4.17 - Índice de desacordo para as estimativas realizadas sobre imagens classificadas pelo método SVM para imagens Landsat-5/TM.....	90
Figura 4.18 – Comparação entre as estimativas ATRANS e ATRAJ e suas respectivas imagens Landsat-5/TM classificadas originais. ....	93



Figura 4.19 – Comparação entre as estimativas ATRANS e ATRAJ e suas respectivas incertezas nas imagens Landsat-5/TM classificadas. ....	94
Figura B.1 - Amostra de Área de Cultivo em imagem Sentinel-2/MSI.....	113
Figura B.2 – Exemplo de Área em Pousio.....	114
Figura B.3 - Amostra de Área de Pousio na imagem Sentinel-2/MSI.....	114
Figura B.4 – Exemplo de Corpo D'água. ....	115
Figura B.5 - Amostra de Corpo D'água na imagem Sentinel-2/MSI. ....	115
Figura B.6 - Exemplo de Formação Florestal. ....	115
Figura B.7 - Amostra de Formação Florestal na imagem Sentinel-2/MSI.....	116
Figura B.8 - Exemplo de Pasto Limpo. ....	116
Figura B.9 - Amostra de Pasto Limpo na imagem Sentinel-2/MSI. ....	116
Figura B.10 - Exemplo de Pasto Sujo.....	117
Figura B.11 - Amostra de Pasto Sujo na imagem Sentinel-2/MSI.....	117
Figura B.12 - Exemplo de Solo Exposto.....	118
Figura B.13- Amostra de Solo Exposto na imagem Sentinel-2/MSI. ....	118
Figura C.1 - Matriz de confusão da classificação da imagem Sentinel-2/MSI de 11 de julho de 2017 pelo método MAXVER. ....	119
Figura C.2 - Matriz de confusão da classificação da imagem Sentinel-2/MSI de 16 de julho de 2017 pelo método MAXVER. ....	120
Figura C.3 - Matriz de confusão da classificação da imagem Sentinel-2/MSI de 26 de julho de 2017 pelo método MAXVER. ....	120
Figura C.4 - Matriz de confusão da classificação da imagem Sentinel-2/MSI de 11 de julho de 2017 pelo método RF. ....	121
Figura C.5 - Matriz de confusão da classificação da imagem Sentinel-2/MSI de 16 de julho de 2017 pelo método RF. ....	121
Figura C.6 - Matriz de confusão da classificação da imagem Sentinel-2/MSI de 26 de julho de 2017 pelo método RF. ....	122
Figura C.7 - Matriz de confusão da classificação da imagem Sentinel-2/MSI de 11 de julho de 2017 pelo método SVM.....	122
Figura C.8 - Matriz de confusão da classificação da imagem Sentinel-2/MSI de 16 de julho de 2017 pelo método SVM.....	123

Figura C.9 - Matriz de confusão da classificação da imagem Sentinel-2/MSI de 26 de julho de 2017 pelo método SVM.....	123
Figura C.10 - Matriz de confusão da classificação da imagem Landsat-5/TM de 21 de junho de 2007 pelo método MAXVER. ....	124
Figura C.11 - Matriz de confusão da classificação da imagem Landsat-5/TM de 23 de junho de 2008 pelo método MAXVER. ....	124
Figura C.12 - Matriz de confusão da classificação da imagem Landsat-5/TM de 29 de junho de 2010 pelo método MAXVER. ....	125
Figura C.13 - Matriz de confusão da classificação da imagem Landsat-5/TM de 21 de junho de 2007 pelo método RF. ....	125
Figura C.14 - Matriz de confusão da classificação da imagem Landsat-5/TM de 23 de junho de 2008 pelo método RF. ....	126
Figura C.15 - Matriz de confusão da classificação da imagem Landsat-5/TM de 29 de junho de 2010 pelo método RF. ....	126
Figura C.16 - Matriz de confusão da classificação da imagem Landsat-5/TM de 21 de junho de 2007 pelo método SVM. ....	127
Figura C.17 - Matriz de confusão da classificação da imagem Landsat-5/TM de 23 de junho de 2008 pelo método SVM. ....	127
Figura C.18 - Matriz de confusão da classificação da imagem Landsat-5/TM de 29 de junho de 2010 pelo método SVM. ....	128
Figura C.19 - Classificações de referência das imagens Sentinel-2/MSI. ....	131
Figura C.20 - Classificações de referência das imagens Landsat-5/TM.....	132
Figura E.1 - Estimativa e incerteza da imagem Sentinel-2/MSI classificada pelo método MAXVER do dia 11 julho de 2017. ....	136
Figura E.2 - Estimativa e incerteza da imagem Sentinel-2/MSI classificada pelo método MAXVER do dia 16 julho de 2017. ....	137
Figura E.3 - Estimativa e incerteza da imagem Sentinel-2/MSI classificada pelo método MAXVER do dia 26 julho de 2017. ....	138
Figura E.4 - Estimativa e incerteza da imagem Sentinel-2/MSI classificada pelo método RF do dia 11 julho de 2017. ....	139
Figura E.5 - Estimativa e incerteza da imagem Sentinel-2/MSI classificada pelo método RF do dia 16 julho de 2017. ....	140

Figura E.6 - Estimativa e incerteza da imagem Sentinel-2/MSI classificada pelo método RF do dia 26 julho de 2017. ....	141
Figura E.7 - Estimativa e incerteza da imagem Sentinel-2/MSI classificada pelo método SVM do dia 11 julho de 2017. ....	142
Figura E.8 - Estimativa e incerteza da imagem Sentinel-2/MSI classificada pelo método SVM do dia 16 julho de 2017. ....	143
Figura E.9 - Estimativa e incerteza da imagem Sentinel-2/MSI classificada pelo método SVM do dia 26 julho de 2017. ....	144
Figura F.1 - Estimativa e incerteza da imagem Landsat-5/TM classificada pelo método MAXVER do dia 21 junho de 2007. ....	145
Figura F.2 - Estimativa e incerteza da imagem Landsat-5/TM classificada pelo método MAXVER do dia 23 junho de 2008. ....	146
Figura F.3 - Estimativa e incerteza da imagem Landsat-5/TM classificada pelo método MAXVER do dia 28 junho de 2010. ....	147
Figura F.4 - Estimativa e incerteza da imagem Landsat-5/TM classificada pelo método RF do dia 21 junho de 2007. ....	148
Figura F.5 - Estimativa e incerteza da imagem Landsat-5/TM classificada pelo método RF do dia 23 junho de 2008. ....	149
Figura F.6 - Estimativa e incerteza da imagem Landsat-5/TM classificada pelo método RF do dia 28 junho de 2010. ....	150
Figura F.7 - Estimativa e incerteza da imagem Landsat-5/TM classificada pelo método SVM do dia 21 junho de 2007. ....	151
Figura F.8 - Estimativa e incerteza da imagem Landsat-5/TM classificada pelo método SVM do dia 23 junho de 2008. ....	152
Figura F.9 - Estimativa e incerteza da imagem Landsat-5/TM classificada pelo método SVM do dia 28 junho de 2010. ....	153



## LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1 - Principais características da imagem Sentinel-2/MSI.....	13
Tabela 2.2 - Principais características espectrais Sentinel-2/MSI.....	13
Tabela 2.3 - Principais características da imagem Landsat-5/TM.....	14
Tabela 2.4 – Métodos de detecção de nuvens e sombras de nuvens em sensoramento remoto.....	21
Tabela 2.5 – Exemplos de métodos de reconstrução de valores faltantes em dados de sensoramento remoto.....	26
Tabela 3.1 – Descrição das imagens Sentinel-2-MSI utilizadas.....	31
Tabela 3.2 – Descrição das imagens Landsat-5/TM utilizadas.....	34
Tabela 3.3 - Especificações das amostras nas imagens Sentinel-2/MSI.....	40
Tabela 3.4 - Especificações das amostras nas imagens Landsat-5/TM.....	40
Tabela 3.5 - Valores selecionados de <i>Cost</i> (C) e <i>gamma</i> (g) para classificação das imagens pelo método SVM.....	41
Tabela 3.6 - Características gerais das simulações geradas.....	45
Tabela 3.7 – Sobreposições temporais das máscaras simuladas.....	46
Tabela 3.8 - Modelo da matriz de erro utilizada para a aferição da acurácia temática das imagens estimadas.....	61
Tabela 4.1 - Taxa de pixels não estimados sobre imagens Sentinel-2/MSI classificadas.....	65
Tabela 4.2 – Índices de avaliação das estimativas pelo método ATRANS realizadas sobre imagens Sentinel-2/MSI classificadas.....	67
Tabela 4.3 - Índices relativos ao método ATRANS para as classes de uso e cobertura da terra em estudo sobre imagens Sentinel-2/MSI classificadas.....	69
Tabela 4.4 - Índices de avaliação das estimativas pelo método ATRAJ realizadas sobre imagens Sentinel-2/MSI classificadas.....	70
Tabela 4.5 - Índices relativos ao método ATRAJ para as classes de uso e cobertura da terra em estudo sobre imagens Sentinel-2/MSI classificadas.....	72
Tabela 4.6 - Valores-P resultantes da aplicação do teste estatístico Z comparativo entre os métodos de estimativa analisados no estudo de caso I.	73

Tabela 4.7 - Taxa de pixels não estimados sobre imagens Landsat-5 / TM classificadas. ....	79
Tabela 4.8 - Índices de avaliação das estimativas pelo método ATRANS realizadas sobre imagens Landsat-5/TM classificadas. ....	82
Tabela 4.9 - Índices relativos ao método ATRANS para as classes de uso e cobertura da terra em estudo sobre imagens Landsat-5/TM classificadas.....	83
Tabela 4.10 - Índices de avaliação das estimativas pelo método ATRAJ realizadas sobre imagens Landsat-5/TM classificadas. ....	84
Tabela 4.11 - Índices relativos ao método ATRAJ para as classes de uso e cobertura da terra em estudo sobre imagens Landsat-5/TM classificadas.....	86
Tabela 4.12 - Valores-P resultantes da aplicação do teste estatístico Z comparativo entre os métodos de estimativa analisados no estudo de caso II.	87
Tabela 4.13 - Exemplo de trajetórias que possuíam a classe Solo Exposto atribuída na primeira e última imagens da série. ....	92
Tabela C.1 – Índices de avaliação para as classificações de referência.....	128
Tabela C.2 – Índices de avaliação por classe para as classificações de referência das imagens Sentinel-2/MSI.....	129
Tabela C.3 – Índices de avaliação por classe para as classificações de referência das imagens Landsat-5/TM. ....	130
Tabela D.1 - Transiograma de probabilidade de mudança de classe para classificação MAXVER das imagens Sentinel-2/MSI. ....	133
Tabela D.2 - Transiograma de probabilidade de mudança de classe para classificação RF das imagens Sentinel-2/MSI.....	133
Tabela D.3 - Transiograma de probabilidade de mudança de classe entre para classificação SVM das imagens Sentinel-2/MSI.....	134
Tabela D.4 - Transiograma de probabilidade de mudança de classe para classificação MAXVER das imagens Landsat-5/TM.....	134
Tabela D.5 - Transiograma de probabilidade de mudança de classe para classificação RF das imagens Landsat-5/TM.....	135
Tabela D.6 - Transiograma de probabilidade de mudança de para classificação SVM das imagens Landsat-5/TM. ....	135

Tabela G.1 – Estatísticas das incertezas por classe para classificação MAXVER da imagem Sentinel-2/MSI de 11 de julho de 2017.....	154
Tabela G.2 – Estatísticas das incertezas por classe para classificação MAXVER da imagem Sentinel-2/MSI de 16 de julho de 2017.....	154
Tabela G.3 – Estatísticas das incertezas por classe para classificação MAXVER da imagem Sentinel-2/MSI de 26 de julho de 2017.....	155
Tabela G.4 – Estatísticas das incertezas por classe para classificação RF da imagem Sentinel-2/MSI de 11 de julho de 2017.....	155
Tabela G.5 – Estatísticas das incertezas por classe para classificação RF da imagem Sentinel-2/MSI de 16 de julho de 2017.....	155
Tabela G.6 – Estatísticas das incertezas por classe para classificação RF da imagem Sentinel-2/MSI de 26 de julho de 2017.....	156
Tabela G.7 – Estatísticas das incertezas por classe para classificação SVM da imagem Sentinel-2/MSI de 11 de julho de 2017.....	156
Tabela G.8 – Estatísticas das incertezas por classe para classificação SVM da imagem Sentinel-2/MSI de 16 de julho de 2017.....	156
Tabela G.9 – Estatísticas das incertezas por classe para classificação SVM da imagem Sentinel-2/MSI de 28 de julho de 2017.....	157
Tabela G.10 – Estatísticas das incertezas por classe para classificação MAXVER da imagem Landsat-5/TM de 21 de junho de 2007.....	157
Tabela G.11 – Estatísticas das incertezas por classe para classificação MAXVER da imagem Landsat-5/TM de 23 de junho de 2008.....	157
Tabela G.12 – Estatísticas das incertezas por classe para classificação MAXVER da imagem Landsat-5/TM de 28 de junho de 2010.....	158
Tabela G.13 – Estatísticas das incertezas por classe para classificação RF da imagem Landsat-5/TM de 21 de junho de 2007.....	158
Tabela G.14 – Estatísticas das incertezas por classe para classificação RF da imagem Landsat-5/TM de 23 de junho de 2008.....	158
Tabela G.15 – Estatísticas das incertezas por classe para classificação RF da imagem Landsat-5/TM de 28 de junho de 2010.....	159
Tabela G.16 – Estatísticas das incertezas por classe para classificação SVM da imagem Landsat-5/TM de 21 de junho de 2007.....	159

Tabela G.17 – Estatísticas das incertezas por classe para classificação SVM da imagem Landsat-5/TM de 23 de junho de 2008. ....	159
Tabela G.18 – Estatísticas das incertezas por classe para classificação SVM da imagem Landsat-5/TM de 28 de junho de 2010. ....	160



## LISTA DE SIGLAS E ABREVIATURAS

AC	Área de Cultivo
ALOS	<i>Advanced Land Observing Satellite</i>
AP	Área em Pousio
ASTER	<i>Advanced Spaceborne Thermal Emission and Reflection Radiometer</i>
ATRAJ	Análise das trajetórias de classes
ATRANS	Análise das transições de classes
AVHRR	<i>Advanced Very High Resolution Radiometer</i>
CA	Corpo D'água
CBERS	<i>China-Brazil Earth-Resources Satellite</i>
CG	Índice de Concordância Global
CP	Índice de Concordância Parcial
EA	Erro de Atribuição de Classe
ETM+	<i>Enhanced Thematic Mapper Plus</i>
EVI	<i>Enhanced Vegetation Index</i>
FL	Formação Florestal
FMask	<i>Function of Mask</i>
ID	Índice de Desacordo
MAXVER	<i>Máxima Verossimilhança</i>
MDE	<i>Modelo Digital de Elevação</i>
MetOp	<i>Meteorological Operational satellite programme</i>
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
MSI	<i>MultiSpectral Instrument</i>
ND	<i>Número Digital</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
OLI	<i>Operational Terra Imager</i>
PA	Pastagem
PALSAR	<i>Phased Array type L-band Synthetic Aperture Radar</i>
PL	Pasto Limpo
PS	Pasto Sujo
QA	<i>Quality Assessment</i>
RC	Índice de Representação de Classe
RF	<i>Random Forest</i>

SAVI	<i>Soil-Adjusted Vegetation Index</i>
SE	Solo Exposto
SLC	<i>Scan-Line Corrector</i>
SMLD	<i>Single Minimum Link Dendrogram</i>
SPOT	<i>Satellite Pour l'Observation de la Terre</i>
SVM	<i>Support Vector Machine</i>
TC	<i>Tasseled Cap</i>
TiSeG	<i>Time-Series Generator</i>
TM	<i>Thematic Mapper</i>
USGS	<i>United States Geological Survey</i>
VI	Vegetação Secundária em Estágio Inicial

## SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO.....	1
1.1 Hipótese de trabalho.....	5
1.2 Objetivos do trabalho.....	5
1.3 Organização do trabalho.....	6
2 FUNDAMENTAÇÃO TEÓRICA .....	7
2.1 Estudos sobre mudanças do uso e cobertura da terra .....	7
2.1.1 Transição de classes de uso e cobertura da terra .....	9
2.1.2 Trajetória de classes de uso e cobertura da terra.....	10
2.2 Sensoriamento remoto passivo .....	11
2.2.1 Dados Sentinel-2/MSI .....	12
2.2.2 Dados Landsat-5/TM.....	13
2.2.3 Classificação de imagens em sensoriamento remoto .....	14
2.3 Valores faltantes em dados de sensoriamento remoto oriundos da cobertura de nuvens e de suas sombras.....	15
2.3.1 Métodos de detecção de nuvens e sombras de nuvens .....	17
2.3.1.1 Algoritmo <i>Function of Mask</i> (FMask).....	21
2.4 Métodos de tratamento de valores faltantes em imagens de sensoriamento remoto.....	22
3 MATERIAL E MÉTODOS .....	27
3.1 Área de Estudo .....	28
3.2 Base de dados.....	30
3.2.1 Imagens Sentinel-2/MSI.....	30
3.2.2 Imagem Landsat-5/TM.....	33
3.3 Pré-processamento.....	36
3.4 Classificação.....	37
3.5 Simulação de valores faltantes .....	44
3.6 Técnicas Propostas .....	47
3.6.1 Análise das transições de classes de uso e cobertura da terra (Método ATRANS) .....	48

3.6.1.1	Construção dos transiogramas .....	49
3.6.1.2	Probabilidade de transição de classes de uso e cobertura da terra. 50	
3.6.1.3	Estimativa da classe de uso e cobertura da terra em áreas com valores faltantes .....	52
3.6.1.4	Cálculo das incertezas.....	55
3.6.2	Análise das trajetórias de classes de uso e cobertura da terra (Método ATRAJ).....	55
3.6.2.1	Construção da matriz de trajetórias .....	56
3.6.2.2	Probabilidade de trajetória e estimativa de classes em áreas com valores faltantes .....	57
3.6.2.3	Cálculo das incertezas.....	58
3.7	Validação.....	60
3.8	Softwares utilizados.....	63
4	RESULTADOS .....	64
4.1	Estudo de caso I: Imagens Sentinel-2/MSI .....	64
4.1.1	Taxa de pixels não estimados.....	64
4.1.2	Avaliação dos resultados obtidos pelo método ATRANS.....	66
4.1.3	Avaliação dos resultados obtidos pelo método ATRAJ.....	70
4.1.4	Avaliação comparativa entre os métodos propostos.....	73
4.2	Estudo de caso II: Imagens Landsat-5/TM .....	79
4.2.1	Taxa de pixels não estimados.....	79
4.2.2	Avaliação dos resultados obtidos pelo método ATRANS.....	81
4.2.3	Avaliação dos resultados obtidos pelo método ATRAJ.....	84
4.2.4	Avaliação comparativa entre os métodos propostos.....	87
5	CONCLUSÕES E TRABALHOS FUTUROS .....	95
	REFERÊNCIAS BIBLIOGRÁFICAS .....	98
	APÊNDICE A – PSEUDOCÓDIGOS UTILIZADOS PARA ESTIMATIVA DE VALORES FALTANTES EM SENSORIAMENTO REMOTO .....	111
	APÊNDICE B - DETALHES DAS CLASSES DE USO E COBERTURA DO SOLO PARA IMAGENS SENTINEL-2/MSI .....	113
	APÊNDICE C – MATRIZ DE CONFUSÃO E ÍNDICE DAS CLASSIFICAÇÕES UTILIZADAS.....	119

APÊNDICE D – TRANSIOGRAMAS DE PROBABILIDADE DE MUDANÇAS DE CLASSES DE USO E COBERTURA DA TERRA .....	133
APÊNDICE E – PRODUTOS DAS ESTIMATIVAS APLICADAS AO ESTUDO DE CASO I .....	136
APÊNDICE F – PRODUTOS DAS ESTIMATIVAS APLICADAS AO ESTUDO DE CASO II .....	145
APÊNDICE G – ESTATÍSTICAS DAS INCERTEZAS SOBRE O MÉTODO DA ANÁLISE DE TRAJETÓRIAS (ATRAJ).....	154

## 1 INTRODUÇÃO

Um dos produtos gerados de dados de sensoriamento remoto mais utilizado em estudos ambientais é o mapa de uso e cobertura da terra obtido a partir da classificação de imagens (GOMEZ-CHOVA *et al.*, 2015; GREEN *et al.*, 1994). Produtos precisos e periódicos permitem a compreensão da dinâmica da cobertura terrestre incluindo mudanças climáticas, conservação da biodiversidade e a interação entre atividades sociais de ambientes em mudança que requerem caracterização espaço-temporal (CHEN; HUANG; XU, 2017; RODRÍGUEZ-JEANGROS *et al.*, 2017). Os dados provenientes de sensores remotos imageadores apresentam alto potencial para interpretação, mapeamento e análise de mudanças devido a disponibilidade de acesso gratuito a uma grande quantidade de dados de diversos sensores (LABORDE *et al.*, 2017).

Dados oriundos de sistemas sensores remotos passivos, aqueles atuantes na faixa óptica e faixa termal do espectro eletromagnético, são os mais frequentemente utilizados para a classificação. Eles são capazes de fornecer dados que variam de acordo com as propriedades físico-químicas dos alvos, bem como as geometrias de iluminação e visada do sensor (GOMEZ-CHOVA *et al.*, 2015; PEREIRA *et al.* 2018).

Entre as vantagens da utilização de sensores passivos estão a ampla série de dados disponíveis e o potencial para geração de produtos com alta precisão e acurácia. Esse tipo de dado gerou bastantes trabalhos desde que foi disponibilizado para estudos da Terra, acumulando uma vasta experiência e conhecimento no campo. Além disso, existe uma grande quantidade de ferramentas disponíveis na literatura para trabalhar com tais dados.

Dentre os diversos sistemas sensores passivos orbitais destinados à observação da terra disponíveis atualmente, destacam-se os pertencentes às plataformas TERRA, AQUA, CBERS (*China-Brazil Earth-Resources Satellite*), Landsat e Sentinel por apresentarem uma boa resolução espacial e temporal viabilizando diversos estudos sobre a cobertura terrestre. Os dados originados desses sistemas, aliados a métodos disponíveis para análise, são capazes de gerar

diversos produtos para compreensão da dinâmica terrestre, entre eles: mudança de uso e cobertura do terra, mudança florestal ou de vegetação, mortalidade florestal e avaliação de danos, mudança de paisagem, análise de crescimento urbano, e de culturas agrícolas, entre outros (LAMBIN *et al.*, 2000; LU *et al.*, 2004; LIU; ZHOU, 2005).


Apesar da facilidade de acesso aos dados, as imagens obtidas de sensores remotos orbitais estão sujeitas ao efeito de ruídos que levam à ausência de dados em determinadas regiões das imagens. Esses ruídos são responsáveis pela geração dos chamados valores faltantes (*missing values*) representados por pixels que compõem áreas com vazios de dados sobre a cobertura terrestre na imagem.

Diversas podem ser as origens desses ruídos, como: defeitos nos instrumentos do sistema imageador, condição atmosférica, características de aquisição dos dados, entre outros (OLIVEIRA; EPIPHANIO, 2012). Trigg *et al.* (2006) destacam que o defeito presente no *Scan-Line Corrector (SLC)* no sensor *Enhanced Thematic Mapper Plus (ETM+)* do satélite Landsat-7 resultou em uma perda de aproximadamente 25% dos pixels de cada cena devido ao efeito *stripping* gerado. Dare (2005) elucida que o efeito das sombras gerado pela mudança na elevação ou mudança do ângulo de aquisição pode levar a perda parcial ou total de informações. Tahsin *et al.* (2017) destacam que as nuvens e suas sombras podem obscurecer, sombrear ou saturar as imagens. Os autores ainda afirmam que os efeitos gerados incluem a omissão ou a distorção total das leituras na imagem dificultando o monitoramento dos ecossistemas terrestres devido à introdução de ruídos indesejáveis.

A Figura 1.1 ilustra alguns exemplos mais comuns da origem de valores faltantes em dados de sensoriamento remoto. Nessa figura as partes (a) e (b) representam valores faltantes oriundos das características de aquisição da imagem nos sensores Orbiview-3 e Sentinel-2/MSI que, devido ao relevo, geram sombras afetando a aquisição de dados. As partes (c) e (d) representam valores faltantes oriundos de falhas no sensor prejudicando a formação das imagens nos sensores Terra/MODIS e Landsat-7/ETM+, respectivamente. Enquanto as

partes (e) e (f) demonstram a presença de valores faltantes devido às condições atmosféricas (presença de nuvens e suas sombras) em imagens EO-1/ALI e CBERS-4A/WFI.

Figura 1.1 - Exemplos de valores faltantes em sensoriamento remoto oriundos da característica de aquisição, defeitos do sistema imageador e condições atmosféricas.



Origens mais comuns de valores faltantes. Obstrução por sombras em imagens Orbview-3 (a) e Sentinel-2/MSI (b). Defeitos no sistema de imageamento em imagens Terra/MODIS (c) e Landsat-7/ETM+ (d). Presença de nuvens em EO-1/ALI (e) e CBERS-4A/WFI (f).

Fonte: Produção do autor.

As nuvens e as projeções de suas sombras na superfície terrestre inviabilizam a obtenção das propriedades de reflectância dos alvos pelos sensores remotos passivos (ECKARDT *et al.*, 2013). Algumas regiões, como florestas tropicais, apresentam alta suscetibilidade à incidência de cobertura de nuvens limitando tanto a obtenção de dados da superfície terrestre quanto a análise dos mesmos e, portanto, mostrando-se a maior desvantagem na utilização de dados oriundos de sensores imageadores orbitais (ASNER, 2001).



Usualmente, é realizada uma pré-seleção das imagens com a menor cobertura de nuvens possível de uma região de interesse antes do processamento. As áreas com cobertura de nuvens são desconsideradas da classificação pelo uso de máscaras que identificam (de maneira automática ou manualmente) os pixels afetados da imagem.

Nesse contexto, o número de estudos relacionados ao desenvolvimento de métodos para estimar a informação presente nas regiões com valores faltantes é crescente no sensoriamento remoto. Atualmente, grande parte das metodologias de reconstrução desenvolvidas visam a estimativa da reflectância ou de índices radiométricos.

Essas metodologias visam a reconstrução das áreas com valores ou índices espectrais faltantes de uma imagem baseada na proximidade espacial e temporal da informação com menor influência de nuvens. O método desenvolvido por Oliveira, Epiphanyo e Rennó (2014) e denominado janela de regressão foi aplicado para a estimativa de pixels classificados como baixa qualidade para produtos NDVI da família MODIS e considerando o contexto espaço-temporal do índice de vegetação. Lguensat *et al.* (2014) utilizaram uma adaptação do filtro de Kalman para estimar valores de temperatura de superfície oceânica do sensor AVHRR (*Advanced Very High Resolution Radiometer*) a bordo do satélite MetOp (*Meteorological Operational satellite programme*). Já Zhu, Liu e Chen (2012) propuseram uma técnica para preenchimento dos valores faltantes em nível digital oriundos de uma falha do SLC baseado na similaridade dos pixels próximos (contexto espacial).

De maneira análoga, poucos são os trabalhos que visam estimar as classes em áreas de valores faltantes a partir do comportamento das mudanças de classes em regiões com pixels com valores válidos. Salberg e Jenssen (2012) utilizaram um algoritmo baseado em *Support Vector Machine* para classificar áreas com cobertura de nuvem e neve em imagens do Landsat-7/ETM+ obtendo bons valores de acurácia.

Nesse trabalho, busca-se, de maneira similar, utilizar uma abordagem pós classificação para estimar a classe de uso e cobertura da terra em pixels com

valores faltantes. A abordagem é baseada na distribuição dessas classes em um contexto espacial e multitemporal. Isso possibilita a redução do número de vazios de informação criando mapas temáticos melhores e mais completos. Entre as vantagens dos métodos propostos estão a efetividade quando aplicados a séries temporalmente curtas e a possibilidade do cálculo das incertezas de estimativas.

### **1.1 Hipótese de trabalho**

As classes de uso e cobertura da terra de uma dada região apresentam uma relação tanto espacial quanto temporal entre si. O comportamento espaço-temporal das classes pode ser extraído e analisado para determinar padrões de mudança.

Em outras palavras, a partir de um conhecimento *a priori* das classes de uso e cobertura da terra em um dado período, obtido da análise multitemporal de uma região delimitada, é possível estimar a classe de um dado pixel numa região afetada pela cobertura de nuvens e suas sombras em um determinado momento de acordo com a classe atribuídas a esse pixel em outros instantes.

### **1.2 Objetivos do trabalho**

O objetivo geral dessa dissertação é o desenvolvimento de métodos de estimativa de classes de uso e cobertura da terra em regiões compostas por pixels com valores faltantes devido a cobertura de nuvens e suas sombras. Esses métodos utilizam uma abordagem multitemporal baseada nas transições e trajetórias de classes. Para tanto, os objetivos específicos são:

- Proposição de dois métodos de estimativa de classes sendo um a partir das transições de classes e outro a partir de suas trajetórias;
- Avaliação do desempenho dos dois métodos utilizando a Máxima Verossimilhança, *Random Forest* e *Support Vector Machine* como algoritmos de classificação aplicados a imagens Sentinel-2/MSI e Landsat-5/TM.

### **1.3 Organização do trabalho**

Os capítulos desta dissertação estão organizados da seguinte maneira:

- Capítulo 1 (Introdução): são apresentados os conceitos gerais, a hipótese e os objetivos do trabalho;
- Capítulo 2 (Fundamentação Teórica): são abordadas as definições e apresentados os problemas de valores faltantes em imagens de sensoriamento remoto orbital, além da apresentação de algumas abordagens que podem ser encontradas na literatura para tratamento desses valores;
- Capítulo 3 (Materiais e Métodos): são apresentadas a área de estudo e as imagens utilizadas, bem como suas principais características e os processamentos executados sobre elas e, além disso, são descritas detalhadamente a metodologias propostas para estimativas de classes de uso e cobertura da Terra baseadas nas distribuições espaço-temporal de classes;
- Capítulo 4 (Resultados): são discutidos e comentados dois estudos de caso realizados para avaliar as técnicas propostas;
- Capítulo 5 (Conclusões e trabalhos futuros): são explicitadas as conclusões e perspectivas para trabalhos futuro.

## 2 FUNDAMENTAÇÃO TEÓRICA

Nesse capítulo são apresentadas algumas definições pertinentes ao desenvolvimento do trabalho, além de alguns métodos encontrados na literatura para tratamento de dados com valores faltantes.

### 2.1 Estudos sobre mudanças do uso e cobertura da terra

A cobertura da terra refere-se a cobertura biofísica da superfície terrestre a partir da identificação da vegetação, águas interiores, solo exposto ou infraestrutura urbana (GÓMEZ; WHITE; WULDER, 2016). Enquanto o estudo sobre o uso e ocupação da terra visa caracterizar as atividades antropogênicas ou ainda os tipos de categorias de vegetação que reveste o solo (ROSA, 2009).

As mudanças no uso e cobertura da terra provocam impactos socioeconômicos que precisam ser considerados durante o planejamento e desenvolvimento de políticas para uso do solo (LAMBIN; ROUNSEVELL; GEIST, 2000). Além disso, essas mudanças apresentam consequências ambientais que podem afetar a hidrologia, a cobertura florestal, a atmosfera e o clima (MESHSHA, 2009). A compreensão e monitoramento dessas alterações, que ocorrem em diversas escalas (local, regional e global), é um tópico relevante atualmente (GREKOUSIS; MOUNTRAKIS; KAVOURAS, 2015).

Nesse contexto, os dados de sensoriamento são capazes de mostrar as transformações na paisagem, fornecendo informações que servem de base para a construção e teste de modelos de cobertura da terra (TURNER; MEYER; SKOLE, 1994). A extração de informações sobre a cobertura da terra a partir de dados de sensoriamento remoto é uma atividade fundamental e necessária para inúmeras aplicações, entre elas: monitoramento ecológico, florestal e agrícola, cálculo da capacidade de produção da terra e para estimar as interações entre a superfície terrestre e a atmosfera (TOWNSHEND, 1992; KANSAKAR; HOSSAIN, 2016; WULDER *et al.*, 2018). Assim, mapas de uso e cobertura da terra são essenciais para o monitoramento, compreensão e previsão das consequências oriundas da complexa interação entre humano – natureza desde escalas locais a globais (CLARK *et al.*, 2010).

Um bom exemplo de estudo na área de mudanças de uso e cobertura do solo foi elaborado por Zewdie e Csaplovics (2015). Os autores utilizaram quatro imagens Landsat-5/TM obtidas entre 1972 e 2010 para gerar mapas classificados da região noroeste da Etiópia e analisar os fatores que mais influenciaram nas mudanças de cobertura da terra da área de estudo. Eles concluíram que as classificações obtidas foram eficientes na quantificação e caracterização das mudanças de cobertura da terra evidenciando as atividades humanas que levaram a alterações na paisagem e no ecossistema.

Similarmente, no Brasil, Garcia e Ballester (2016) utilizaram imagens ASTER, Landsat-1/MSS, Landsat-5/TM, Landsat-7/ETM+ e IKONOS entre 1975 e 2011 juntamente com dados censitários socioeconômicos para analisar os processos e consequências das mudanças de uso e cobertura da terra em uma região do Cerrado. Os autores foram capazes de descrever as principais mudanças, associá-las aos fatores econômicos e discutir planos de ação na região de estudo.

No trabalho realizado por Silva Junior *et al.* (2014) analisaram-se as mudanças de cobertura da terra na porção noroeste da Amazônia brasileira a partir de mapas obtidos da classificação de duas imagens Landsat-5/TM entre os anos de 2004 e 2010. Os autores afirmaram que a metodologia foi eficiente no monitoramento de mudanças da cobertura terrestre e na identificação das classes naturais mais afetadas pela ação humana.

Similarmente, no trabalho de Reis (2014) foram gerados mapas de uso e cobertura da terra em uma região da Amazônia brasileira a partir de dados Landsat-5/TM e ALOS/Palsar para os anos de 2008 e 2010. Nesse contexto foi possível analisar as mudanças ocorridas no uso e cobertura da terra a partir da integração dos dados de ambos os sensores. Além disso, no estudo realizou-se a correlação entre essas mudanças e as atividades antrópicas da região.

Lopes *et al.* (2020) utilizaram mapas de uso e cobertura da terra derivados de imagens da série Landsat entre os anos de 1985 e 2017 no estado de Goiás como base para análise estatística da dinâmica terrestre. O resultado foi uma descrição a nível municipal das mudanças de uso e cobertura da terra ao longo

de 33 anos. Os autores destacam que a metodologia aplicada foi capaz de detectar a conversão de áreas remanescentes de vegetação nativa para pastagem e áreas de cultivo devido como consequência das políticas públicas de crescimento agrícola da região.

Dessa maneira, torna-se evidente a capacidade dos dados do sensoriamento remoto possam fornecer informações precisas e periódicas sobre o uso e cobertura da terra que são fundamentais para diversos estudos (TOWNSHEND *et al.*, 1991). Os produtos de sensoriamento remoto são, portanto, fundamentais no acompanhamento e monitoramento das mudanças de uso e cobertura da terra (TURNER; LAMBIN; REENBERG, 2007).

Diversos métodos são encontrados na literatura com a finalidade de detectar e extrair as informações de mudanças de uso e cobertura da terra visando o monitoramento de ecossistemas (COPPIN *et al.*, 2004; ZHU, 2017). Para o levantamento dessas informações e no contexto de aplicação neste trabalho, é possível analisar sob dois aspectos distintos: bitemporal e multitemporal.

A partir do contexto bitemporal é realizada a análise das mudanças de uso e cobertura da terra a partir de duas imagens classificadas em tempos distintos sobre uma mesma área. Essas mudanças são denominadas transições de classes de uso e cobertura da terra. Enquanto no contexto multitemporal, é realizada uma análise das mudanças sucessivas sobre uma determinada região ao longo de diversas imagens que representam momentos distintos. Nesse segundo contexto, as mudanças são denominadas trajetórias de uso e cobertura da terra. As definições de cada mudança de uso e cobertura da terra aplicadas nesse trabalho são exploradas nas seções seguintes.

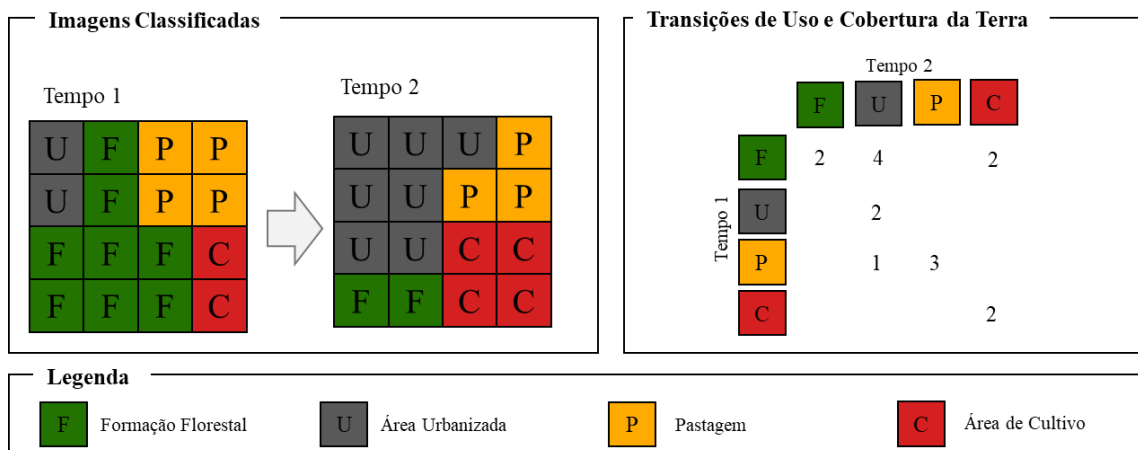
### **2.1.1 Transição de classes de uso e cobertura da terra**

As probabilidades de transições espaciais (também conhecidas como transiogramas) são capazes de representar e quantificar a relação entre classes de duas classificações (LI, 2006). Segundo Liu *et al.* (2019), similarmente, essa probabilidade de transição de classes pode ser estendida para um contexto espaço-temporal para caracterizar as trajetórias de mudança de cobertura da terra.

Os transiogramas são amplamente utilizados na área de modelagem espacial como parâmetros de calibração de modelos preditivos para simulação de mapas de uso e cobertura da terra (CHENG; CAO, 2011; SANG *et al.*, 2011; HAN; YANG; SONG, 2015; HAMAD; BALZTER; KOLO, 2018; SIMIONI; GUASSELLI, 2018; ANEESHA SATYA; SHASHI; DEVA, 2020).

Alguns exemplos de transições de uso e cobertura da terra são ilustrados na Figura 2.1. No exemplo, as trajetórias são extraídas a partir de uma série de cinco imagens classificadas em períodos distintos e sucessivos e compostas por quatro classes de uso e cobertura da terra.

Figura 2.1 - Exemplos de transições de uso e cobertura da terra.



Fonte: Produção do autor.

### 2.1.2 Trajetória de classes de uso e cobertura da terra

Diferentemente dos transiogramas que são utilizados para detectar mudanças tendo duas imagens de tempos distintos como referência, a análise de trajetórias de mudanças de uso e cobertura da terra é um método de pesquisa capaz de acompanhar as mudanças em séries temporais (WANG *et al.*, 2012). Apesar de eficiente para detecção e análise de mudanças em apenas dois instantes no tempo, o método de comparação bitemporal torna-se pouco aplicável com o aumento da série de observações (LIU; ZHOU, 2005).

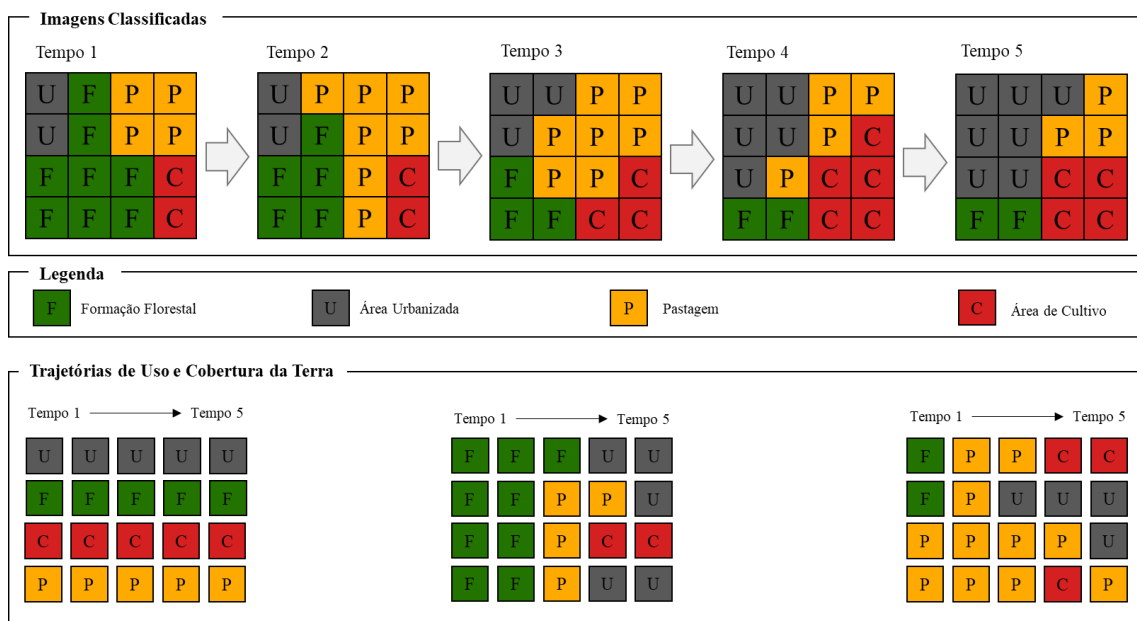
As trajetórias de mudanças de uso e cobertura da terra podem ser definidas como sucessivas transições entre categorias de uso e cobertura ao longo de

mais de duas observações (MERTENS; LAMBIN, 2000; PETIT *et al.*, 2001; MENA; 2008; ZHOU *et al.*, 2008). Segundo Zhou *et al.* (2008), a análise temporal das trajetórias é capaz de revelar as tendências de mudanças de uso e cobertura da terra através de curvas ou perfis de dados multitemporais.

Diversos pesquisadores estudam as trajetórias e analisam as ações antrópicas e os impactos gerados (MERTENS; LAMBIN, 2000; VERBURG *et al.*, 2004; ZHOU; LI; KURBAN, 2008; ZOMLOT *et al.*, 2017). Mais recentemente, os estudos na área focam na utilização das trajetórias para melhorar as classificações eliminando as mudanças de classes impossíveis e aumentando, assim, a acurácia dos mapas classificados (LIU *et al.*, 2019; REIS *et al.*, 2020a).

Alguns exemplos de trajetórias de uso e cobertura da terra são ilustrados na Figura 2.2. No exemplo, as trajetórias são extraídas a partir de uma série de cinco imagens classificadas em períodos distintos e sucessivos e compostas por quatro classes de uso e cobertura da terra.

Figura 2.2 - Exemplos de trajetórias de uso e cobertura da terra.



Fonte: Produção do autor.

## 2.2 Sensoriamento remoto passivo

Os sensores imageadores ópticos passivos geram imagens a partir do registro da quantidade de energia refletida de uma fonte, em regiões que variam do



visível ao infravermelho médio do espectro eletromagnético, ou emitida, na região do infravermelho termal (SCHOWENGERDT, 2007). A identificação de feições características de cada alvo é possível visto que a quantidade de energia refletida varia segundo as propriedades físicas, químicas e biológicas de cada objeto de estudo (JENSEN, 2009).

Atualmente, existe um amplo catálogo de imagens disponíveis de diversas plataformas diferentes, cada uma com características distintas devido à natureza dos sensores que originam cada uma (WULDER *et. al.*, 2015). Entre elas merecem destaque os programas CBERS (LINO; LIMA; HUBSCHER, 2000), SPOT (ARNAUD; LEROY, 1991), MODIS (JUSTICE *et. al.*, 1998), Resoursat (SESHADRI *et. al.*, 2005).

Em se tratando de observação da terra com o foco no meio ambiente, o programa norte-americano LANDSAT foi uns dos primeiros satélites a ser lançado visando o monitoramento terrestre com a primeira missão datada de 1972 (JENSEN, 2009). E, por isso, dispõe de um amplo acervo de imagens visto que é um programa ativo até hoje. O programa LANDSAT ganhou ainda mais destaque quando disponibilizou seu acervo gratuitamente em 2008, aumentando o número de publicações baseadas em seus dados (WULDER *et. al.*, 2012; ZHU *et. al.*, 2019).

O programa Sentinel-2 é uma iniciativa europeia com plataforma ativa desde 2015 visando manter a aquisição contínua de dados aliado às séries Landsat e SPOT com produtos de alta resolução espacial, espectral e espacial para observação da superfície terrestre (ESA, 2019a).

### **2.2.1 Dados Sentinel-2/MSI**

O sensor MSI atua desde a faixa do aerossol costeiro ao infravermelho médio do espectro eletromagnético e suas principais características são apresentadas na Tabela 2.1. Esse sensor possui uma resolução temporal que permite um tempo de revisita de 5 dias no equador (considerando a constelação de satélites) de uma mesma área.

Os sensores da plataforma Sentinel-2 apresentam 13 bandas ao longo do espectro eletromagnético que abrangem desde as bandas do aerossol até

infravermelho curto. As características espectrais dos sensores MSI são apresentadas na Tabela 2.2.

Tabela 2.1 - Principais características da imagem Sentinel-2/MSI.

<b>Característica</b>	<b>Imagem</b>
Resolução espacial	10, 20 e 60 metros
Resolução radiométrica	12 bits
Resolução temporal	10 dias <sup>1</sup>
Resolução espectral	13 bandas
Faixa imageada	290 km

<sup>1</sup> A resolução temporal considerando a constelação de satélites em regiões equatoriais é de 5 dias.

Fonte: ESA (2019b).

Tabela 2.2 - Principais características espectrais Sentinel-2/MSI.

Denominação	Banda	Resolução Espacial (m)	Sentinel-2A/MSI		Sentinel-2B/MSI	
			Centro de banda (nm)	Largura de banda (nm)	Centro de banda (nm)	Largura de banda (nm)
Aerossol	B1	60	442,7	21	442,2	21
Azul	B2	10	492,4	66	492,1	66
Verde	B3	10	559,8	36	559,0	36
Vermelho	B4	10	664,6	31	664,9	31
Red edge - 1	B5	20	704,1	15	703,8	16
Red edge - 2	B6	20	740,5	15	739,1	15
Red edge - 3	B7	20	782,8	20	779,7	20
NIR	B8	10	832,8	106	832,9	106
NIR	B8a	20	864,7	21	864,0	22
Vapor d'água	B9	60	945,1	20	943,2	21
Cirrus	B10	60	1373,5	31	1376,9	30
SWIR-1	B11	20	1613,7	91	1610,4	94
SWIR-2	B12	20	2202,4	175	2185,7	185

Fonte: Adaptado de ESA (2019b).

### 2.2.2 Dados Landsat-5/TM

Os dados adquiridos pelos sensores a bordo dos satélites Landsat compõem o mais longo e completo registro superfície terrestre a partir do espaço sendo de grande valor para estudos sobre mudanças globais (NOVO, 2010). O sensor TM a bordo do satélite Landsat-5 atua da região do visível ao infravermelho termal do espectro eletromagnético. As principais características das imagens oriundas desse sensor são descritas na Tabela 2.3.

Tabela 2.3 - Principais características da imagem Landsat-5/TM.

Característica	Imagem
Resolução espacial	30 e 120 metros <sup>1</sup>
Resolução radiométrica	8 bits
Resolução temporal	16 dias
Resolução espectral	7-bandas: 1 (0,45-0,52 $\mu\text{m}$ ); 2 (0,52-0,60 $\mu\text{m}$ ); 3 (0,63-0,69 $\mu\text{m}$ ); 4 (0,76-0,90 $\mu\text{m}$ ); 5 (1,55-1,75 $\mu\text{m}$ ); 6 (10,40-12,5 $\mu\text{m}$ ); 7 (2,08-2,35 $\mu\text{m}$ )
Faixa imageada	185 km

<sup>1</sup> A resolução espacial de 120 metros corresponde a banda 6 (infravermelho termal).

Fonte: JENSEN (2009).

### 2.2.3 Classificação de imagens em sensoriamento remoto

A classificação pode ser definida como o método de reconhecimento de padrões através do qual um objeto (neste caso, o pixel) é atribuído a um grupo ou classe específicos com base em seus atributos (NATH *et. al.*, 2014). Padrões podem ser definidos como um vetor de feições que descrevem um objeto, sendo assim o principal objetivo do reconhecimento de padrões é estabelecer uma relação entre um desses padrões e uma classe rotulada (MATHER; TSO, 2009). Atualmente existem diversos algoritmos implementados em distintos softwares capazes de classificar imagens orbitais, cada metodologia apresentando parâmetros de entrada ou processamentos diferentes.

Os métodos de classificação são divididos basicamente em supervisionados e não supervisionados. Nas classificações supervisionadas, os pixels são rotulados de acordo com classes de acordo com uma referência (verdade de campo, mapas existentes ou fotointerpretação), enquanto nas classificações não supervisionadas os pixels não são rotulados, mas são determinados por possuir características intrínsecas distintas (SCHOWENGERDT, 2007).

As amostras associadas a rótulos e contêm os atributos de cada banda utilizada (variáveis) são utilizadas nas classificações supervisionadas que utilizam métodos automáticos para categorização (WEBB, 2002). A classificação supervisionada requer a seleção de amostras representativas pelo usuário para

cada classe pré-definida e seu desempenho será altamente dependente da qualidade das amostras coletadas (MATHER; TSO, 2009). Entre os métodos de classificação mais empregados a dados de sensoriamento remoto estão: a Máxima Verossimilhança (MAXVER), *Support Vector Machine* (SVM) e *Random Forest* (RF).

A classificação MAXVER é amplamente utilizada em dados de sensoriamento remoto. Ela compreende um método paramétrico que atribui um pixel a uma classe baseados na fórmula Bayesiana de probabilidade (MATHER; TSO, 2009).

A classificação SVM é um método não-paramétrico que utiliza uma função *kernel* para traçar um hiperplano no espaço de atributos dos dados (KNORN *et al.*, 2009). Nesse estudo, adotou-se uma *Radial Basis Function* (RBF) como função *kernel* por apresentar bons resultados quando comparado a outras funções (SOTHE *et al.*, 2017). A função RBF exige dois parâmetros de entrada para modelar o hiperplano: *Cost* (C) e *gamma* (g). O parâmetro C (*Cost*) é o valor utilizado para ajustar os erros de classificação de acordo com as amostras de treinamento Sothe *et al.* (2017), enquanto o parâmetro *gamma* (g) corresponde a extensão do kernel relacionada diretamente com a suavização da função (MELGANI; BRUZZONE, 2004).

O método RF apresenta-se como um algoritmo não-paramétrico baseado em aprendizado de máquina (*Machine Learning*) que se destaca por sua efetividade na classificação de imagens (ADAM *et al.*, 2014). Ghasemian e Akhoondzadeh (2018) afirmam em seu trabalho que o algoritmo de classificação RF que cria várias árvores de decisão e através de amostras de treinamento são atribuídos pesos para cada uma até uma ser selecionada. Os autores ainda afirmam que o método evita problemas de *overfitting* da classificação, possui um tempo de treinamento menor, reduz ruídos nas classificações e é capaz de estimar a importância de cada variável.

### **2.3 Valores faltantes em dados de sensoriamento remoto oriundos da cobertura de nuvens e de suas sombras**

Apesar dos dados de sensores ópticos serem amplamente utilizados por facilitar não somente a interpretação visual como também a caracterização espectral dos

alvos que compõem a superfície terrestre, eles podem apresentar distúrbios no sinal. Também denominados de ruídos, esses distúrbios são oriundos de erros geométricos remanescentes, condições atmosféricas (presença de nuvens, sombras de nuvens, camadas de aerossóis e vapor d'água), problemas instrumentais durante a geração da imagem, geometrias de visada e iluminação ou ainda anisotropia da superfície (OLIVEIRA; EIPHANIO, 2012; MORENO *et al.*, 2014).

A cobertura de nuvens e a projeção de suas sombras na superfície terrestre mostram-se como os principais obstáculos em diversos estudos quando são utilizados dados oriundos de sensores remotos passivos. A existência de nuvens é uma considerável fonte de incerteza durante a aplicação de qualquer algoritmo que objetiva a recuperação de parâmetros da superfície terrestre, o que dificulta a extração de informações (ECKARDT *et al.*, 2013).

Regiões com cobertura de nuvens persistentes ao longo do ano apresentam uma maior dificuldade para fornecer produtos periódicos de classificação da cobertura terrestre por reduzir o número de observações disponíveis (KOVALSKYY; ROY, 2013). A cobertura de nuvens é um dos maiores problemas na aquisição de imagens por sensoriamento remoto passivo em regiões de clima tropical úmido, como a Floresta Amazônica (ASNER, 2001). Essas regiões requerem constante monitoramento devido à alta dinâmica da cobertura do solo mas também apresentam alta vulnerabilidade à presença de nuvens mesmo durante as épocas de seca entre junho e novembro (ASNER, 2001; LABORDE *et al.*, 2017). Isso afeta mapeamentos a nível regional, como no bioma do Cerrado brasileiro, onde a aquisição de imagens é afetada durante a estação chuvosa da região compreendida entre os meses de novembro e março impedindo a estudos focados na vegetação nativa ou de monitoramento de uso e cobertura da terra a nível mensal (SANO *et al.*, 2007).

Dessa maneira, a geração de alguns produtos é diretamente afetada. Entre eles, destacam-se: cálculo de índices de vegetação (HUETE *et al.*, 2002), monitoramento de vegetação (LU; COOPS; HERMOSILLA, 2017), composição de imagens (ROY *et al.*, 2010), classificação e análise de uso e cobertura do solo

(ZHANG; GUINDON; CIHLAR, 2002; ZHU; WOODCOCK, 2014a), detecção de mudanças (ZHU; WOODCOCK, 2014b; ZHU, 2017), análise de componentes opticamente ativos em ambientes aquáticos (LIU; WANG, 2019), entre outros.

Prudente *et. al.* (2020) apresentaram um estudo sobre as limitações causadas pela cobertura de nuvens no sensoriamento remoto agrícola na América do Sul. Os autores afirmam que em cerca de 59% das áreas de cultivo em território brasileiro apresentam uma cobertura média de nuvens entre 60 e 80% somente entre os meses de dezembro e fevereiro. Além disso, concluiu-se que o monitoramento de culturas a partir de dados de sensoriamento remoto passivo torna-se particularmente difícil durante o verão, principalmente sobre as culturas de soja e trigo.

### **2.3.1 Métodos de detecção de nuvens e sombras de nuvens**


Zhai *et al.* (2018) destacam que, em muitos casos, a busca por imagens livres de cobertura de nuvens pode ser bastante onerosa tanto do ponto de vista financeiro quanto do tempo e trabalho gastos, sendo fundamental a identificação precisa de nuvens e sombras de nuvens em imagens antes de qualquer processamento. Esse pode ser um procedimento desafiador dada a natureza imprevisível de sua distribuição espacial visto as diferentes formas, tamanhos e densidade que as nuvens podem se apresentar devido aos diversos fatores que influenciam durante sua formação (RODTS; DUYNKERKE; JONKER, 2003).

Do ponto de vista radiométrico, as nuvens podem apresentar comportamentos espectrais distintos de acordo com suas propriedades (PLATNICK *et al.*, 2003). Além disso, áreas cobertas por nuvens pouco espessas apresentam comportamento espectral pouco distinguível (ZHU; WOODCOCK, 2012).

Sombras de nuvens também possuem comportamento espectral semelhante a alvos escuros que podem ser encontrados na superfície terrestre como: sombra de relevo, água e pântanos (ZHU; WANG; WOODCOCK, 2015). A Figura 2.3 exemplifica alguns dos comportamentos de semelhança na resposta espectral de alguns alvos. Nas partes (a) e (b), destacam-se as sombras oriundas da projeção do relevo frente à incidência dos raios solares. Nas partes (c) e (d), é possível notar a resposta espectral de corpos de água. Enquanto nas partes (e)

e (f), são destacadas as sombras oriundas da projeção das nuvens sobre a superfície terrestre. Apesar de apresentarem respostas espectrais semelhantes (regiões escuras nas imagens), eles são oriundos de diferentes naturezas e devem ser diferenciados a fim de aprimorar as análises. Nas partes (g) e (h), é possível observar a influência de nuvens pouco espessas sobre a resposta espectral dos alvos terrestres. Nota-se que ainda é possível a distinção de alguns alvos (dependendo das bandas espectrais consideradas). O comportamento assemelha-se àquele sem a presença de nuvens tornando a sua detecção mais difícil.

Figura 2.3 - Exemplos de respostas espectrais similares em composições colorida verdadeira (R4G3B2) e falsa-cor (R6G5B4).



Fonte: Produção do autor.

A detecção das áreas com cobertura de nuvens é a primeira etapa para implementação de diversos estudos. Existem muitos métodos distintos que foram elaborados buscando a obtenção de uma máscara que apresentem boa acurácia e precisão (ROSSOW, 1989). Entretanto, escolher uma metodologia apropriada ainda se mostra uma tarefa difícil visto que não há um conjunto padrão de imagens para comparação, além das avaliações serem realizadas por inspeções visuais baseadas em uma composição de cor verdadeira das imagens (ZHU, 2017).

Ainda segundo Zhu (2017), os métodos podem ser classificados segundo seus algoritmos. Eles podem ser baseados em parâmetros e características físicas das nuvens e suas sombras ou em algoritmos de aprendizado de máquina (*machine learning*) que as identificam a partir de uma classificação supervisionada com base em amostras de treinamento coletadas previamente. Zhai *et al.* (2018) também classificam os métodos para detecção de nuvens baseados em cena única ou multicenas, isto é, quando a análise ocorre, respectivamente, a partir de uma única imagem ou de várias imagens. Os autores ainda afirmam que apesar do avanço de estudos recentes baseados em métodos multicena devido ao progresso do uso de séries, estes ainda se mostram metodologias menos populares por exigirem, no mínimo, duas imagens da mesma área livres de nuvens em um curto período temporal.

Desenvolvida em 1976, a transformação *Tasseled Cap* (TC) foi um dos métodos pioneiros para detecção de nuvens e neblinas. Entretanto, em muitos casos, falhava em obter bons resultados, pois os alvos não satisfaziam em sua totalidade as premissas teóricas básicas para sua aplicação (KAUTH; THOMAS, 1976; ZHAI *et al.*, 2018). Desde então, com o surgimento de novos sensores, os métodos foram sendo aperfeiçoados paralelamente à evolução tecnológica dos sensores. Mais recentemente, muitas metodologias baseadas em aprendizado de máquina estão sendo desenvolvidas mesmo que, ao contrário dos demais métodos, exijam maior desempenho computacional e tempo de processamento (ZHAI *et al.*, 2018; MAHAJAN; FATANIYA, 2020).



De outra forma, os métodos para detecção de sombras de nuvens podem ser divididos em 3 categorias. A primeira utiliza os parâmetros do imageamento, como ângulo solar azimutal e altitude, para o cálculo da projeção e direção de sombras. A segunda baseia-se na utilização de filtros para identificação de sombras de nuvens. E a terceira categoria combina métodos de análise espectral e geométrica. Apesar dos diferentes métodos existentes de detecção de sombras de nuvens, eles geralmente não obtêm grande precisão visto que não consideram a variabilidade do comportamento espectral das sombras e sua semelhança com pixels escuros (ZHAI *et al.*, 2018).

As novas abordagens visam uma análise conjunta para detecção de nuvens e suas sombras projetadas simultaneamente a partir do comportamento espectral e parâmetros de geometria espacial (oriundas do sensor ou da localização espacial das próprias nuvens). Esses métodos utilizam as características espectrais únicas das nuvens principalmente na banda cirrus, presente em alguns sensores como Landsat-8/OLI e Sentinel-2/MSI, e os parâmetros de geometria de visada e iluminação dos alvos para geração de uma máscara de nuvem e sombras.

Na Tabela 2.4 demonstra-se, resumidamente, algumas das abordagens explicadas anteriormente além de exemplificá-las com alguns trabalhos publicados na área de sensoriamento remoto. Entre eles, destaca-se o algoritmo *Function of Mask* (FMask) desenvolvido por Zhu e Woodcock (2012) por ser aplicável em grande parte das imagens da série Landsat-5 e a toda a série Sentinel-2.

Tabela 2.4 – Métodos de detecção de nuvens e sombras de nuvens em sensoriamento remoto.

Alvo Detectado	Parâmetros Analisados	Método	Referência
Nuvem	Cena única	<i>Tasseled Cap</i> (TC)	Kauth; Thomas (1976)
		<i>Haze Optimized Transformation</i> (HOT)	Zhang; Guindon; Cihlar (2002)
		<i>Markov Random Field</i>	Le Hégarat-Mascle; André (2009), Vivone <i>et al.</i> (2014)
		Redes Neurais	Hughes; Hayes (2014)
	Multicena	<i>Support Vector Machine</i>	Bai <i>et al.</i> (2016), Ishida <i>et al.</i> (2018)
Sombra de nuvem	Comportamento Espectral	<i>Multitemporal Cloud Masking in GEE</i>	Mateo-García <i>et al.</i> (2018)
	Comportamento Espectral	Filtragem	Richter; Müller (2005)
	Comportamento Espectral e Geometrias de Aquisição	Classificação por fatiamento	Simpson; Stitt (1998)
Nuvem e sombra de nuvem	Comportamento Espectral e Geometrias de Aquisição	<i>Decision Tree</i>	Li; Sun; Yu (2013)
		<i>Function of Mask</i> (FMask)	Zhu; Woodcock (2012)
		Índices Espectrais	Zhai <i>et al.</i> (2018)
	Comportamento Espectral e Textura	<i>Random Forest</i>	Ghasemian; Akhoondzadeh (2018)
	Comportamento Espectral	Redes Neurais	Chai <i>et al.</i> (2019)
		<i>Deep Learning</i>	Mateo-García <i>et al.</i> (2020)

Fonte: Produção do autor.

### 2.3.1.1 Algoritmo *Function of Mask* (FMask)

O método conhecido como FMask (*Function of Mask*) proposto por Zhu e Woodcock (2012) juntamente com seus aprimoramentos (ZHU; WANG; WOODCOCK, 2015; QIU *et al.*, 2017) é um dos mais utilizados na literatura. Proposto originalmente para aplicação em imagens oriundas dos sensores a bordo das plataformas Landsat 4-7. As nuvens são identificadas a partir da probabilidade do pixel ser uma nuvem e classificadas baseadas em um fatiamento dinâmico na cena analisada, enquanto a máscara de sombra de nuvens é gerada levando-se em conta a geometria de imageamento (ZHU, 2017).

Recentemente, Qiu *et al.* (2017) propuseram uma modificação no algoritmo ao integrá-lo com um Modelo Digital de Elevação (MDE) obtendo melhores resultados na detecção. Além disso, o Serviço Geológico Americano (*United States Geological Survey* – USGS) reprogramou o algoritmo em linguagem C e

desde 2016 é utilizado para fornecer uma camada que representa a qualidade da imagem (*Quality Assessment – QA*) para todos os produtos da coleção 1 do catálogo da série Landsat 4-8 (ZHU, 2017).

Zhai *et al.* (2018) destacam que entre as limitações do método estão a possível superestimação da cobertura de nuvens e a dependência de bandas na região do infravermelho termal do espectro eletromagnético ou na região do espectro dedicada para análise de cirrus. Ainda assim, o método é amplamente adotado em imagens Landsat e com aplicações em imagens Sentinel-2 mostrando bons resultados de precisão e acurácia (ZHU; WANG; WOODCOCK, 2015).

O produto gerado da aplicação do FMask é uma imagem classificada composta por pixels referentes a cobertura de nuvens, sombra de nuvens, cirrus, cobertura de neve e pixels livres. Por se tratar de um método probabilístico, as classes referentes às coberturas de nuvens e cirrus ainda dispõem de subclasses correspondentes ao nível de confiança da classificação (alto, médio ou baixo).

#### **2.4 Métodos de tratamento de valores faltantes em imagens de sensoriamento remoto**

Basicamente, existem duas abordagens ao se trabalhar com conjuntos de dados onde são identificados valores faltantes. A primeira prevê que os valores faltantes (dentro das máscaras) em uma série podem ser desconsiderados na análise. Na segunda abordagem, esses valores podem ser estimados por diversos métodos de interpolação existentes a partir dos valores adjacentes presentes na série (MITSA, 2010; GERBER *et al.*, 2018).

A desvantagem da primeira abordagem é a limitação do uso dos dados. Pois, durante a análise de séries temporais, os valores faltantes podem induzir a criação de feições com diferentes dimensionalidades e prolongam os intervalos entre imagens adjacentes produzindo intervalos irregulares resultando em menos dados para análise (ADDINK; STEIN, 1999; WU *et al.*, 2018).

A segunda abordagem prevê que os valores faltantes podem ser estimados a partir de métodos preditivos para obtenção de imagem sem cobertura de nuvens (VUOLO; NG; ATZBERGER, 2017). Essas metodologias para determinação de valores faltantes podem ser agrupadas em três classes distintas dependendo do

domínio sobre o qual é realizada a estimativa: espacial, temporal e espaço-temporal.

No domínio espacial, a estimativa é realizada baseada nos valores válidos próximos espacialmente em uma cena única. No domínio temporal o valor faltante é estimado baseado em sua variação temporal, ou seja, utilizando diversas cenas de uma mesma região sobrepostas. Enquanto no domínio espaço-temporal consiste numa análise conjunta simultânea dos domínios espacial e temporal.

Historicamente, os primeiros métodos abrangiam unicamente o domínio espacial para estimativa de valores faltantes e foram os pioneiros, sendo desenvolvidos por volta de 1984 para aplicação em pixels com erros sistemáticos em linhas e colunas inteiras (KRUG, 1992). Foi a partir da década de 90 que começaram a ser desenvolvidos métodos baseados em estatística espacial para estimativa de valores faltantes (KRUG, 1992; ROSSI; DUNGAN; BECK, 1994; ADDINK; STEIN, 1999).

As metodologias que trabalham no domínio espacial, também conhecidas como restauração, reconstróem uma região com valores faltantes na imagem baseadas na extensão de características extraídas da distribuição espacial de uma região livre de ruídos ao se considerar a auto correlação entre pixels adjacentes. Usualmente apresentam resultados satisfatórios para áreas pequenas e homogêneas com valores faltantes (LIN *et al.*, 2013; WU *et al.*, 2018).

Paralelamente, com o aumento da disponibilidade de dados oriundos de sensoriamento remoto, houve o surgimento de métodos baseados na análise de séries temporais, ou seja, no domínio temporal. As metodologias baseadas nesse domínio, também denominadas de métodos de mosaico ou multitemporais, exploram a correlação temporal entre os dados para estimativa dos valores faltantes. Para tanto, considera-se que imagens da mesma região tomadas em tempos diferentes não são simultaneamente cobertas por nuvens ou sombras e, portanto, podem ser utilizadas para estimativas nas regiões

cobertas e gerando assim uma imagem sintética livre de nuvens e sombras (WU *et al.*, 2018).

Um dos métodos temporais mais utilizado e simples é a interpolação linear entre pixels adjacentes temporalmente. Neste caso, o valor faltante de um pixel é substituído por um valor interpolado a partir de valores de pixels adjacentes mais próximos e livres de nuvem em uma série temporal (QUARMBY, 1992). Porém, com a evolução da capacidade de processamento dos computadores, diversos métodos foram desenvolvidos utilizando não somente funções lineares como redes neurais, funções polinomiais, gaussiana e logística, entre outras (JÖNSSON; EKLUNDH, 2004; NETELER, 2010; VERGER; BARET; WEISS, 2014).

Nesse contexto, os estudos mais recentes focam no desenvolvimento de metodologias que, a partir de máscaras, atuem no campo espacial e temporal simultaneamente visando a obtenção das vantagens de ambos os domínios. Oliveira e Epiphanyo (2012) propuseram, em seu trabalho, um método capaz de estimar valores de índice de vegetação NDVI para pixels considerados de baixa qualidade, ou seja, aqueles com valores afetados pela cobertura de nuvens. O método consiste em uma regressão linear pixel-a-pixel considerando os valores dos pixels vizinhos e seus valores em imagens tomadas em outros instantes do tempo.

Na Tabela 2.5 é apresentada uma síntese de alguns métodos de reconstrução de valores faltantes aplicados em imagens de sensoriamento remoto que podem ser encontrados na literatura. Nota-se que há diversas metodologias para reconstrução de áreas com valores faltantes, entretanto, atualmente, os métodos são dedicados para tratamento diretamente de valores radiométricos ou índices calculados a partir dos mesmos, como *Normalized Difference Vegetation Index* (NDVI), *Enhanced Vegetation Index* (EVI), *Soil-Adjusted Vegetation Index* (SAVI), entre outros. A escolha do método mais adequado varia com o tipo de dado utilizado, o sensor a partir do qual foi obtido e quantidade de dados disponíveis. Metodologias como Janela de Regressão e *Time-Series Generator*

for MODIS data (TiSeG), por exemplo, foram desenvolvidas para aplicação em produtos MODIS (COLDITZ *et al.*, 2008; OLIVEIRA; EPIPHANIO, 2012).

Independentemente do contexto considerado, grande parte dos métodos de recuperação de valores faltantes apresentam desvantagens que afetam diretamente suas aplicações (ECKARDT *et al.*, 2013). Gerber *et al.* (2018) destacam que entre os problemas mais comuns que podem ser encontrados nos métodos de reconstrução de valores faltantes estão:

- Falha parcial na estimativa de valores, principalmente quando os valores faltantes se encontram entre longos períodos de ausência de dados;
- Inexistência de quantificação de incertezas;
- Indisponibilidade de algoritmos em código aberto bem documentados, para promover o uso e desenvolvimento do método;
- Falta de escalabilidade para conjuntos grandes compostos por grande quantidade de dados;
- Baixa velocidade de processamento por exigir amplo armazenamento computacional.

Outro ponto importante é que métodos baseados na substituição de valores por composições de imagens sintéticas partem da premissa básica que não há variabilidade espaço-temporal significativa entre as imagens utilizadas para a reconstrução dos valores faltantes (SOLBERG; JAIN; TAXT, 1994; TSENG; TSENG; CHIEN, 2008). Enquanto métodos baseados em técnicas de interpolação normalmente tem aplicação limitada pelo tipo do sensor, da cobertura terrestre e além do tipo de nuvem (MELGANI, 2006).

Assim, nota-se que valores faltantes se mostram um problema antigo em trabalhos na área de sensoriamento remoto, e diversos métodos estão sendo estudados e desenvolvidos para lidar com tal questão. Particularmente em se tratando de métodos de reconstrução de valores faltantes a partir de imagens classificadas, uma área de estudo relativamente nova. Dado o exposto, no presente trabalho, são propostos dois novos métodos para tratamento de valores faltante a partir de imagens classificadas.

Tabela 2.5 – Exemplos de métodos de reconstrução de valores faltantes em dados de sensoriamento remoto.

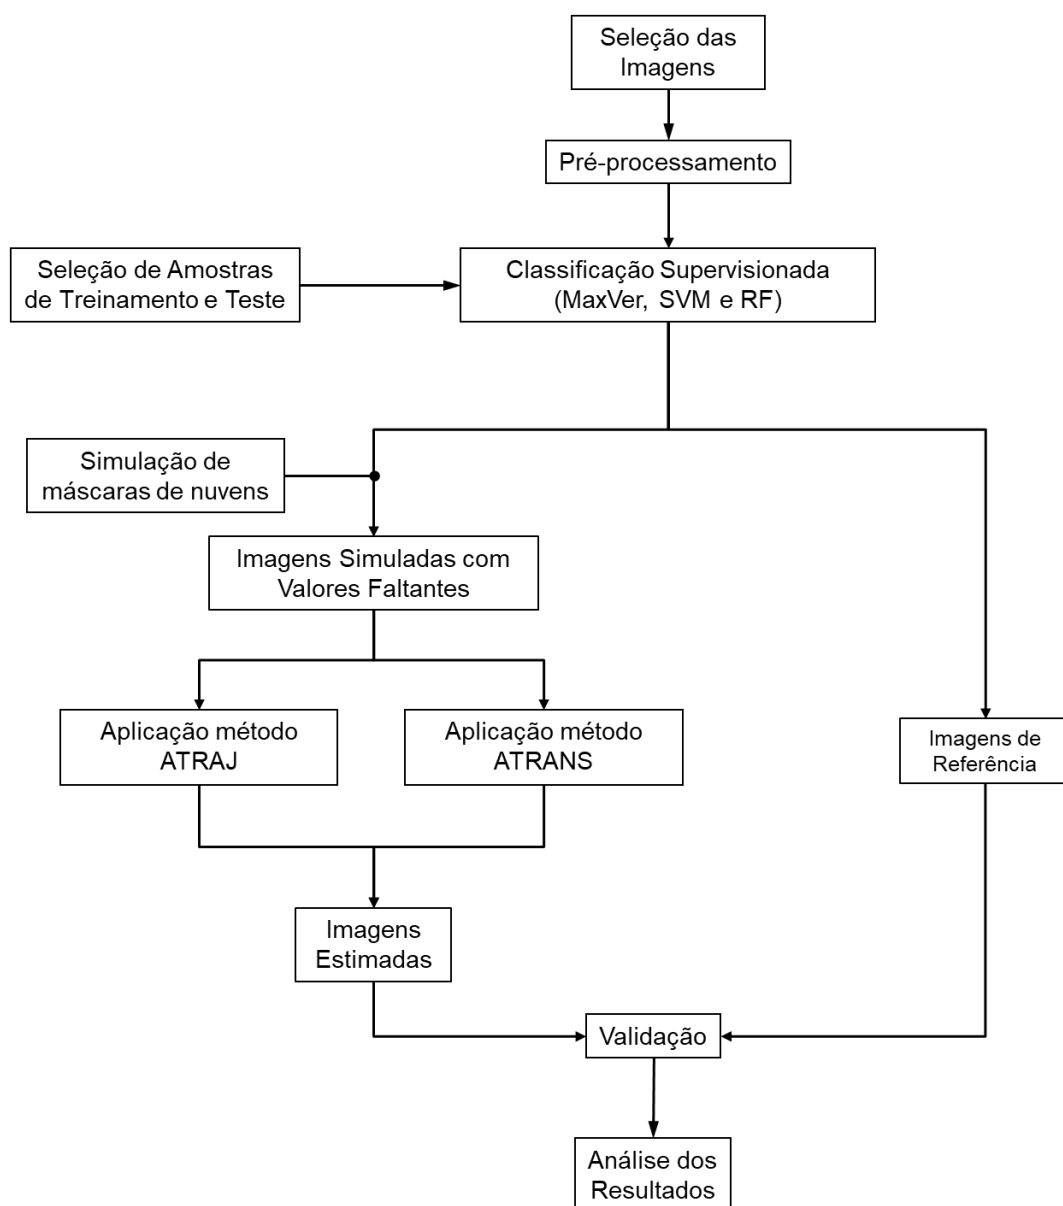
<b>Tipo</b>	<b>Método</b>	<b>Referência</b>
Espacial	Modelos de variogramas espaciais (Co-Krigagem)	Rossi; Dungan; Beck (1994); Addink; Stein (1999)
	<i>Geostatistical Neighborhood Similar Pixel Interpolator</i> (GNSPI)	Chen <i>et al.</i> (2011), Zhu; Liu; Chen (2012)
	<i>Harmonic Analysis of Time-Series</i> (HANTS)	Roerink; Menenti; Verhoef (2000)
Temporal	Funções Savitzky-Golay, gaussiana assimétrica e logística dupla (TIMESAT)	Jönsson; Eklundh (2004)
	Modelos lineares e <i>spline</i> combinados com análise de Fourier	Scharlemann <i>et al.</i> (2008)
	<i>Time-Series Generator for MODIS data</i> (TiSeG)	Colditz <i>et al.</i> (2008)
	<i>Breaks For Additive Season and Trend</i> (BFAST)	Verbesselt <i>et al.</i> (2010a, 2010b)
	Modelos <i>spline</i> com elevação	Neteler (2010)
	<i>Consistent Adjustment of Climatology to Actual Observations</i> (CACAO)	Verger <i>et al.</i> (2013)
	Redes neurais combinadas com funções Savitzky-Golay	Verger; Baret; Weiss (2014)
	<i>Locally wEighted Scatterplot Smoothing</i> (LOESS)	Moreno <i>et al.</i> (2014)
	<i>Detecting Breakpoints and Estimating Segments in Trend</i> (DBEST)	Jamali <i>et al.</i> (2015)
	<i>Empirical Orthogonal Functions</i> (EOF)	Beckers <i>et al.</i> (2003)
	<i>Singular Spectrum Analysis</i> (SSA)	Golyandina; Osipov (2007), Buttlar; Zscheischler; Mahecha (2014)
Espaço-Temporal	<i>Generalized Additive Model and kriging</i> (GAM and kriging)	Poggio; Gimona; Brown (2012)
	Janela de regressão	Oliveira; Epiphonio (2012), Oliveira; Epiphonio; Rennó (2014)
	Método de previsão usado no <i>Malaria Atlas Project</i> (gapfill-MAP)	Weiss <i>et al.</i> (2014)
	Versão Monte Carlo do filtro de Kalman	Lguensat <i>et al.</i> (2014)
	Modelos de variograma espaço-temporais	Zeng <i>et al.</i> (2014), Guo <i>et al.</i> (2015)
Regressões de quantis adaptadas para parâmetros espaço-temporais (gapfill)	Gerber <i>et al.</i> (2018)	

Fonte: Adaptado de Gerber *et al.* (2018).

### 3 MATERIAL E MÉTODOS

Neste capítulo, são apresentados os dados utilizados na estimativa de classes faltantes, bem como a região onde dois estudos de casos foram realizados. Além disso, descrevem-se também as etapas executadas no pré-processamento dos dados. Na Figura 3.1 é esquematizado um fluxograma com as etapas da metodologia adotada aplicação e validação das técnicas propostas e serão detalhadas nas próximas seções.

Figura 3.1 - Metodologia adotada no trabalho.



Fonte: Produção do autor.



### 3.1 Área de Estudo

A região de estudo representa uma porção da Floresta Amazônica, um ambiente dinâmico e alvo de diversos estudos por apresentar uma rica biodiversidade fundamental para funcionamento da biosfera (FOLEY *et al.*, 2007). Esse bioma sofre alterações devido à ação antropogênica e, segundo o Projeto de Monitoramento do Desmatamento na Amazônia Legal (PRODES), a taxa anual de desmatamento para o ano de 2018 foi de 7.536 km<sup>2</sup>/ano, apresentando um aumento de 8% quando comparada com o ano anterior<sup>1</sup>. Essa expansão do desmatamento provoca uma mudança na cobertura da terra, gerando impactos que variam desde a emissão de gases do efeito estufa até alteração do ciclo da água local ou a perda da biodiversidade (FEARNSIDE, 2008).

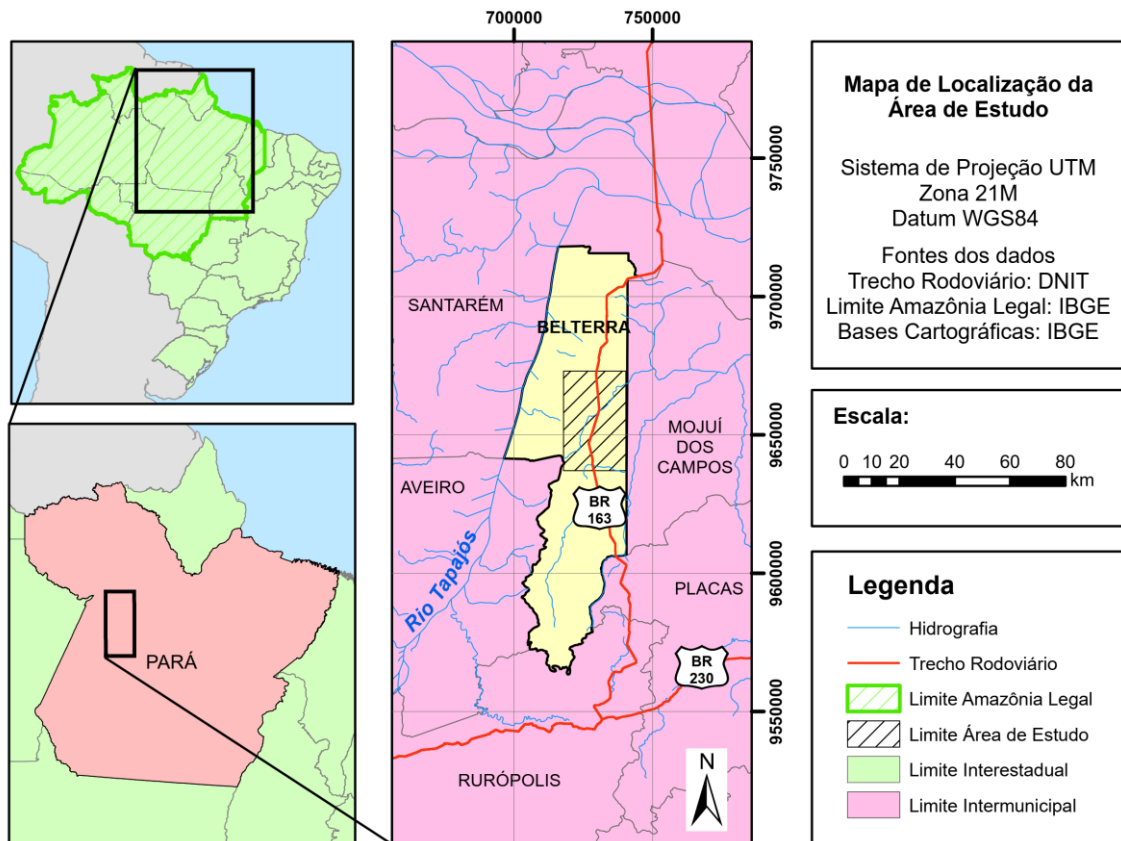
A região de estudo compreende uma área localizada no município de Belterra, estado do Pará, localizado na região norte do Brasil. A área abrange uma porção que contempla a influência da rodovia Cuiabá- Santarém (BR-163) além de parte de uma unidade de conservação de nível federal (Floresta de Tapajós – FLONA). A localização da área de estudo além dos limites utilizados nos estudos de caso são ilustrados na Figura 3.2.

De acordo com a classificação de Köppen, o clima da região é tipo Am, que apresenta estações secas de curta duração e período chuvoso com elevada precipitação. De acordo com o projeto RADAMBRASIL, o solo é predominantemente argiloso do tipo Latossolo Amarelo Distrófico e a vegetação é composta por floresta ombrófila densa, vegetação secundária e pastagens (IBGE, 1976).

---

<sup>1</sup> A taxa divulgada para o ano PRODES (ano-calendário do desmatamento) de 2018 refere-se ao período de 01 de agosto de 2017 a 31 de julho de 2018 (SOUZA *et al.*, 2019).

Figura 3.2 - Mapa de localização da área de estudo.



Fonte: Produção do autor.

Especificamente na região de estudo, a ocupação começou na década de 1970, quando o governo brasileiro incentivou o desenvolvimento regional e maior integração da região Norte focando em planos para infraestrutura como a construção das rodovias Transamazônica (BR - 230) e Cuiabá-Santarém (BR - 163) (IBAMA, 2004). Fearnside (2007) afirma que a pavimentação da rodovia BR-163, presente na região de estudo, em 1976 tinha como objetivo principal se tornar um eixo de transporte de produtos agrícolas entre Cuiabá (MT) e Santarém (PA), entretanto levou a uma expansão de estradas vicinais promovendo a ocupação da área e, conseqüentemente, o desmatamento da vegetação nativa.

Essa ocupação se estabeleceu em áreas próximas às redes rodoviárias principalmente através da agricultura familiar responsável pela prática de cultivos de ciclo curto com épocas dedicadas a queima e pousio entre eles que, após alguns anos, são convertidos em pastagem (ROZON *et al.*, 2015).

Escada *et al.* (2009) destacam que na região as alterações da paisagem ocorrem devido à agricultura, representada principalmente pelo cultivo de soja no planalto, a pecuária e atividades de extração de madeira e minério.

Outro fator importante para o equilíbrio ecológico da região é a sua suscetibilidade a incêndios, que por apresentar elevado número de ações antrópicas principalmente devido ao avanço das atividades de agropecuária de larga escala e suas práticas como corte e queima. Esses processos resultam em mudanças no uso e cobertura do solo com consequências microclimáticas na região diminuindo a evapotranspiração, aumentando a temperatura e prolongando, assim, o período de estiagem favorecendo os incêndios florestais e, portanto, influenciando diretamente no manejo da cobertura da terra (RIBEIRO; BAPTISTA, 2015).

### **3.2 Base de dados**

Para desenvolvimento do estudo foram utilizadas imagens oriundas do sensor *MultiSpectral Instrument* (MSI) a bordo dos satélites Sentinel-2A e Sentinel-2B que compõem o primeiro estudo de caso. Enquanto as imagens oriundas do sensor *Thematic Mapper* (TM) a bordo do satélite Landsat-5 e compõem o segundo estudo de caso.

#### **3.2.1 Imagens Sentinel-2/MSI**

O estudo de caso composto pelas imagens Sentinel-2/MSI tem por objetivo verificar a capacidade dos métodos propostos em estimar as classes de uso e cobertura da terra. As imagens compõem um estudo de caso com alta resolução espacial e com pequeno intervalo de tempo entre elas.

O critério de seleção das imagens Sentinel-2 foi a maior proximidade com a data da coleta dos dados de campo disponível de trabalhos previamente realizados na região, além da menor ocorrência de cobertura de nuvens e sombras a fim de possibilitar a simulação. Foram selecionadas 3 imagens para aplicação das metodologias propostas: uma oriunda do satélite Sentinel-2B datada de 11 de julho de 2017 e duas do satélite Sentinel-2A datadas de 16 de julho de 2017 e 26 de julho de 2017. Elas apresentam uma frequência temporal diária e não

regular a fim de analisar o comportamento dos métodos propostos sob condições de pequena variação temporal.

Todas têm como referência a localização 21MYS da grade MGRS do Sentinel. As imagens correspondem ao nível de processamento 1C (*Level-1C*), ou seja, os números digitas representam valores de reflectância do topo da atmosfera (*Top-of-Atmosphere*). As imagens selecionadas são ilustradas na Figura 3.3. Considerando a região de estudo analisada, o recorte retangular apresenta dimensão de 3601 pixels em linha e 2251 pixels em coluna. Um resumo das características das imagens utilizadas é apresentado na Tabela 3.1.

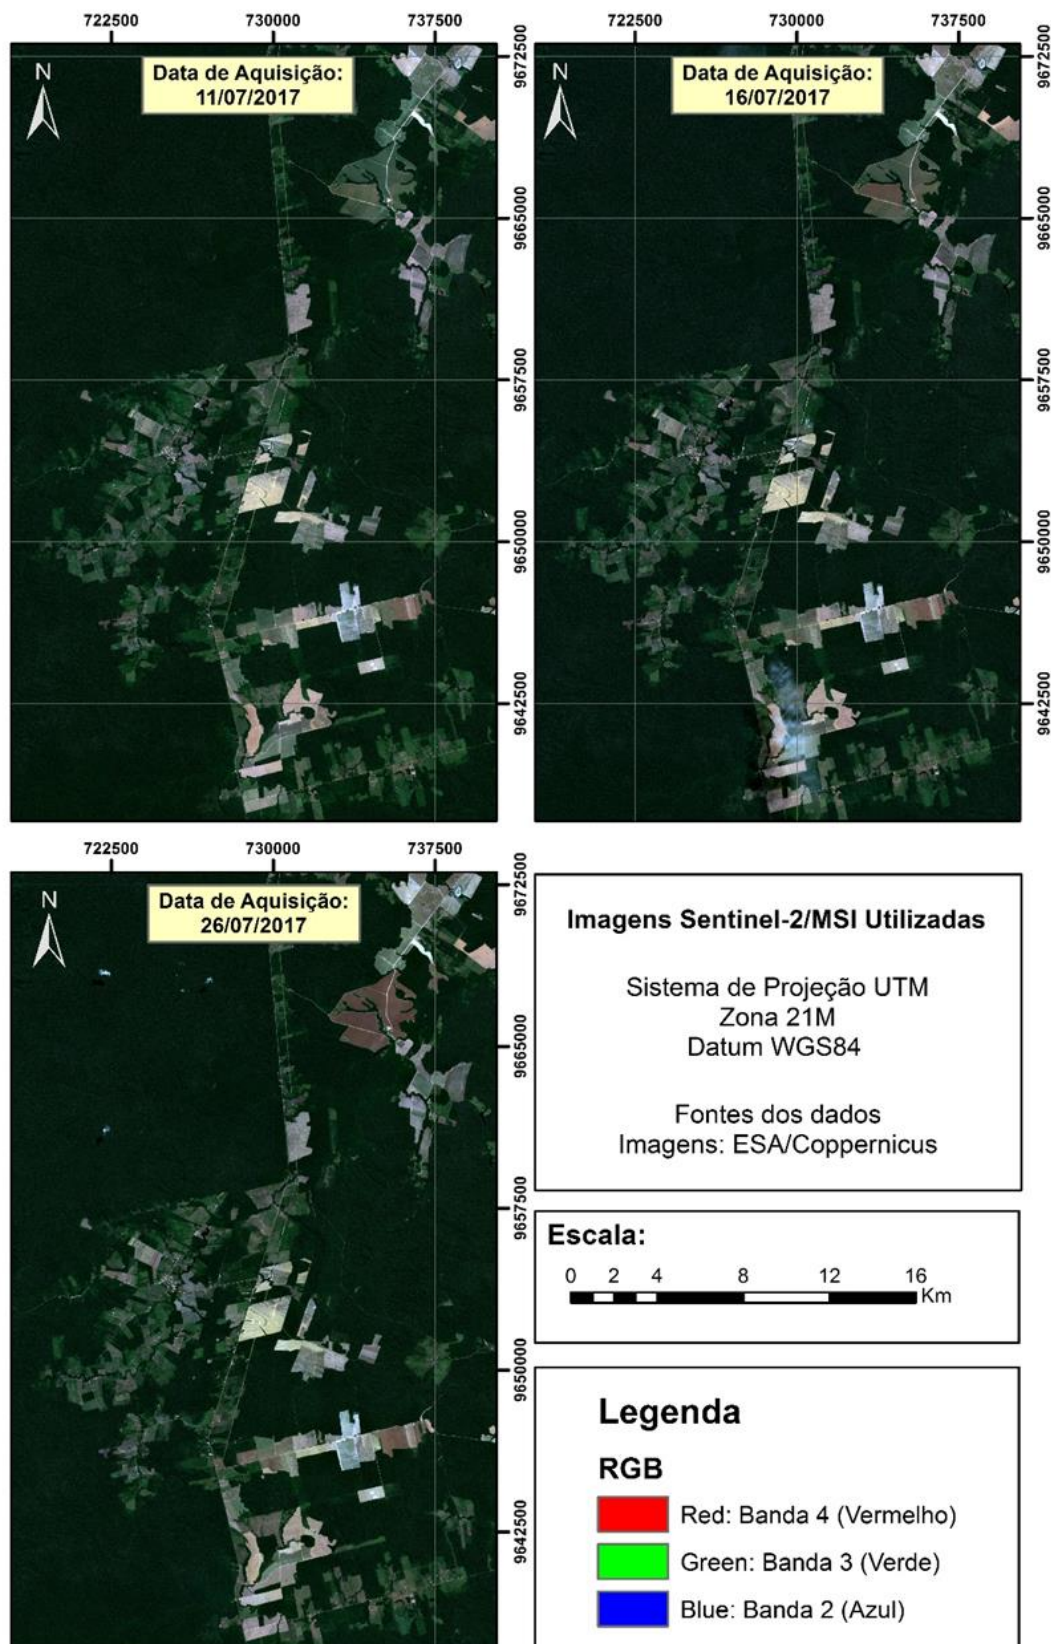
Os produtos Sentinel-2/MSI possuem correções radiométrica e geométrica de sistema. Eles são disponibilizados gratuitamente pela plataforma Scihub da Copernicus, responsável pelo desenvolvimento e manutenção do sistema Sentinel.

Tabela 3.1 – Descrição das imagens Sentinel-2-MSI utilizadas.

	Sentinel-2A/MSI	Sentinel-2B/MSI
	Características	
Data de aquisição	16 jul 2017; 26 jul 2017	11 jul 2017
Bandas selecionadas	2, 3, 4, 8, 11 e 12	
Tamanho da imagem (pixels)	2251 x 3601	
Nível de processamento	<i>Level 1-C</i>	
Resolução espacial	10 metros (20 metros para bandas 11 e 12)	

Fonte: Produção do autor.

Figura 3.3 - Imagens Sentinel-2/MSI selecionadas.



Fonte: Produção do autor.

### 3.2.2 Imagem Landsat-5/TM

O estudo de caso composto pelas imagens Landsat-5/TM tem por objetivo verificar a capacidade dos métodos propostos em estimar as classes de uso e cobertura da terra. As imagens compõem um estudo de caso com resolução espacial média e com intervalo de tempo anual entre elas.

As imagens selecionadas para classificação e aplicação dos métodos propostos equivalem as imagens utilizadas no trabalho de Reis *et. al.* (2020b). Dentre as imagens utilizadas pelos autores, foram escolhidas aquelas pertencentes ao mesmo sensor e que, simultaneamente, apresentassem as mesmas classes na região de estudo.

Dessa maneira, as imagens Landsat-5/TM datam de 21 de junho de 2007, 23 de junho de 2008 e 28 de junho de 2010 referentes a órbita/ponto 227/062 e obtidas do catálogo de imagens disponibilizado pela USGS através do portal online *Earth Explorer*. Elas apresentam uma frequência temporal anual e não regular a fim de analisar o comportamento dos métodos propostos sob condições de maior variação temporal. Mais detalhes sobre os critérios de seleção das imagens e bandas para gerar as classes de uso e cobertura da terra podem ser encontrados em Reis *et. al.* (2020b). Considerando a região de estudo analisada, o recorte retangular apresenta dimensão de 1200 pixels em linha e 750 pixels em coluna. As imagens Landsat-5/TM selecionadas são ilustradas na Figura 3.4. Um resumo das características das imagens utilizadas é apresentado na Tabela 3.2.

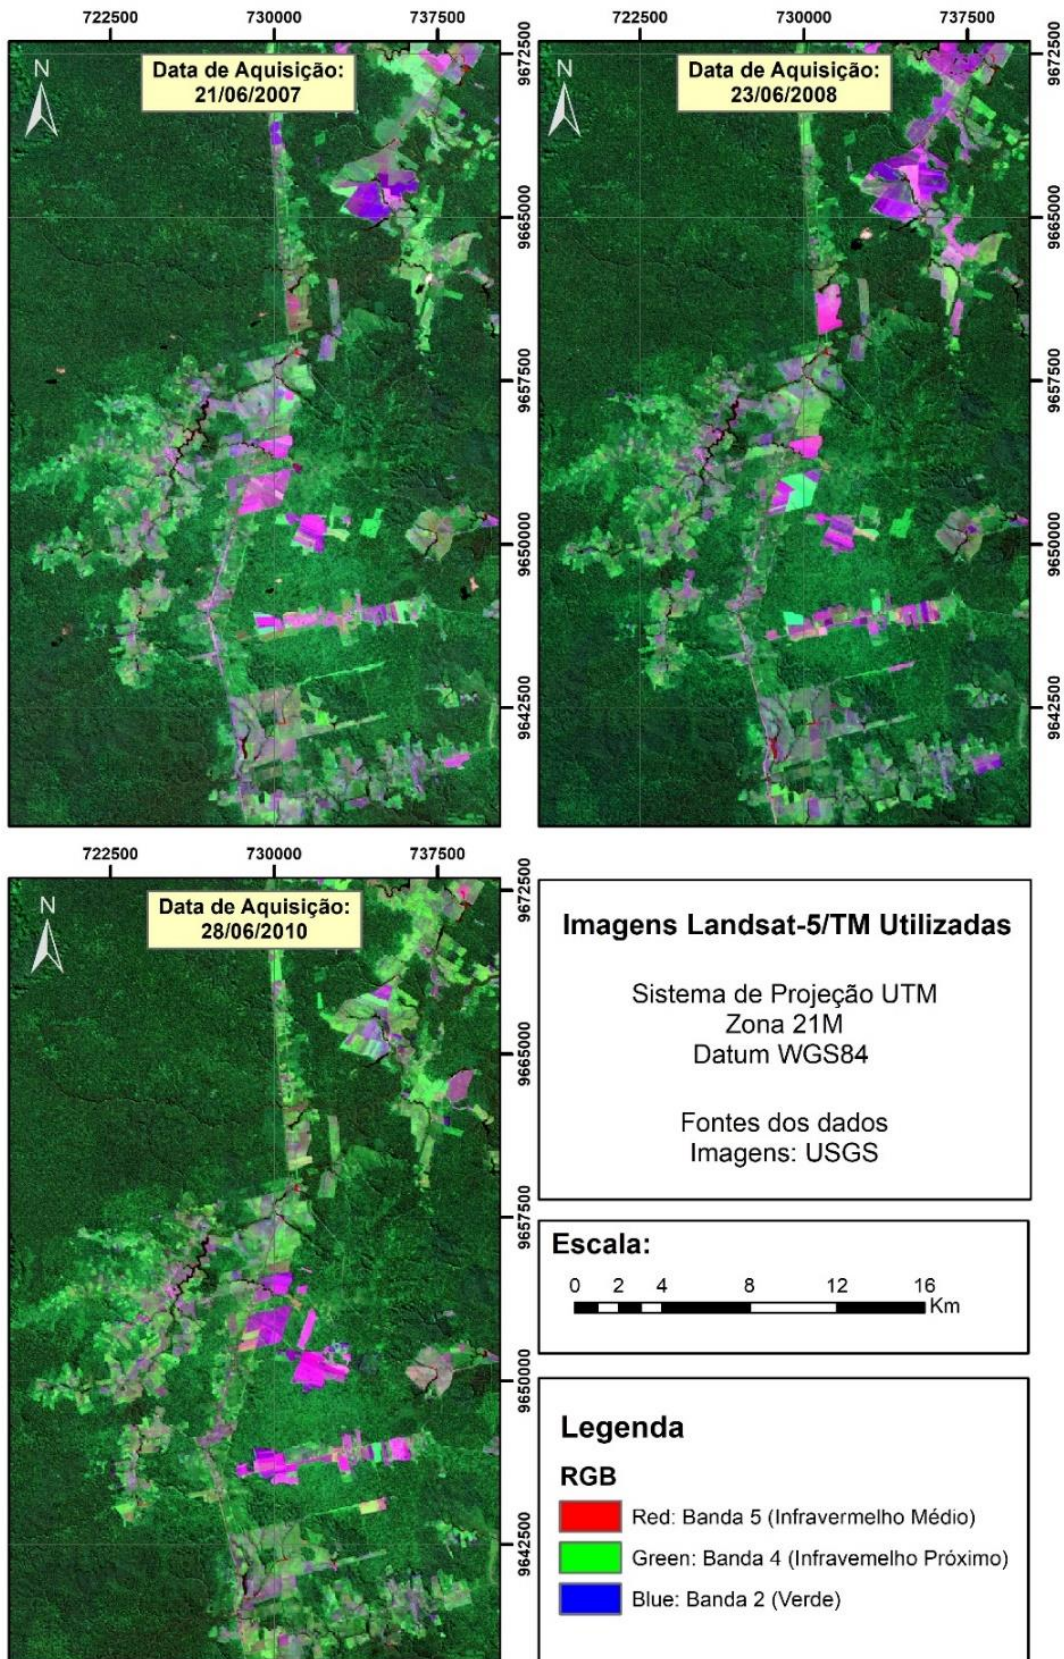
As imagens correspondem ao nível 2 de processamento (*Level-2*), ou seja, os números digitas representam valores de reflectância superfície (*Bottom-of-Atmosphere*) com correção atmosférica. Mais detalhes sobre a correção atmosférica aplicada podem ser encontrados em USGS (2019). Além disso, esse produto também já apresenta correção geométrica e radiométrica de sistema.

Tabela 3.2 – Descrição das imagens Landsat-5/TM utilizadas.

Landsat-5/TM	
Características	
Data de aquisição	21 jun 2007; 23 jun 2008; 28 jun 2010
Bandas selecionadas	2, 4 e 5
Tamanho da imagem (pixels)	750 x 1200
Nível de processamento	<i>Level-2</i>
Resolução espacial	30 metros

Fonte: Produção do autor.

Figura 3.4 - Imagens Landsat-5/TM selecionadas.



Fonte: Produção do autor.



### 3.3 Pré-processamento

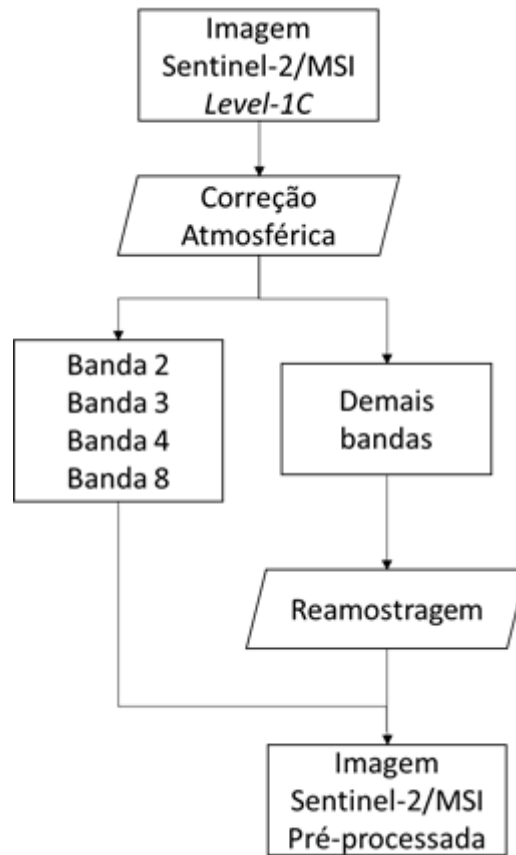
A normalização dos dados durante a etapa de pré-processamento em uma análise temporal é importante por permitir que eles se encontrem em uma mesma escala possibilitando, assim, comparações entre os dados (MITSA, 2010). Dessa forma, com a finalidade de garantir a confiabilidade radiométrica entre as imagens analisadas, os valores de ND (número digital) são convertidos para reflectância considerando as condições de geração das imagens e características específicas de cada sensor permitindo a caracterização espectral dos objetos (PONZONI; SHIMABUKURO; KUPLICH, 2010).

Assim, foi realizada a correção atmosférica para reduzir possíveis ruídos no sinal causados pela interferência dos componentes das camadas atmosféricas. Isto visa garantir a comparabilidade entre dados de diferentes sensores com datas de aquisição distintas (SONG *et al.* 2001). Visto que as imagens Landsat-5/TM já foram obtidas com correção atmosférica, a etapa de pré-processamento descrita nesta seção foi aplicada somente às imagens Sentinel-2/MSI.

O resultado desse processo são imagens com valores equivalentes à reflectância de superfície. Neste caso, foi adotado o algoritmo *Sen2Cor* versão 2.8.0 disponível no *software* SNAP versão 7.0.0 para correção atmosférica das imagens utilizadas no primeiro estudo de caso.

Posteriormente, utilizando o mesmo *software*, foi aplicado um procedimento de reamostragem nas imagens referentes a bandas com resolução diferente de 10 metros a fim de manter característica e propriedades originais dos valores dos pixels. Dessa forma, todas as bandas têm seu tamanho de pixel homogeneizado permitindo o empilhamento das bandas 2, 3, 4, 8, 11 e 12, que foram utilizadas posteriormente para classificação por atuarem em faixas que facilitam a distinção de classes de uso e cobertura da terra. Um fluxograma resumindo as etapas de pré-processamento adotadas nas imagens Sentinel-2/MSI é ilustrado na Figura 3.5.

Figura 3.5 – Pré-processamento aplicado às imagens Sentinel-2.



Fonte: Produção do autor.

### 3.4 Classificação

Foram selecionados três métodos distintos de classificação, sendo eles: Máxima Verossimilhança (MAXVER), *Support Vector Machine* (SVM) e *Random Forest* (RF). Os métodos foram selecionados por apresentarem alta relevância em estudos de classificação de uso e cobertura da terra, além de serem amplamente aplicados em trabalhos na área de sensoriamento remoto. Os produtos obtidos dessas classificações compõem as imagens de referência para avaliação da efetividade dos métodos propostos nesse trabalho.

Por se tratar de métodos de classificação supervisionados, eles requerem como parâmetro de entrada amostras de treinamento. A coleta de amostras rotuladas de classes de uso e cobertura da terra distintas para classificação das imagens Sentinel-2/MSI baseou-se em dados de campo coletados sobre a área de estudo

entre 13 e 20 de setembro de 2017, imagens da série histórica do programa Landsat e Sentinel, e na série histórica de classificação obtida do projeto TerraClass (ALMEIDA *et. al.*, 2016). A definição das classes de uso e cobertura da terra são baseadas em outros trabalhos executados na mesma região de estudo (BRAGA *et. al.*, 2015; PEREIRA *et. al.*, 2016; REIS, *et. al.*, 2017; REIS *et. al.*, 2020b). A descrição detalhada de cada classe, bem como as chaves de interpretação para identificação de cada uma nas imagens Sentinel-2/MSI podem ser encontradas no Apêndice B e são descritas, sucintamente, como:

- Área de Cultivo (AC): áreas agrícolas dedicadas ao cultivo de culturas anuais;
- Área em Pousio (AP): áreas agrícolas em pousio, caracterizada pela presença de palha ou vegetação esparsa;
- Corpos D'água (CA): regiões que representam corpos hídricos como rios, córregos, lagos, lagoas, represas, entre outros;
- Formação Florestal (FL): áreas compostas por vegetação densa representadas por vegetações arbóreas de médio e grande porte como florestas primária, degradada e em regeneração em estágio intermediário e avançado;
- Pasto Limpo (PL): classe caracterizada por vegetações gramíneas típicas de pastagens com predominância de herbáceas;
- Pasto Sujo (PS): caracterizado por vegetações gramíneas típicas de pastagens com presença de espécies arbustivas e invasoras;
- Solo Exposto (SE): áreas compostas predominantemente por solo exposto.

As amostras foram, então, divididas aleatoriamente em dois conjuntos para treinamento dos classificadores (treino) e posterior avaliação das classificações (teste). Devido à alta correlação espacial dos dados Sentinel-2/MSI por sua alta resolução espacial, e visando a otimização computacional do processo de classificação, foram sorteados 10% dos pixels de cada classe aleatoriamente

para compor os conjuntos de treinamento e teste evitando a redundância de dados. Assim, a quantidade de pixels sorteados para as amostras de treinamento e teste de cada classe de uso e cobertura da terra referente às imagens Sentinel-2/MSI é descrita na Tabela 3.3.

O conjunto de dados referente às amostras utilizadas na classificação das imagens LANDSAT-5/TM foi o mesmo adotado por Reis *et al.* (2020a). Com a finalidade de diminuir os ruídos de classificação (efeito *salt-pepper*) e, simultaneamente, manter uma distinção de classes que favoreça estudos de mudanças de uso e cobertura da terra na região, os dados foram reagrupados em cinco classes segundo o dendrograma baseado na separabilidade espectral das classes (*Single Minimum Link Dendrogram* - SMLD) e descrito em Reis *et al.* (2018) .

Assim, as classes adotadas para classificação das imagens LANDSAT-5/TM são descritas por: Agricultura (AC), Solo Exposto (SE), Formação Florestal (FL), Vegetação Secundária em Estágio Inicial (VI) e Pasto (PA). Mais detalhes sobre os critérios de seleção e definição das classes podem ser encontrados em Reis *et al.* (2018). A localização das amostras coletadas ao longo das imagens Sentinel-2/MSI e LANDSAT-5/TM são ilustradas, respectivamente, na Figura 3.6 e Figura 3.7. Na Tabela 3.4, são mostrados o número de polígonos e o respectivo número de pixels das amostras de treinamento e das amostras de teste de cada classe de interesse referente às imagens LANDSAT-5/TM.

O *software* ENMap-Box foi utilizado tanto para a definição das árvores de decisão pelo método RF, quanto para busca dos valores de (C) e (g) pelo método SVM. Para tanto, adotou-se a mesma metodologia e parâmetros aplicados por Sothe *et al.* (2017). Os parâmetros (C) e (g) selecionados para classificação das imagens pelo método SVM estão expostos na Tabela 3.5. As matrizes de confusão, seus respectivos índices de avaliação da classificação, além das imagens classificadas utilizadas como referência podem ser encontrados no Apêndice C.

Foram selecionadas imagens com a menor quantidade possível de nuvens sobre a área de estudo em ambos os estudos de caso. Com a finalidade de não afetar

o levantamento necessário de cada técnica bem como a simulação de valores faltantes, foi gerado uma máscara de nuvens e sombras para cada série utilizada. Cada pixel que em alguma imagem da série apresentasse nuvem ou sombra de nuvem foi desconsiderado das análises. Essa máscara foi gerada manualmente através de interpretação visual.

Tabela 3.3 - Especificações das amostras nas imagens Sentinel-2/MSI.

Classe	Símbolo	Número de Amostras					
		#Pixels					
		11 julho 2017		16 julho 2017		26 julho 2017	
		Treinamento	Teste	Treinamento	Teste	Treinamento	Teste
Formação Florestal	FL	15224	4980	14571	4635	15894	4980
Área de Cultivo	AC	1713	451	400	243	418	211
Pasto Sujo	PS	1427	745	981	522	886	422
Pasto Limpo	PL	1443	653	1472	747	1920	924
Área em Pousio	AP	752	289	1225	529	1680	868
Solo Exposto	SE	1072	413	473	148	440	411
Corpo D'água	CA	219	83	169	113	113	35

Fonte: Produção do autor.

Tabela 3.4 - Especificações das amostras nas imagens Landsat-5/TM.

Classe	Símbolo	Número de Amostras					
		#Pixels					
		2007		2008		2010	
		Treinamento	Teste	Treinamento	Teste	Treinamento	Teste
Formação Florestal	FL	8373	2970	8264	2946	11230	5643
Vegetação Secundária em Estágio Inicial	VI	336	134	147	129	464	191
Área de Cultivo	AC	450	194	1194	539	820	323
Pastagem	PA	1529	876	815	329	1541	1284
Solo Exposto	SE	2405	1327	2454	1363	4032	2944

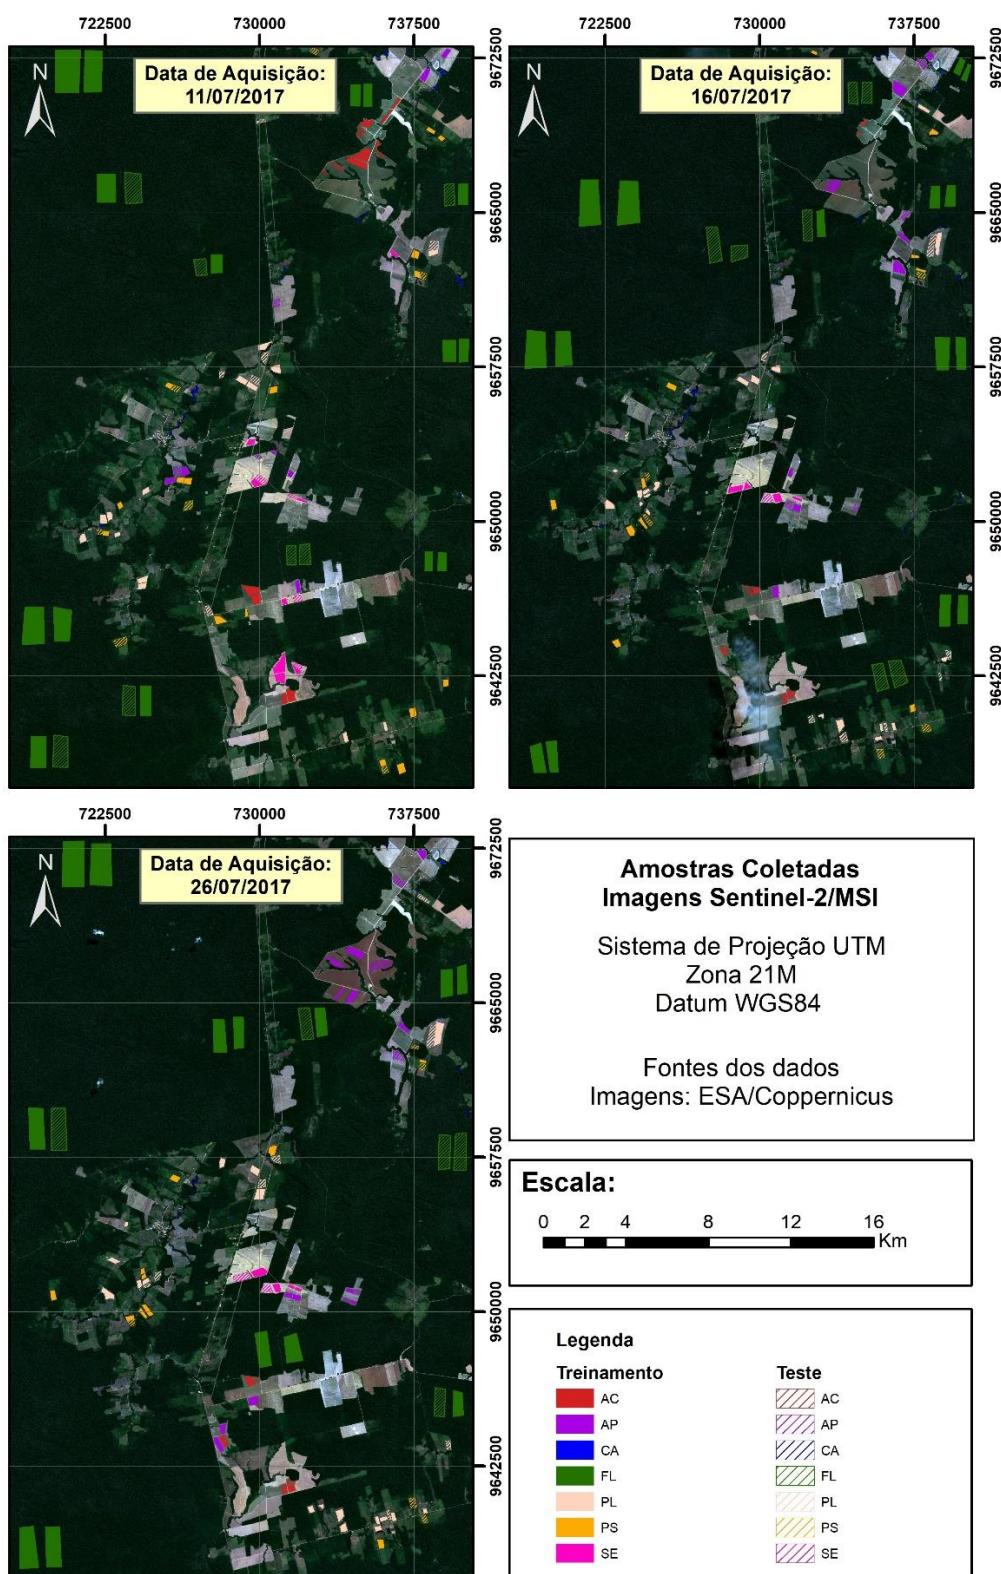
Fonte: Produção do autor.

Tabela 3.5 - Valores seleccionados de *Cost* (C) e *gamma* (g) para classificação das imagens pelo método SVM.

Imagem		Parâmetros SVM-RBF	
Plataforma/ Sensor	Data de Aquisição	Cost (C)	Gamma (g)
Sentinel-2/MSI	11 julho 2017	100	1
	16 julho 2017	100	1
	26 julho 2017	10	1
Landsat-5/TM	21 junho 2007	10	10
	23 junho 2008	100	10
	29 junho 2010	10	10

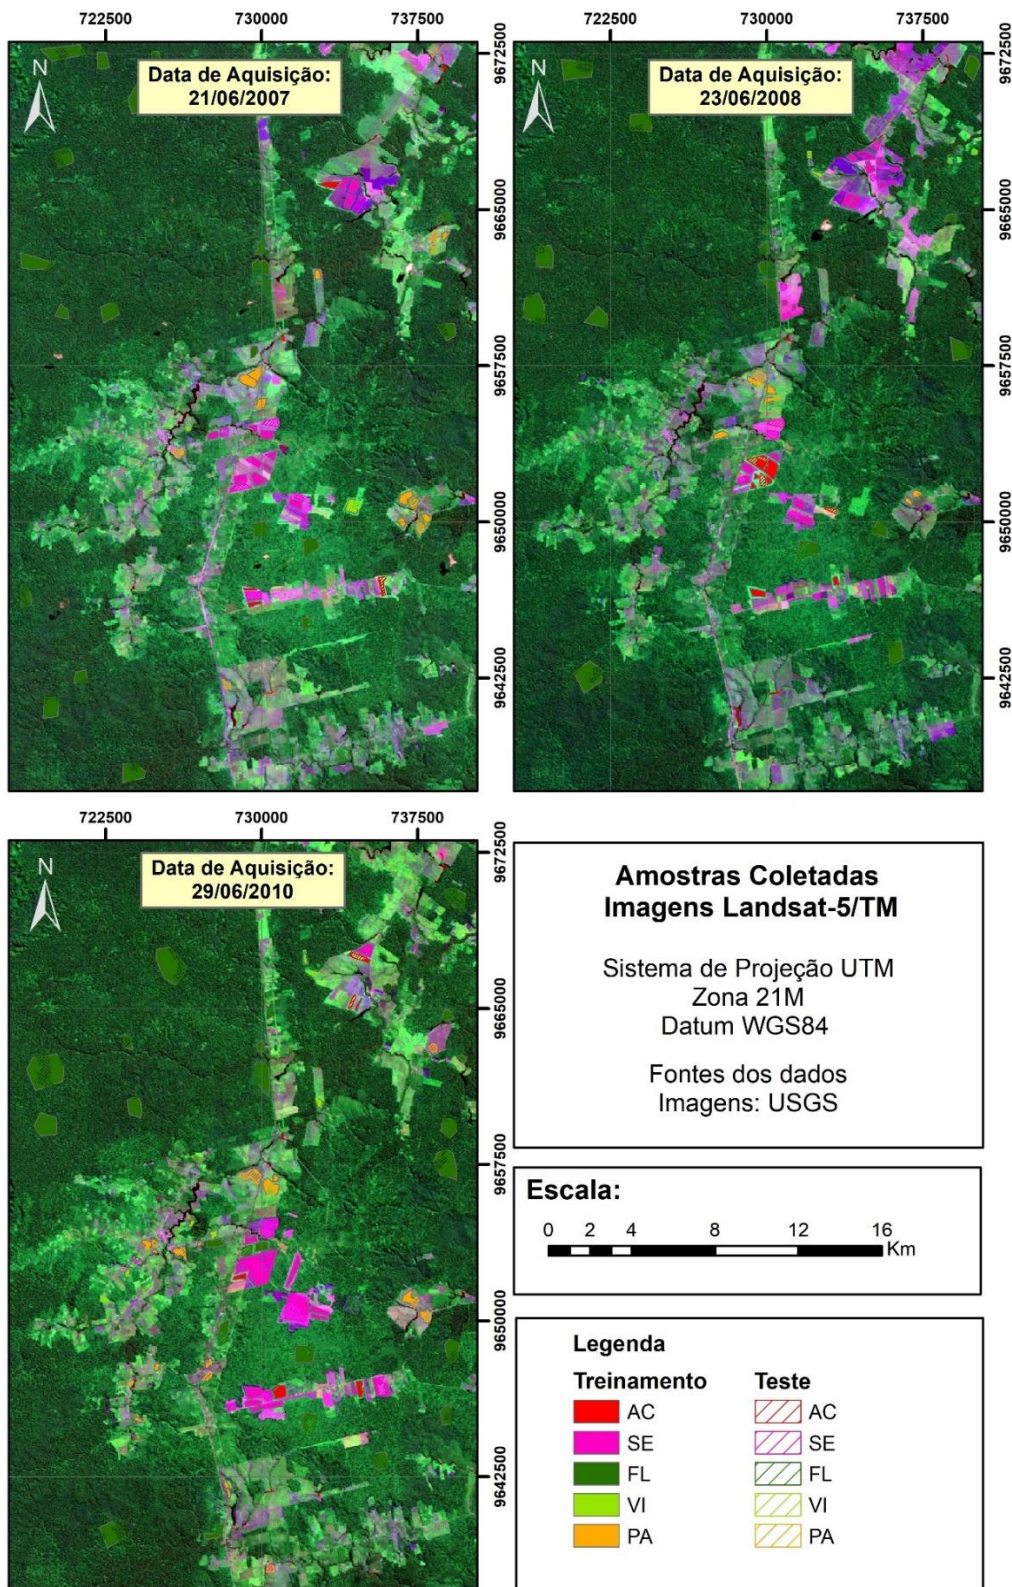
Fonte: Produção do autor.

Figura 3.6 - Amostras das classes de uso e cobertura da terra, sobrepostas às composições R4G3B2 das imagens Sentinel-2/MSI.



Fonte: Produção do autor.

Figura 3.7 - Amostras das classes de uso e cobertura da terra, sobrepostas às composições R5G4B2 das imagens Landsat-5/TM.



Fonte: Produção do autor.



### 3.5 Simulação de valores faltantes

Para aplicar os métodos apresentados foi necessário simular valores faltantes nas imagens classificadas que representam as máscaras de nuvens e suas sombras. Sobre essas áreas são estimadas as classes de uso e cobertura da terra e posteriormente comparadas com classes originais das classificações.

Para tanto, Eckardt *et al.* (2013) destacam que para o processo de simulação de nuvens três fatores devem ser levados em consideração:

- Porcentagem de cobertura da imagem;
- Tamanho médio das nuvens;
- Distribuição espacial.

Quanto à porcentagem de cobertura da imagem, foi adotado um valor de cobertura de aproximadamente 10% do total de pixels com valores válidos (aqueles que não apresentam presença de nuvem em nenhuma das imagens da série analisada). Esse valor foi selecionado por não ocultar demasiadamente os valores dentro da região de estudo evitando a sua descaracterização. Além disso, segundo Asner (2001), em um âmbito anual e considerando o intervalo temporal entre 1984 e 1997, a probabilidade de obter imagens Landsat/TM com 10% e 30% ou menos da Amazônia brasileira é relativamente boa. Martins *et.al.* (2018) também concluem que a fração cobertura de nuvens em grande parte da Amazônia varia entre 10 e 40% entre os meses de junho e novembro.

Quanto ao tamanho médio das nuvens, o tamanho modal de nuvens do tipo cumulus variam entre 1 e 2 km (O'BRIEN, 1987; PLANK, 1969; RODTS; DUYNKERKE; JONKER, 2003). Nas simulações foram adotadas nuvens com formato circular de diâmetro aproximado de 1 km devido ao tamanho relativamente reduzido da área de estudo a fim de não perder características de transição de classes importantes para a estimativa.

Quanto a distribuição espacial, as circunferências foram dispostas de maneira aleatória sobre os pixels com valores válidos. Esta sobreposição seguiu algumas regras de distribuição, entre elas:

- Não foram consideradas sobreposições entre as circunferências;
- As circunferências devem ter sua área completamente localizada no interior da região de estudo;
- As circunferências devem ter sua área completamente localizada em regiões com valores de pixels válidos.

Dessa maneira, foram geradas seis imagens de máscaras simuladas e para cada uma foram considerados os fatores descritos anteriormente. Na Fonte: Produção do autor.

Figura 3.8 são ilustradas as imagens máscara simuladas utilizadas nos estudos de caso. Por apresentarem resolução espacial diferentes, o tamanho e número das circunferências são também diferentes para imagens Sentinel-2/MSI e Landsat-5/TM. Um resumo com as características gerais das simulações de nuvens geradas pode ser encontrado na Tabela 3.6.

Tabela 3.6 - Características gerais das simulações geradas.

	Imagem	
	Sentinel-2/MSI	Landsat-5/TM
Número de pixels válidos	7.735.007	895.137
Diâmetro das circunferências (em pixels)	100	33
Tamanho das circunferências (em pixels)	7825	889
Número de circunferências geradas	99	101
Porcentagem de cobertura das imagens	10,02%	10,03%

Fonte: Produção do autor.

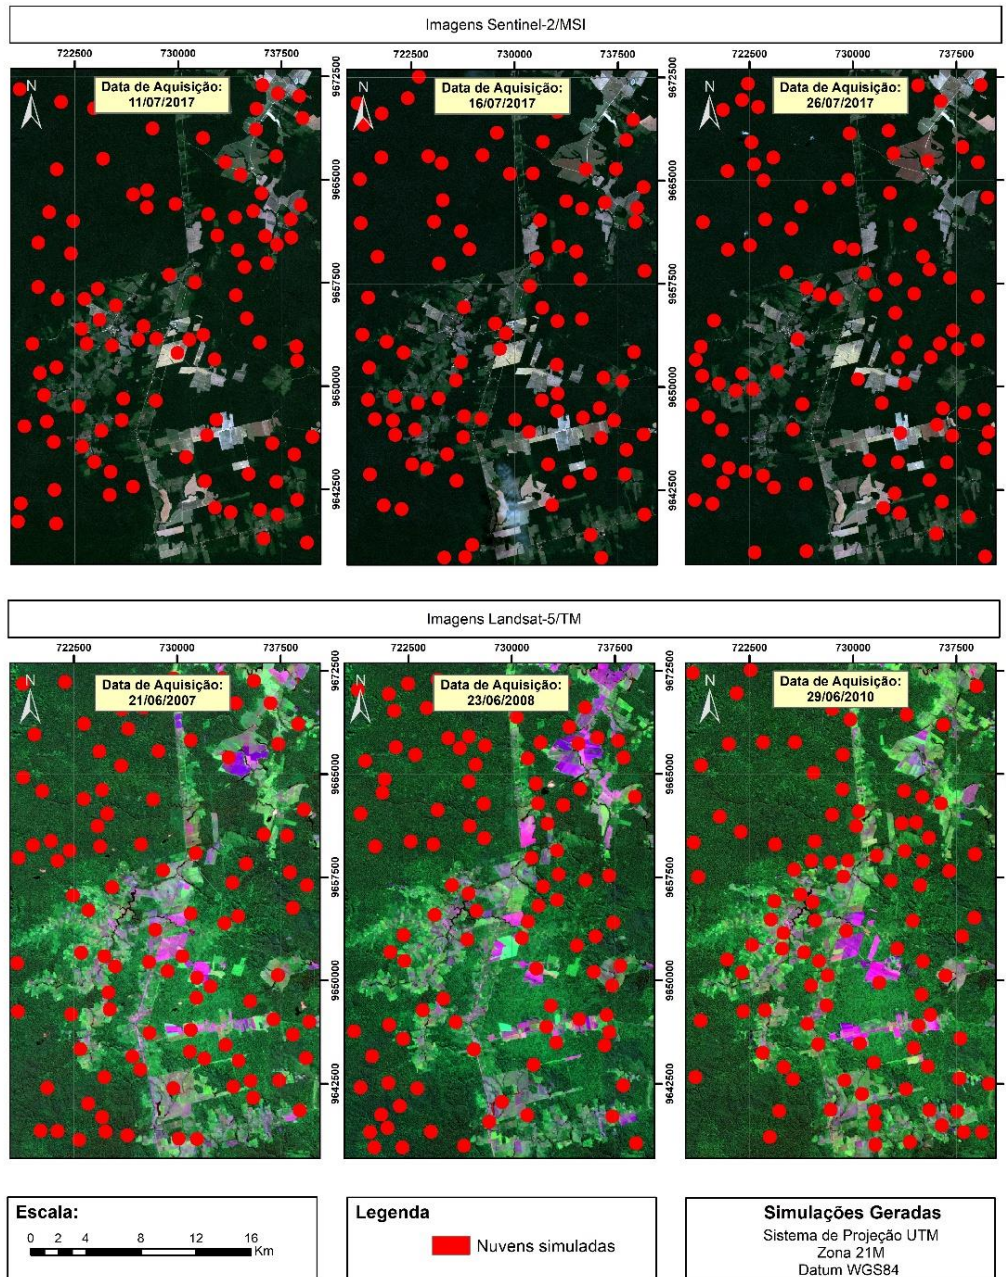
A fim de melhor representar a realidade e devido à distribuição espacial das simulações, as sobreposições temporais das circunferências foram permitidas. Dessa maneira, foram simuladas áreas com ausência total e parcial de dados ao longo do período analisado. Assim, o número de pixels sobrepostos nas imagens que compõem a série analisada, a partir da combinação das máscaras em diferentes instantes de tempo, é descrito na Tabela 3.7.

Tabela 3.7 – Sobreposições temporais das máscaras simuladas.

Combinação	Sentinel-2/MSI	Landsat-5/TM
	# Pixels	
Tempo 1 → Tempo 2	98.553	10.191
Tempo 2 → Tempo 3	86.886	11.836
Tempo 1 → Tempo 3	82.948	10.568
Tempo 1 → Tempo 2 → Tempo 3	12.924	1.901

Fonte: Produção do autor.

Figura 3.8 - Simulações de nuvens geradas.



Fonte: Produção do autor.

### 3.6 Técnicas Propostas

Neste capítulo, são introduzidas duas novas abordagens de estimativa de valores discretos. As operações pixel a pixel utilizam a distribuição espaço-temporal de classes para estimar classes de pixels em áreas com valores faltantes de imagens de sensoriamento remoto classificadas.

As metodologias propostas procuraram superar algumas das limitações apresentadas na Seção 2.4. Eckardt *et al.* (2013) afirmam que métodos sólidos para restaurar informações de valores faltantes não são compostos necessariamente de algoritmos complexos de processamento de imagens. Dessa maneira, os métodos propostos baseiam-se na estatística das mudanças de classes para estimar as classes em áreas com valores faltantes. Segundo Zhu e Woodcock (2014b), a análise multitemporal explora a capacidade de identificar mudanças de uso e cobertura da terra a partir de dados de sensoriamento remoto sendo assim utilizado como princípio para as técnicas propostas.

A principal diferença entre os métodos apresentados na Seção 2.4 e os propostos nesta dissertação está na efetividade destes métodos quando aplicados a séries temporalmente curtas compostas número de imagens limitadas, entre 3 e 5. Grande parte das metodologias listadas na Seção 2.4 são aplicáveis a longas séries temporais, sendo eficazes em suavizar os ruídos presentes nas mesmas.

Para ambas as técnicas propostas nesse trabalho adotam-se algumas premissas básicas:

- Existir uma série de imagens classificadas;
- Existir uma série de imagens que constituem máscaras de nuvens e sombras de nuvens sendo uma para cada imagem classificada da série;
- Todas as imagens classificadas encontram-se corregistradas entre si;
- As imagens possuem a mesma resolução espacial e, portanto, o mesmo número de pixels;

- Todas as classes de uso e cobertura da terra consideradas na análise são encontradas em cada uma das imagens classificadas utilizadas;
- O tamanho do recorte da imagem é o suficiente para abranger a mudanças de classes de uso e cobertura da terra de interesse.

Além disso, as técnicas propostas permitem a utilização de imagens classificadas oriundas de métodos distintos de classificação ou mesmo sensores distintos. Isso permite a integração de informações e torna a série mais densa aumentando a confiabilidade das estimativas.

Dessa forma, esse estudo propõe a estimativa de classes de uso e cobertura da terra em áreas afetadas pela cobertura de nuvens e suas sombras a partir de imagens classificadas baseando-se na extração de informações dos padrões de mudanças em áreas livres de nuvens. As técnicas propostas são denominadas: análise das transições de classes (ATRANS) e análise da trajetória de classes (ATRAJ). Ambos utilizam padrões de mudança no uso e cobertura da terra para estimar as classes nas áreas afetadas pela cobertura de nuvens.

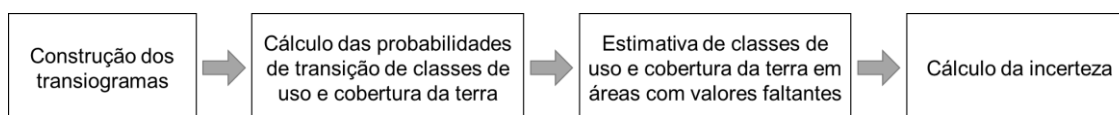
A técnica ATRANS utiliza os padrões de mudança a partir da transição de classes. Baseando-se na distribuição de transições de classes em áreas não afetadas pela cobertura de nuvens é realizada uma estimativa em áreas com valores faltantes. Enquanto a técnica ATRAJ utiliza os padrões definidos pela trajetória de classes em áreas não afetadas para realizar a estimativa de classes em áreas com valores faltantes. Nas próximas seções, as técnicas são detalhadas.

### **3.6.1 Análise das transições de classes de uso e cobertura da terra (Método ATRANS)**

Com base no exposto sobre as transições de classes de uso e cobertura da terra previamente, o método ATRANS considera que os transiogramas caracterizam as áreas de estudo e, por isso, são capazes de serem utilizados para estimar as classes nos pixels com valores faltantes. O método é estruturado nas fases apresentadas na Figura 3.9. Primeiramente, são construídos os transiogramas baseados em pixels com valores válidos, a partir dos quais são geradas as

probabilidades de transição de classes. Posteriormente, essas probabilidades são utilizadas para estimativa de classes. E, por fim, essa mesma probabilidade é utilizada para geração dos mapas de incertezas. Cada fase é descrita detalhadamente nas próximas seções.

Figura 3.9 - Organização do método ATRANS.



Fonte: Produção do autor.

### 3.6.1.1 Construção dos transiogramas

O parâmetro de entrada desta fase é composto por um conjunto de imagens classificadas ordenadas temporalmente, juntamente com um conjunto de máscaras que indicam o local dos valores faltantes ambos com o mesmo número de imagens. As máscaras representam as áreas de nuvens, sombras de nuvens, independentemente do método a partir do qual foram obtidas (sejam métodos automáticos ou manuais de detecção).

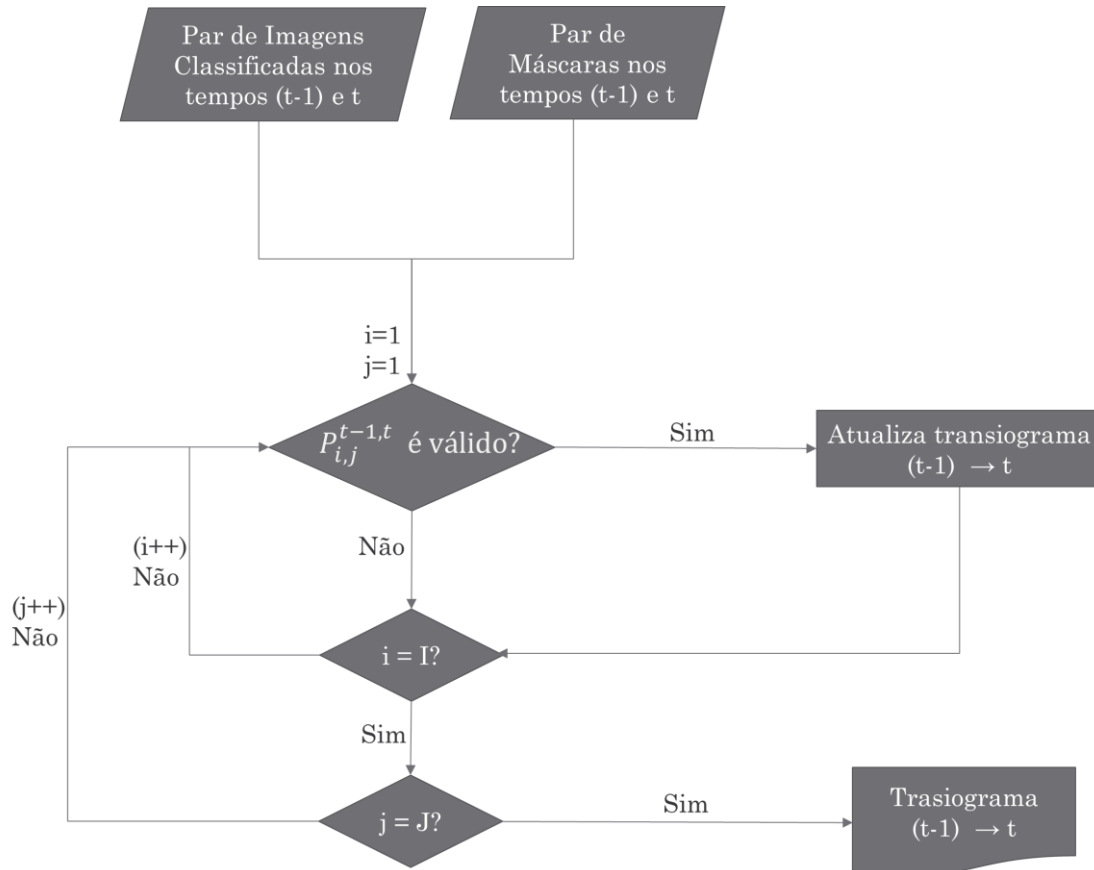
Neste método é construído um transiograma para cada par de imagens. Dessa maneira, é contabilizado o número de pixels que representam cada transição de classe de uso e cobertura da terra. O número total de transições possíveis é representado por  $K \times K$ , onde  $K$  é o número de classes a ser considerada em cada classificação. Para construção do transiograma, somente são considerados os pixels com valores válidos em ambas as imagens sendo analisadas, ou seja, pixels fora das máscaras de entrada do método.

O procedimento para construção dos transiogramas é apresentado na Figura 3.10. Neste fluxograma o termo  $i$  indica o número de linhas ( $0 < i \leq I$ ),  $j$  representa o número de colunas das imagens ( $0 < j \leq J$ ),  $P$  representa o pixel analisado e  $t$  e  $(t - 1)$  representam o tempo de cada imagem do par analisado.

Esse procedimento é repetido par-a-par para todas as imagens que compõem a série analisada. O resultado são  $N - 1$  transiogramas, sendo  $N$  o número de imagens totais utilizadas na série analisada. Cada transiograma quantifica as

transições de classe existentes para cada par de imagens. Esses transiogramas são utilizados como parâmetros de entrada da próxima etapa do método.

Figura 3.10 - Fluxograma para geração dos transiogramas.



Fonte: Produção do autor.

### 3.6.1.2 Probabilidade de transição de classes de uso e cobertura da terra

Nesta fase, os parâmetros de entrada do algoritmo são os transiogramas. As probabilidades de transição de classes são calculadas a partir dos transiogramas. Para cada transiograma é computada a probabilidade de um pixel pertencer a uma determinada classe dada a classe atribuída a ele na imagem do tempo imediatamente anterior.

O cálculo das probabilidades de transição entre classes é realizado para cada par de imagens da série considerada a partir de transiogramas no formato de matrizes. Assim, a partir de uma série de imagens classificadas de uma mesma região em tempos distintos  $t \in \{1, 2, 3, \dots, T\}$  e, considerando duas imagens classificadas dessa série em tempos distintos e consecutivos  $t - 1$  e  $t$ , sendo

$L_{(t-1)}$  e  $L_{(t)}$  as classes  $\omega_k (k \in 1, 2, 3, \dots, K)$ , a probabilidade é calculada para um par de imagens e é representado por uma matriz  $K \times K$ . O número total de transições ( $N_{Tr}$ ) possíveis é representado por:

$$N_{Tr} = K^2 \quad (3.1)$$

Cada elemento da matriz representa a probabilidade condicional calculada a partir dos pixels com valores válidos em ambas as imagens. A Equação 3.2 mostra a matriz genérica de probabilidade de transição de classes.

$$P_{\omega_k} = \begin{bmatrix} P(L_{(t)} = \omega_1 | L_{(t-1)} = \omega_1) & P(L_{(t)} = \omega_2 | L_{(t-1)} = \omega_1) & \cdots & P(L_{(t)} = \omega_i | L_{(t-1)} = \omega_1) \\ P(L_{(t)} = \omega_1 | L_{(t-1)} = \omega_2) & P(L_{(t)} = \omega_2 | L_{(t-1)} = \omega_2) & \cdots & P(L_{(t)} = \omega_i | L_{(t-1)} = \omega_2) \\ \vdots & \vdots & \ddots & \vdots \\ P(L_{(t)} = \omega_1 | L_{(t-1)} = \omega_k) & P(L_{(t)} = \omega_2 | L_{(t-1)} = \omega_k) & \cdots & P(L_{(t)} = \omega_i | L_{(t-1)} = \omega_k) \end{bmatrix} \quad (3.2)$$

Para tanto, tem-se uma probabilidade  $P(L_{(t)} = \omega_n | L_{(t-1)} = \omega_m)$ , para um elemento localizado na linha  $m$  e coluna  $n$  da matriz onde  $1 \leq m$  e  $n \leq K$ . E essa probabilidade é calculada segundo a seguinte fórmula:

$$P_{m,n} = \frac{T_{m,n}}{\sum_{m=1}^K T_{m,n}} \quad (3.3)$$

Dessa maneira, a probabilidade  $P(L_{(t)} = \omega_1 | L_{(t-1)} = \omega_2)$ , por exemplo, representa a probabilidade de um pixel ser atribuído a classe  $\omega_1$  dado que anteriormente ele pertencia a classe  $\omega_2$ . Isso se aplica às demais probabilidades. Nesse caso a soma das probabilidades de cada linha da matriz é igual a 1.

Uma exceção considerada no método é quanto a estimativa em pixels na primeira imagem da série, visto que essa não possui uma imagem de referência em um tempo anterior para cálculo da probabilidade. Neste caso, é calculada a probabilidade de ocorrência de uma classe no tempo  $t$  dada sua classe de ocorrência no tempo  $t + 1$ , conforme representado na Equação 3.4. Da mesma forma que no caso anterior (tempos  $t - 1$  e  $t$ ), a soma das probabilidades de cada linha também é igual a 1.

$$P_{\omega_k} = \begin{bmatrix} P(L_{(t)} = \omega_1 | L_{(t+1)} = \omega_1) & P(L_{(t)} = \omega_2 | L_{(t+1)} = \omega_1) & \cdots & P(L_{(t)} = \omega_i | L_{(t+1)} = \omega_1) \\ P(L_{(t)} = \omega_1 | L_{(t+1)} = \omega_2) & P(L_{(t)} = \omega_2 | L_{(t+1)} = \omega_2) & \cdots & P(L_{(t)} = \omega_i | L_{(t+1)} = \omega_2) \\ \vdots & \vdots & \ddots & \vdots \\ P(L_{(t)} = \omega_1 | L_{(t+1)} = \omega_k) & P(L_{(t)} = \omega_2 | L_{(t+1)} = \omega_k) & \cdots & P(L_{(t)} = \omega_k | L_{(t+1)} = \omega_k) \end{bmatrix} \quad (3.4)$$



Vale ressaltar que a probabilidade de transição de classes é calculada para cada transiograma separadamente e não de maneira unificada. Isto evita que alterações nos padrões de mudanças de uso e cobertura da terra influenciem na estimativa.

### **3.6.1.3 Estimativa da classe de uso e cobertura da terra em áreas com valores faltantes**

Nessa etapa são efetivamente realizadas as estimativas das classes de uso e cobertura da terra atribuídas aos pixels com valores faltantes, ou seja, aqueles indicados pelas máscaras. Essa etapa tem como parâmetros de entrada as matrizes de probabilidade obtidas da etapa anterior, as imagens classificadas e as máscaras.

A classe é estimada para um pixel em um tempo  $t$  dada a classe atribuída a esse mesmo pixel no tempo  $t - 1$ . Para tanto são consideradas estimativas somente para pixels que no primeiro momento tenha um valor válido e, posteriormente, um valor faltante. A classe atribuída  $\omega$  ao pixel com valor faltante é aquela com maior probabilidade de ocorrência. Isto é, a classe que satisfaz a Equação 3.5. Ou seja, aquela classe com maior probabilidade de ocorrência. Esse processo é repetido ao longo de toda série até a  $N$ -ésima imagem da série.

$$\omega = \arg \max P(L_{(t)}|L_{(t-1)}) \quad (3.5)$$

Um esquema que exemplifica a estimativa de classes é ilustrado na Figura 3.11. Nela, é possível observar a técnica aplicada a um par de imagens classificadas a partir da qual são extraídos os transiogramas que representam as transições de classes. A partir desses transiogramas são calculadas as probabilidades e incertezas (descrita na próxima seção) para cada caso em que a estimativa de classes é realizada.

Caso o valor máximo não seja único foi definido um critério de desempate baseado no conhecimento *a priori* da distribuição espacial das classes. Assim, considerando que ao estimar uma classe de um pixel no tempo  $t$  dada sua classe no tempo  $t - 1$  haja mais classes com valores equivalentes ao máximo, ao pixel atribuído à classe com maior ocorrência no tempo  $t$  entre as classes com

empate. Caso o empate persista, a classe é definida através de um sorteio aleatório entre as classes com valor de probabilidades iguais.

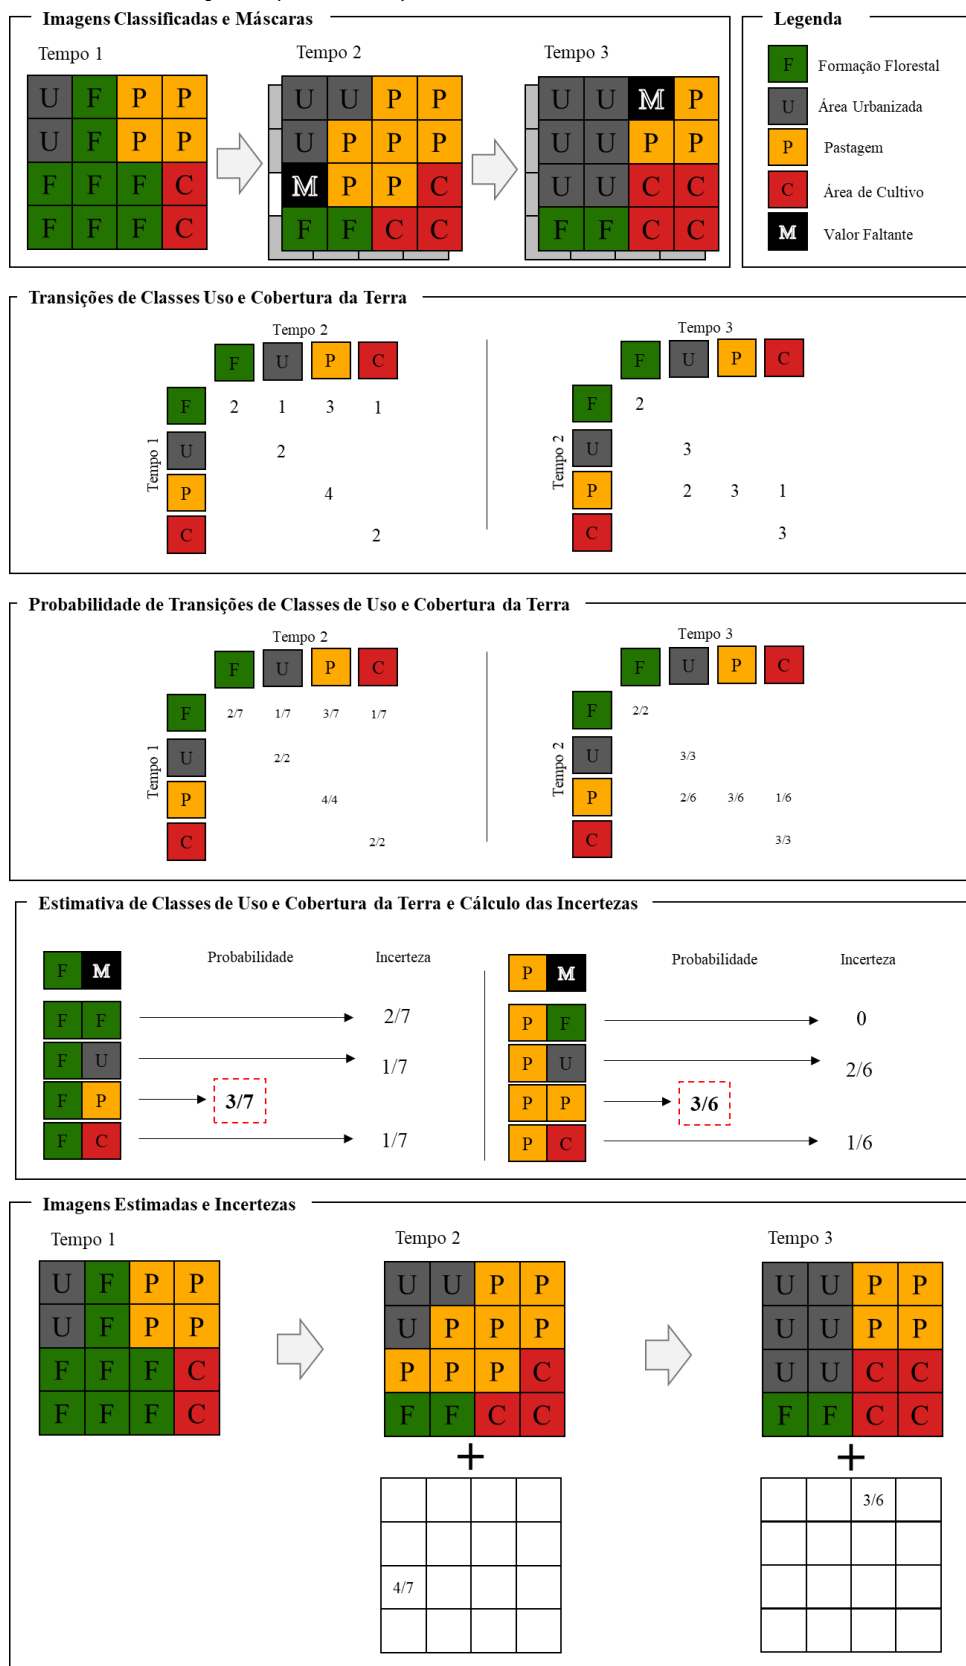
Como descrito anteriormente, outro caso especial considerado durante a elaboração do método é quanto a estimativa da primeira imagem da série, visto que essa não possui uma imagem de referência em um tempo anterior para cálculo da probabilidade. Neste caso, a classe atribuída ao pixel é aquela que maximiza a probabilidade de ocorrência de uma classe no tempo  $t$  de ocorrência da classe no tempo  $t + 1$ :

$$\omega = \arg \max P(L_{(t)}|L_{(t+1)}) \quad (3.6)$$

Os critérios de desempate permanecem os mesmos. Primeiramente, baseado no conhecimento *a priori* da distribuição espacial das classes de uso e cobertura da terra possíveis no tempo  $t$ . Caso ainda não seja possível calcular um valor único de máximo, é realizado um sorteio aleatório entre as classes de uso e cobertura da terra possíveis.

O pseudocódigo contendo as etapas para estimativa pode ser encontrado no Apêndice A.

Figura 3.11 - Exemplo da estimativa de classes realizada pelo método da Análise de Transições (ATRANS).



Fonte: Produção do autor.

#### 3.6.1.4 Cálculo das incertezas

Uma das principais vantagens desse método é a possibilidade de gerar mapas de incerteza para os pixels estimados. Isso abrange um dos requisitos descritos por Gerber et al. (2018) para desenvolvimento de métodos de estimativa de valores. A incerteza ( $E$ ) de um pixel irá depender de sua classe ( $L_{(t)}$ ) assumida no tempo  $t$  dada sua classe ( $L_{(t-1)}$ ) no tempo  $t - 1$ . A equação para obtenção da incerteza é dada por:

$$E_{i,j} = 1 - \max P(L_{(t)}|L_{(t-1)}) \quad (3.7)$$

De maneira similar, a incerteza para as estimativas das classes na primeira imagem da série é calculada a partir da probabilidade condicional. Entretanto, a incerteza ( $E$ ) irá depender da classe ( $L_{(t)}$ ) atribuída ao pixel dada sua classe ( $L_{(t+1)}$ ) no tempo  $t + 1$ . A equação para obtenção das incertezas na primeira imagem da série é expressa por:

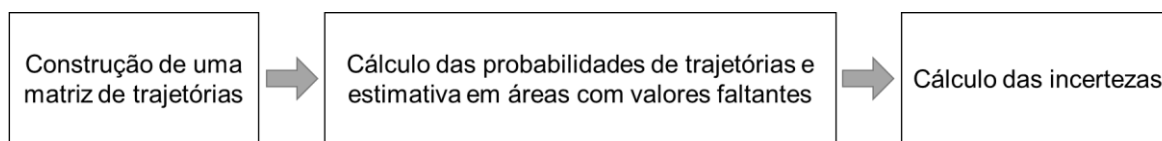
$$E_{i,j} = 1 - \max P(L_{(t)}|L_{(t+1)}) \quad (3.8)$$

#### 3.6.2 Análise das trajetórias de classes de uso e cobertura da terra (Método ATRAJ)

Ao contrário do método apresentado anteriormente em que se considera apenas as transições de classes de uso e cobertura da terra, nesse método se consideram as trajetórias das mudanças de uso e cobertura da terra para se obter as estimativas em áreas com pixels inválidos. Baseado no exposto, no método ATRAJ se considera que as trajetórias de mudanças de uma região também são capazes de expressar as suas características. Portanto, são capazes de serem utilizadas para estimar as classes nos pixels com valores faltantes.

O método é estruturado nas etapas apresentadas na Figura 3.12. Para aplicação do método, primeiramente, é realizado o levantamento das trajetórias baseado em pixels com valores válidos. Posteriormente, esse levantamento é utilizado no cálculo das probabilidades que são utilizadas para estimativa de classes. Por fim, são computadas as incertezas das estimativas dos valores faltantes.

Figura 3.12 - Organização do método ATRAJ.



Fonte: Produção do autor.

### 3.6.2.1 Construção da matriz de trajetórias

Assim como na primeira etapa do método ATRANS, nessa fase de construção da matriz de trajetórias, o parâmetro de entrada do algoritmo é composto por um conjunto de imagens classificadas ordenadas temporalmente, juntamente com um conjunto de máscaras que indicam o local dos valores faltantes. Da mesma maneira, as máscaras representam as áreas de nuvens ou sombras de nuvens independentemente do método a partir do qual foram obtidas (sejam métodos de detecção automáticos ou manuais).

A partir de uma série de imagens classificadas de uma mesma região em tempos distintos  $t \in \{1, 2, 3, \dots, T\}$ , no método cria-se de uma matriz  $T$ -dimensional capaz de armazenar o número de ocorrências de cada trajetória de classes de uso e cobertura da terra. Para construção da matriz de trajetórias, somente são considerados os pixels com valores válidos em todas as imagens sendo analisadas. Isto é, pixels fora das máscaras de entrada do método simultaneamente em todas as imagens que compõem a série. Considerando as classes  $\omega_k (k = 1, 2, 3, \dots, K)$  presentes na série, o número de células em cada dimensão da matriz será igual ao número de classes ( $K$ ).

De acordo com Petit, Scudder e Lambin (2001), o número de trajetórias possíveis ( $Tc$ ) é calculado em função do número de classes de uso e cobertura da terra presentes na série ( $K$ ) e o número de imagens classificadas da série ( $N$ ). Esse é o valor equivalente ao número de células total da matriz de trajetórias. O número de trajetórias possíveis numa série é expresso por  $K^N$ .

O procedimento tem como produto uma matriz que armazena em cada célula o número de pixels de trajetórias presente na região de estudo. Vale ressaltar, que são considerados no levantamento somente os pixels que apresentam valores válidos em todas as imagens classificadas da série.

### 3.6.2.2 Probabilidade de trajetória e estimativa de classes em áreas com valores faltantes

Para o cálculo da probabilidade de cada trajetória as imagens classificadas, as máscaras e a matriz de trajetórias são os parâmetros de entrada. Nessa etapa, a partir das probabilidades das trajetórias são estimadas as classes dos pixels que possuem valores faltantes.

No método é realizada uma análise pixel-a-pixel, verificando as classes atribuídas a cada um ao longo da série analisada. Caso haja pelo menos um pixel com valor faltante, é calculada a probabilidade das classes que podem ser atribuídas a ele e, posteriormente, realizada a estimativa. Vale ressaltar que o método depende da existência de pelo menos um valor válido presente na série do pixel analisado, ou seja, pixels compostos somente por valores faltantes em toda série não são estimados.

Considerando a classe conhecida ( $C_{(t)}$ ) e os pixels com valores faltantes, os quais as classes são desconhecidas ( $D_{(t)}$ ) em uma série de tamanho ( $T$ ) analisada em um dado tempo ( $t$ ) onde  $t \in \{1, 2, 3, \dots, T\}$ , a classe atribuída ao pixel é aquela que satisfaz a Equação 3.9. Ou seja, serão consideradas as trajetórias com maior probabilidade de ocorrência dadas as classes atribuídas àquele pixel quando seus valores são válidos.

$$\omega = \arg \max(P\{D_{(t=1)}, D_{(t=2)}, \dots | C_{(t=1)}, C_{(t=2)}, \dots \}) \quad (3.9)$$

Um esquema que exemplifica a estimativa de classes é ilustrado na Figura 3.13. Nele é demonstrado um exemplo da aplicação da técnica ATRAJ a um conjunto de 3 imagens classificadas com 4x4 pixels de dimensão e 3 classes. Pode ser observada a etapa de construção da matriz de trajetórias a partir dos pixels válidos em todas as imagens. Além disso, mostra a estimativa de classes aplicada a dois pixels da série e como é calculada a probabilidade e incerteza (descrita na próxima seção) das estimativas.

Visto que, nesse caso, são estimadas as trajetórias, ou seja, o conjunto de mudanças de classes como um todo, o critério de desempate adotado quando


mais de uma trajetória é possível foi a primeira trajetória encontrada durante a busca pelo máximo.

### 3.6.2.3 Cálculo das incertezas

Assim como o método ATRANS, esse método prevê o cálculo das incertezas das estimativas. A incerteza ( $E$ ) de um pixel estimado localizado na linha  $i$  e coluna  $j$  irá depender de suas classes conhecidas ( $C_{(t)}$ ) e os pixels com valores faltantes, os quais as classes são desconhecidas ( $D_{(t)}$ ) em uma série de tamanho ( $T$ ) analisada em um dado tempo ( $t$ ) onde  $t \in \{1, 2, 3, \dots, T\}$ . A equação para obtenção da incerteza é descrita pela Equação 3.10.

$$E_{i,j} = 1 - \max(P\{D_{(t=1)}, D_{(t=2)}, \dots | C_{(t=1)}, C_{(t=2)}, \dots\}) \quad (3.10)$$

Figura 3.13 - Exemplo da estimativa de classes realizada pelo método da Análise de Trajetórias (ATRAJ).



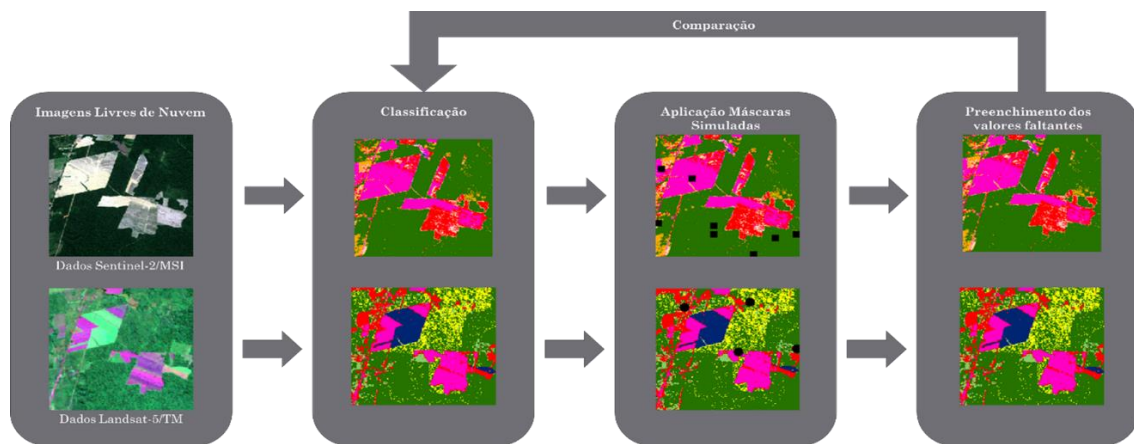
Fonte: Produção do autor.



### 3.7 Validação

Como parte do processo de validação, foram examinadas a influência dos métodos ATRANS e ATRAJ aplicados aos dois estudos de casos com características distintas de classificação. Para validação das classificações estimadas foram utilizados os índices de avaliação adquiridos por intermédio de matrizes de confusão. Um fluxograma geral ilustrando a comparação realizada é demonstrado na Figura 3.14.

Figura 3.14 - Fluxograma geral da metodologia de avaliação dos métodos.



Fonte: Produção do autor.

Para tanto, em ambos os estudos de caso, foram sorteados aleatoriamente e de maneira independente 100 e 15 pixels por classe em cada imagem classificada de referência oriundas das imagens Sentinel-2/MSI e Landsat-5/TM, respectivamente. O sorteio foi realizado dentro das regiões delimitadas pelas máscaras simuladas a fim de gerar as matrizes de confusão e cálculo dos coeficientes. Vale ressaltar que somente foram consideradas as áreas dentro das máscaras simuladas e que foram efetivamente estimadas, ou seja, o sorteio não abrange áreas não estimadas. Um modelo de matriz de erros genérico é apresentado na Tabela 3.8.

A partir das matrizes foram gerados os índices de concordância global, concordância parcial, desacordo, representação de classe e erro de atribuição de classe que indicam as taxas de acerto das estimativas. O índice de concordância global ( $CG$ ) representa o percentual total de pixels estimados em acordo com a classificação de referência, representado pela Equação 3.11. Do

ponto de vista da imagem de referência, são calculados os índices de concordância parcial ( $CP$ ) e desacordo ( $ID$ ) representados pelas Equações 3.12 e 3.13. Já do ponto de vista da imagem estimada, são calculados os índices de representação de classe ( $RC$ ) e o erro de atribuição de classe ( $EA$ ) representados pelas Equações 3.14 e 3.15. Sendo  $x_{kk}$  o número total de pontos corretamente classificados da classe  $k$ ,  $n$  é o número total de pixels amostrados,  $x_{ij}$  é o número de pixels da classe  $j$  da imagem de referência atribuído a classe  $i$  na imagem estimada,  $x_{+j}$  representa o número total de pixels avaliados da classe  $j$  na referência e  $x_{i+}$  representa o número total de pixels avaliados da classe  $i$  na estimativa.

Tabela 3.8 - Modelo da matriz de erro utilizada para a aferição da acurácia temática das imagens estimadas.

		Referência				Total
		$C_1$	$C_2$	...	$C_c$	
Estimativa	$C_1$	$x_{11}$	$x_{12}$	...	$x_{1c}$	$x_{1+}$
	$C_2$	$x_{21}$	$x_{22}$	...	$x_{2c}$	$x_{2+}$
	⋮	⋮	⋮	⋮	⋮	⋮
	$C_c$	$x_{c1}$	$x_{c2}$	...	$x_{cc}$	$x_{c+}$
	Total	$x_{+1}$	$x_{+2}$	...	$x_{+c}$	$n$

Fonte: Produção do autor.

$$CG = \frac{\sum_{k=1}^c x_{kk}}{n} \quad (3.11)$$

$$CP = \frac{x_{kk}}{x_{+k}} \quad (3.12)$$

$$ID = 1 - CP \quad (3.13)$$

$$RP = \frac{x_{kk}}{x_{k+}} \quad (3.14)$$

$$EA = 1 - RP \quad (3.15)$$

A concordância parcial ( $CP$ ) e o índice de desacordo ( $ID$ ) relacionam-se a porcentagem de pontos de determinada classe que foram corretamente estimados em relação à totalidade dos pixels da imagem de referência. O índice de representação de classe ( $RC$ ) e o erro de atribuição de classe ( $EA$ ) indicam a

probabilidade de um pixel ser atribuído pela estimativa à mesma classe que na classificação de referência.

Para verificar a existência de diferença significativa entre os métodos de estimativa, foi aplicado um teste de hipóteses a partir do índice Kappa (Equação 3.16) calculado as matrizes de erros geradas sobre as amostras sorteadas. O teste segue a metodologia descrita por Congalton e Green (2009) e Hudson e Ramm (1987) e prevê um teste estatístico de hipótese Z unilateral (Equação 3.18) comparando duas classificações distintas com a mesma referência.

$$\kappa = \frac{\theta_1 - \theta_2}{1 - \theta_2} \quad (3.16)$$

$$\theta_2 = \frac{\sum_{k=1}^c x_{k+} x_{+k}}{n^2} \quad (3.17)$$

$$Z = \frac{|\hat{\kappa}_1 - \hat{\kappa}_2|}{\sqrt{v\hat{a}r(\hat{\kappa}_1) + v\hat{a}r(\hat{\kappa}_2)}} \quad (3.18)$$

$$var(\hat{\kappa}) = \frac{1}{n} \left[ \frac{\theta_1(1 - \theta_1)}{(1 - \theta_2)^2} + \frac{2(1 - \theta_1)(2\theta_1\theta_2 - \theta_3)}{(1 - \theta_2)^3} + \frac{(1 - \theta_1)^2(\theta_4 - 4\theta_2^2)}{(1 - \theta_2)^4} \right] \quad (3.19)$$

$$\theta_3 = \frac{\sum_{k=1}^c x_{kk}(x_{k+} + x_{+k})}{n^2} \quad (3.20)$$

$$\theta_4 = \frac{\sum_{i=1}^c \sum_{j=1}^c x_{ij}(x_{i+} + x_{+j})^2}{n^3} \quad (3.21)$$

Considerando um teste de hipótese com hipótese nula (H0):  $(\hat{\kappa}_1 - \hat{\kappa}_2) = 0$ , sendo  $\hat{\kappa}_1$  e  $\hat{\kappa}_2$  as estimativas estatísticas do Kappa, enquanto  $v\hat{a}r(\hat{\kappa}_1)$  e  $v\hat{a}r(\hat{\kappa}_2)$  são a variância de Kappa das matrizes de confusão 1 e 2, respectivamente. E o valor de  $\theta_1$  equivale ao valor de CG.

### 3.8 Softwares utilizados

Para realizar os processamentos pertinentes ao trabalho, foram utilizados os seguintes *softwares*:

- *Anaconda Navigator* 3 no desenvolvimento do algoritmo para aplicação da técnica ATRAJ;
- ArcGIS 10.6 na confecção dos mapas;
- ENMap-Box na classificação pelos métodos SVM e RF;
- ENVI 4.7 na classificação das imagens pelo método MaxVer;
- *Interactive Data Language* (IDL) 8.0 no desenvolvimento do algoritmo para aplicação da técnica ATRANS;
- Sen2Cor 2.8.0 na correção atmosférica das imagens Sentinel-2;
- *Sentinel Application Platform* (SNAP) 6.0 na manipulação das imagens Sentinel-2.

## **4 RESULTADOS**

Neste capítulo, são descritos e apresentados os resultados de dois estudos de caso propostos para avaliar a aplicabilidade e eficiência dos métodos propostos (ATRANS e ATRAJ) em relação a preservação das classes de uso e cobertura da Terra. No primeiro estudo de caso, apresentam-se os resultados aplicados a imagens Sentinel-2/MSI com intervalo temporal de dias. Já no segundo estudo de caso, foram aplicados a imagens Landsat-5/TM com intervalo de tempo da ordem de anos.

### **4.1 Estudo de caso I: Imagens Sentinel-2/MSI**

Este estudo de caso tem por objetivo verificar a capacidade dos métodos propostos em estimar as classes de uso e cobertura da terra aplicados às imagens Sentinel-2/MSI descritas na Seção 3.2.1. As imagens compõem um estudo de caso com alta resolução espacial e com pequeno intervalo de tempo entre elas.

Dessa maneira, na Seção 4.1.1, é apresentada a taxa de pixels não estimados. Enquanto nas Seções 4.1.2 e 4.1.3 são apresentados os resultados para aplicação dos métodos ATRANS e ATRAJ, respectivamente. Os mapas que representam os produtos das estimativas para ambos os métodos desse estudo de caso encontram-se no Apêndice E.

#### **4.1.1 Taxa de pixels não estimados**

De maneira geral, foi observado que o método de análise das trajetórias (ATRAJ) apresentou uma menor taxa de pixels não estimados, ou seja, pixels que continuaram com valores faltantes quando comparado com o método ATRANS. Na Tabela 4.1 são descritos, em resumo, os valores, em porcentagem, de pixels não estimados para cada método, classificação e imagens adotados nesse primeiro estudo de caso.

Considerando o método ATRAJ, um total de 1,7% do número de pixels referentes às máscaras simuladas não foram estimados para cada uma das imagens em todas as classificações analisadas. Esse valor corresponde ao número de pixels sobrepostos simultaneamente em todas as máscaras simuladas da série, onde


há inexistência de valores necessários para a estimativa. Ou seja, o método somente foi incapaz de realizar estimativas na ausência total de informação de classe ao longo de toda série. Um exemplo demonstrando a situação descrita é ilustrado na Figura 4.1. Nesta figura a imagem corresponde ao produto da estimativa pelo método ATRAJ a partir da classificação SVM (data referência: 26 de julho de 2017).

Tabela 4.1 - Taxa de pixels não estimados sobre imagens Sentinel-2/MSI classificadas.

Método	Data de Referência		
	%		
	11 julho 17	16 julho 17	26 julho 17
ATRAJ	1,7	1,7	1,7
ATRANS	12,7	12,7	11,2

Fonte: Produção do autor.

Figura 4.1 – Exemplo de área com pixels não estimados pelo método ATRAJ em imagens classificadas do Sentinel-2/MSI.




Fonte: Produção do autor.

Para o método de análise dos transiogramas (ATRANS), a taxa de pixels não estimados foi superior a 11% em todos os cenários analisados. Esse valor foi maior que os apresentados no método anterior por dois motivos. Primeiramente, pelo método ser aplicado a pares de imagens, havendo assim um maior número de combinações com valores faltantes na série analisada. Além disso, não é previsto no método baseado em pixels já estimados. Esses dois fatores, em conjunto, são responsáveis por limitar a estimativa em um número maior de

pixels. Um exemplo demonstrando as situações descritas é ilustrado na Figura 4.2. Nesta figura a imagem corresponde aos produtos das estimativas pelo método ATRANS a partir da classificação SVM.

Figura 4.2 - Exemplo de área com pixels não estimados pelo método ATRANS em imagens classificadas do Sentinel-2/MSI.



Fonte: Produção do autor.

#### 4.1.2 Avaliação dos resultados obtidos pelo método ATRANS

A partir da amostragem realizada e descrita anteriormente, foram geradas as matrizes de concordância entre as imagens classificadas de referência e as estimadas. Os índices de avaliação foram calculados e são exibidos na Tabela 4.2, onde os valores correspondem às estimativas geradas a partir do emprego do método ATRANS.

De maneira geral, o método apresentou bons índices de concordância entre as classificações de referência e suas respectivas estimativas. Com exceção do índice *CG* da primeira imagem classificada da série, as estimativas realizadas sobre as classificações MAXVER apresentaram valores iguais ou superior quando comparado com as imagens classificadas por outros métodos. Entre as possíveis fontes que podem esclarecer esses resultados destaca-se que tal classificação apresentou menores erros de classificação. As classificações

obtidas pelo método MAXVER, apresentaram menor confusão de classes sendo capazes de gerar transiogramas com menos ruídos a partir dos quais foram baseadas as estimativas.

Analisando os resultados obtidos nas estimativas realizadas pelo método ATRANS, nota-se os valores de índice *CG* superiores a 0,55. A série de imagens referentes a classificação RF apresentou simultaneamente o maior (primeira imagem da série) e menor (última imagem da série) índice *CG* entre as classificações analisadas. Tais valores podem ser visualizados na Tabela 4.2.

Tabela 4.2 – Índices de avaliação das estimativas pelo método ATRANS realizadas sobre imagens Sentinel-2/MSI classificadas.

Data de Referência	MAXVER	RF	SVM
	Concordância Global ( <i>CG</i> )		
11 julho 17	0,68	0,76	0,69
16 julho 17	0,68 <sup>1</sup>	0,66	0,67 <sup>1</sup>
26 julho 17	0,71 <sup>1</sup>	0,55 <sup>1,2</sup>	0,69 <sup>1</sup>

(1) Nenhum pixel da classe AC foi estimado.

(2) Nenhum pixel da classe SE foi estimado.

Fonte: Produção do autor.

Na Tabela 4.3, é possível analisar a concordância parcial (*CP*), o índice de representação de classe (*RC*) e as taxas de erro (*ID* e *EA*) cometidos nas estimativas pelo método ATRANS ao variarem-se as classificações das imagens Sentinel-2/MSI analisadas. Observa-se que as classes de Formação Florestal, Corpo D'água e Pasto Sujo apresentaram, de maneira geral, bons valores de seus índices avaliativos. Além disso, houve pouca variação entre os índices dessas classes quando comparadas imagens classificadas de mesma data. A classe Pasto Limpo apresentou valores razoáveis de tanto de índice *CP* quanto de índice *ID*. Entretanto, as classes de Área de Cultivo, Área em Pousio e Solo Exposto apresentaram índices muito variáveis.

Analisando-se a média dos índices de cada classe, nota-se que as classes de Formação Florestal, Pasto Sujo, Solo Exposto e Corpo D'Água obtiveram bons índices de concordância parcial e de representação de classe. Já as classes de Pasto Limpo, Área de Pousio e Área de Cultivo foram as que apresentaram os



menores índices médios *CP* e *RC* registrando 0,21 na classe de Área de Cultivo e, conseqüentemente, os maiores índices de *ID* e *EA* com valor máximo de 0,79 na mesma classe.

Outro ponto que merece destaque ao analisar, simultaneamente, a Tabela 4.3 e os transiogramas utilizados para as estimativas do método que se encontram no Apêndice D é a inexistência de algumas classes na estimativa. Nota-se que a classe Área de Cultivo não foi predominante em nenhum dos transiogramas apresentados, resultando na não estimativa de nenhum pixel para mesma. De maneira similar, a classe de Solo Exposto não foi predominante no segundo transiograma da classificação pelo método RF, o que levou a não ser estimado nenhum pixel para ela na última imagem da série referente ao método.

Nota-se que as classes cujo método demonstrou maior dificuldade em estimar e, conseqüente, gerou as maiores incertezas são aquelas que apresentaram maior confusão nas classificações de referência. Os erros de comissão e omissão das classificações de referência influenciaram na construção dos transiogramas devido à presença de ruídos de classificação.

Tabela 4.3 - Índices relativos ao método ATRANS para as classes de uso e cobertura da terra em estudo sobre imagens Sentinel-2/MSI classificadas.

Método ATRANS																																	
Concordância Parcial (CP), Índice de Representação de Classe (RC), Índice de Desacordo (ID) e Erro de Atribuição de Classe (EA)																																	
Classificação		FL				AC				PS				PL				AP				SE				CA							
Método	Data de Referência	CP	RC	ID	EA	CP	RC	ID	EA	CP	RC	ID	EA	CP	RC	ID	EA	CP	RC	ID	EA	CP	RC	ID	EA	CP	RC	ID	EA	CP	RC	ID	EA
MAXVER	11 julho 17	1,00	0,87	0,00	0,13	0,66	0,23	0,34	0,77	0,82	0,83	0,18	0,17	0,44	0,59	0,56	0,41	0,43	0,68	0,57	0,32	0,95	0,59	0,05	0,41	1,00	0,87	0,00	0,13				
	16 julho 17	1,00	0,82	0,00	0,18	*				0,78	0,87	0,22	0,13	0,40	0,74	0,60	0,26	0,59	0,45	0,41	0,55	0,77	0,92	0,23	0,08	1,00	0,82	0,00	0,18				
	26 julho 17	1,00	0,98	0,00	0,02	*				0,82	0,80	0,18	0,20	0,50	0,79	0,50	0,21	0,48	0,75	0,52	0,25	0,92	0,72	0,08	0,28	1,00	0,98	0,00	0,02				
RF	11 julho 17	1,00	0,86	0,00	0,14	0,77	0,17	0,23	0,83	0,85	0,90	0,15	0,10	0,61	0,71	0,39	0,29	0,55	0,75	0,45	0,25	0,85	0,94	0,15	0,06	1,00	0,86	0,00	0,14				
	16 julho 17	1,00	0,88	0,00	0,12	*				0,71	0,77	0,29	0,23	0,38	0,71	0,62	0,29	0,51	0,43	0,49	0,57	0,77	0,77	0,23	0,23	1,00	0,88	0,00	0,12				
	26 julho 17	1,00	0,92	0,00	0,08	*				0,84	0,81	0,16	0,19	0,37	0,62	0,63	0,38	0,25	0,55	0,75	0,45	*				1,00	0,92	0,00	0,08				
SVM	11 julho 17	1,00	0,93	0,00	0,07	0,82	0,23	0,18	0,77	0,84	0,75	0,16	0,25	0,54	0,62	0,46	0,38	0,44	0,68	0,56	0,32	0,90	0,60	0,10	0,40	1,00	0,93	0,00	0,07				
	16 julho 17	1,00	0,79	0,00	0,21	*				0,75	0,71	0,25	0,29	0,49	0,69	0,51	0,31	0,47	0,62	0,53	0,38	0,83	0,87	0,17	0,13	1,00	0,79	0,00	0,21				
	26 julho 17	1,00	0,99	0,00	0,01	*				0,90	0,73	0,10	0,27	0,47	0,73	0,53	0,27	0,36	0,50	0,64	0,50	0,91	0,87	0,09	0,13	1,00	0,99	0,00	0,01				
Média		1,00	0,89	0,00	0,11	0,75	0,21	0,25	0,79	0,81	0,80	0,19	0,20	0,47	0,69	0,53	0,31	0,45	0,60	0,55	0,40	0,86	0,79	0,14	0,22	1,00	0,89	0,00	0,11				

\* Não houve estimativas para a classe analisada.

AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

### 4.1.3 Avaliação dos resultados obtidos pelo método ATRAJ

De forma similar ao método ATRANS, a partir da amostragem, foram geradas as matrizes de concordância entre as imagens classificadas de referência e as estimadas. Os índices avaliativos foram calculados e são exibidos na Tabela 4.4.

De maneira geral, o método ATRAJ também apresentou bons índices de concordância entre as classificações de referência e suas respectivas estimativas. Analisando os resultados obtidos nas estimativas realizadas pelo ATRAJ, nota-se que os valores de índice  $CG$  superior ou igual a 0,66 em todas as estimativas analisadas.

Tabela 4.4 - Índices de avaliação das estimativas pelo método ATRAJ realizadas sobre imagens Sentinel-2/MSI classificadas.

Data de Referência	MAXVER	RF	SVM
	Concordância Global ( $CG$ )		
11 julho 17	0,68	0,74	0,63
16 julho 17	0,68	0,66	0,73
26 julho 17	0,68 <sup>1</sup>	0,67	0,67

(1) Nenhum pixel da classe AC foi estimado.

Fonte: Produção do autor.

Na Tabela 4.5, é possível observar a concordância parcial ( $CP$ ), o índice de representação de classe ( $RC$ ) e as taxas de erro ( $ID$  e  $EA$ ) cometidos nas estimativas pelo método ATRAJ ao variarem-se as classificações das imagens Sentinel-2/MSI analisadas. Assim como o método ATRANS, as classes Formação Florestal, Corpo D'água e Pasto Sujo apresentaram melhores índices de acurácia e menores erros. O método ATRAJ também apresentou pouca variação dos índices quando comparadas classificações de mesma data.

Entre as vantagens do método ATRAJ em relação ao método ATRANS, é que o ATRAJ foi incapaz de estimar a classe de Área de Cultivo em apenas uma das imagens classificadas (Classificação MAXVER datada de 26 de julho de 2017) ao contrário do método ATRANS onde não houver estimativas dessa classe em seis imagens. Entretanto, vale ressaltar que as estimativas apresentaram valores elevados de índice  $ID$  e  $EA$ .

De forma similar, a classe Solo Exposto foi estimada em todas as imagens classificadas pelo método ATRAJ. Na imagem datada de 26 de julho de 2017 classificada pelo método RF, anteriormente não estimado nenhum pixel para a classe Solo Exposto agora apresenta uma concordância parcial (*CP*) superior a 0,70.

Tabela 4.5 - Índices relativos ao método ATRAJ para as classes de uso e cobertura da terra em estudo sobre imagens Sentinel-2/MSI classificadas.

Método ATRAJ																													
Concordância Parcial (CP), Índice de Representação de Classe (RC), Índice de Desacordo (ID) e Erro de Atribuição de Classe (EA)																													
Classificação		FL				AC				PS				PL				AP				SE				CA			
Método	Data de Referência	CP	RC	ID	EA	CP	RC	ID	EA	CP	RC	ID	EA	CP	RC	ID	EA	CP	RC	ID	EA	CP	RC	ID	EA	CP	RC	ID	EA
MAXVER	11 julho 17	0,81	1,00	0,19	0,00	0,31	0,65	0,69	0,35	0,84	0,78	0,16	0,22	0,63	0,50	0,37	0,50	0,71	0,41	0,29	0,59	0,47	1,00	0,53	0,00	0,81	1,00	0,19	0,00
	16 julho 17	0,74	1,00	0,26	0,00	0,04	0,57	0,96	0,43	0,70	0,72	0,30	0,28	0,68	0,43	0,32	0,58	0,80	0,61	0,20	0,39	0,81	1,00	0,19	0,00	0,74	1,00	0,26	0,00
	26 julho 17	0,94	1,00	0,06	0,00	*				0,77	0,86	0,23	0,14	0,73	0,42	0,27	0,58	0,81	0,47	0,19	0,53	0,50	1,00	0,50	0,00	0,94	1,00	0,06	0,00
RF	11 julho 17	0,81	1,00	0,19	0,00	0,33	0,70	0,67	0,30	0,83	0,77	0,17	0,23	0,49	0,64	0,51	0,36	0,82	0,54	0,18	0,46	0,89	0,88	0,11	0,12	0,81	1,00	0,19	0,00
	16 julho 17	0,85	1,00	0,15	0,00	0,05	0,63	0,95	0,38	0,87	0,77	0,13	0,23	0,72	0,37	0,28	0,63	0,46	0,57	0,54	0,43	0,68	0,80	0,32	0,20	0,85	1,00	0,15	0,00
	26 julho 17	0,85	1,00	0,15	0,00	0,00	-	1,00	-	0,76	0,80	0,24	0,20	0,59	0,46	0,41	0,54	0,79	0,40	0,21	0,60	0,73	0,96	0,27	0,04	0,85	1,00	0,15	0,00
SVM	11 julho 17	0,78	1,00	0,22	0,00	0,28	0,61	0,72	0,39	0,72	0,79	0,28	0,21	0,49	0,49	0,51	0,51	0,72	0,43	0,28	0,57	0,44	1,00	0,56	0,00	0,78	1,00	0,22	0,00
	16 julho 17	0,85	1,00	0,15	0,00	0,11	0,85	0,89	0,15	0,73	0,82	0,27	0,18	0,80	0,46	0,20	0,54	0,75	0,69	0,25	0,31	0,84	0,97	0,16	0,03	0,85	1,00	0,15	0,00
	26 julho 17	0,91	1,00	0,09	0,00	0,13	0,76	0,87	0,24	0,67	0,82	0,33	0,18	0,61	0,59	0,39	0,41	0,80	0,40	0,20	0,60	0,61	1,00	0,39	0,00	0,91	1,00	0,09	0,00
Média		0,84	1,00	0,16	0,00	0,18	0,68	0,82	0,32	0,77	0,79	0,23	0,21	0,64	0,48	0,36	0,52	0,74	0,50	0,26	0,50	0,66	0,96	0,34	0,04	0,84	1,00	0,16	0,00

\* Não houve estimativas para a classe analisada.

AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

#### 4.1.4 Avaliação comparativa entre os métodos propostos

Ambos os métodos ATRANS e ATRAJ apresentaram valores similares de coeficiente Kappa e exatidão global com poucas variações notáveis entre os dois métodos. Mais de 55% dos pixels estimados em cada uma das imagens individualmente foram estimados em concordância com as classificações de referência. Na Tabela 4.6, são apresentados os valores-P dos resultados dos testes estatísticos Z à um nível de significância de 5% (com  $H_0$ : Kappa Atrans – Kappa Atraj = 0) comparando os índices Kappa entre os métodos de estimativa aplicados (valores em negrito representam rejeição da hipótese  $H_0$ ).

Tabela 4.6 - Valores-P resultantes da aplicação do teste estatístico Z comparativo entre os métodos de estimativa analisados no estudo de caso I.

Data de Referência	MAXVER	RF	SVM
	Valor-P		
11 julho 17	0,39 (1)	0,17 (1)	<b>0,01 (1)</b>
16 julho 17	0,48 (1)	0,43 (2)	<b>0,01 (2)</b>
26 julho 17	0,06 (1)	<b>0,00 (2)</b>	0,30 (1)

(1)  $H_1$ : Kappa Atrans – Kappa Atraj > 0

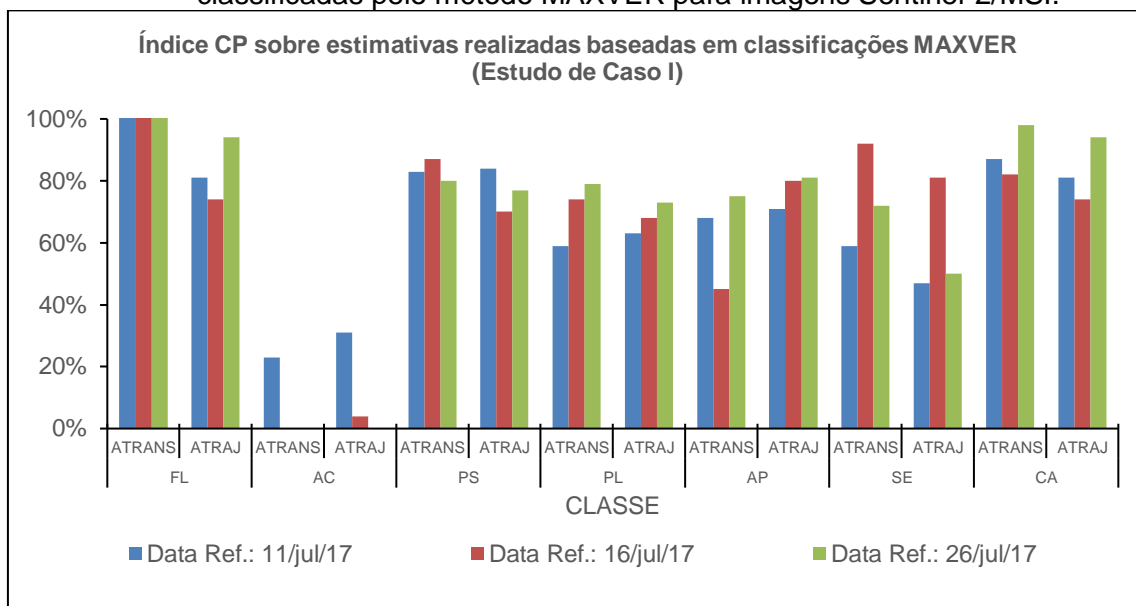
(2)  $H_1$ : Kappa Atrans – Kappa Atraj < 0

Fonte: Produção do autor.

De maneira geral, aceitou-se a hipótese  $H_0$ , ou seja, os índices Kappa não são significativamente diferentes. Entretanto os índices Kappa obtidos a partir dos produtos das estimativas pelo método ATRANS são significativamente menores do que os estimados pelo método ATRAJ para classificação RF datada de 26 de julho de 2017 e classificação SVM datada de 16 de julho de 2017. Enquanto o índice Kappa obtido na estimativa pelo método ATRAJ do produto da classificação SVM datada de 11 de julho de 2017 é significativamente maior do que o obtido na estimativa pelo método ATRANS.

As maiores diferenças entre os métodos foram observadas nas classes de Área de Cultivo e Solo Exposto. Principalmente pois, como descrito anteriormente, o método ATRAJ estimou tais classes quando o método ATRANS não foi capaz de fazê-lo. As comparações entre os índices  $CP$  por classe são exibidas na Figura 4.3, Figura 4.4 e Figura 4.5 e os índices  $ID$  na Figura 4.6, Figura 4.7 e Figura 4.8.

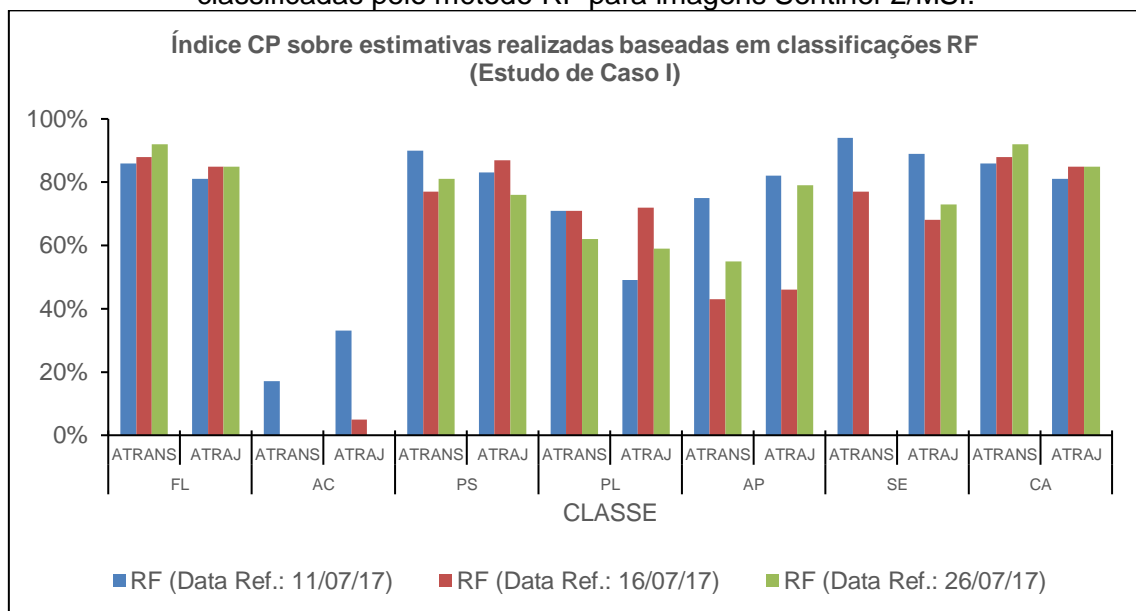
Figura 4.3 - Concordância parcial para as estimativas realizadas sobre imagens classificadas pelo método MAXVER para imagens Sentinel-2/MSI.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

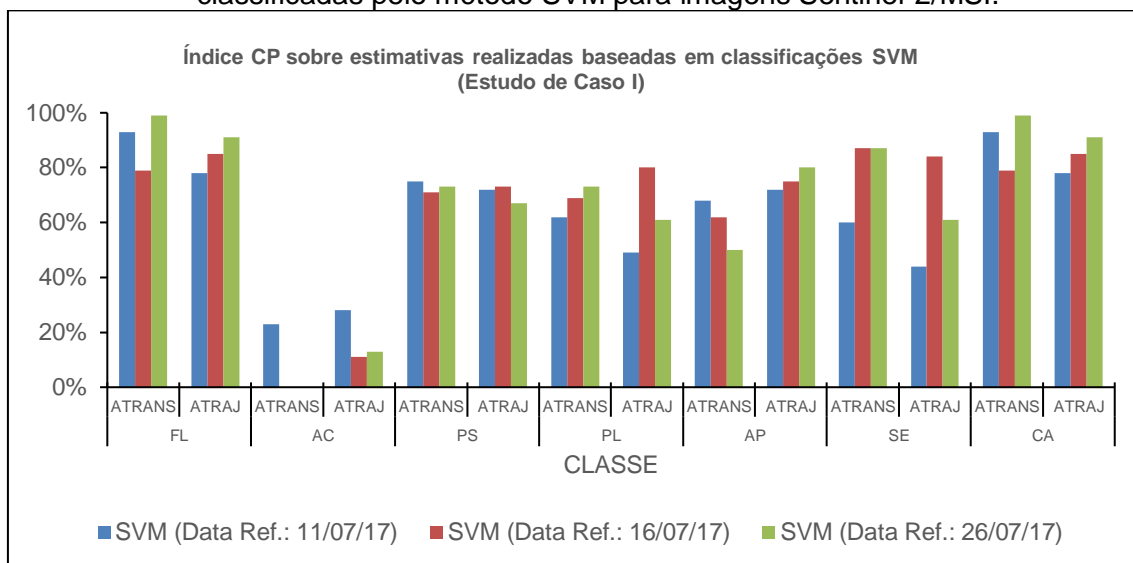
Figura 4.4 - Concordância parcial para as estimativas realizadas sobre imagens classificadas pelo método RF para imagens Sentinel-2/MSI.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

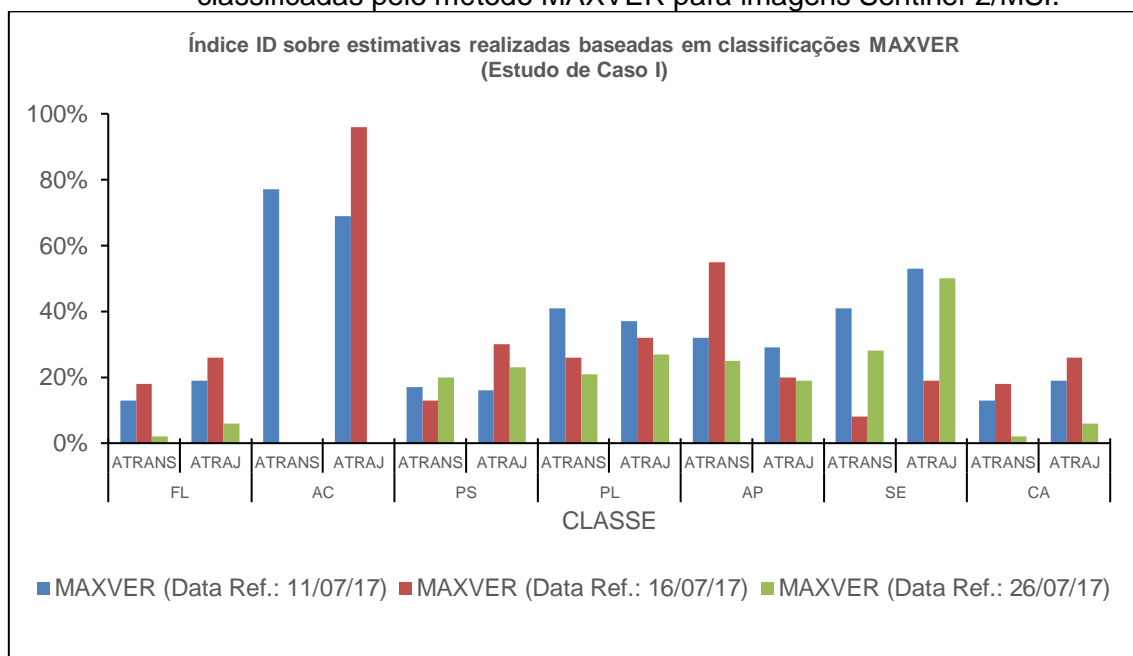
Figura 4.5 – Concordância parcial para as estimativas realizadas sobre imagens classificadas pelo método SVM para imagens Sentinel-2/MSI.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

Figura 4.6 - Índice de desacordo para as estimativas realizadas sobre imagens classificadas pelo método MAXVER para imagens Sentinel-2/MSI.

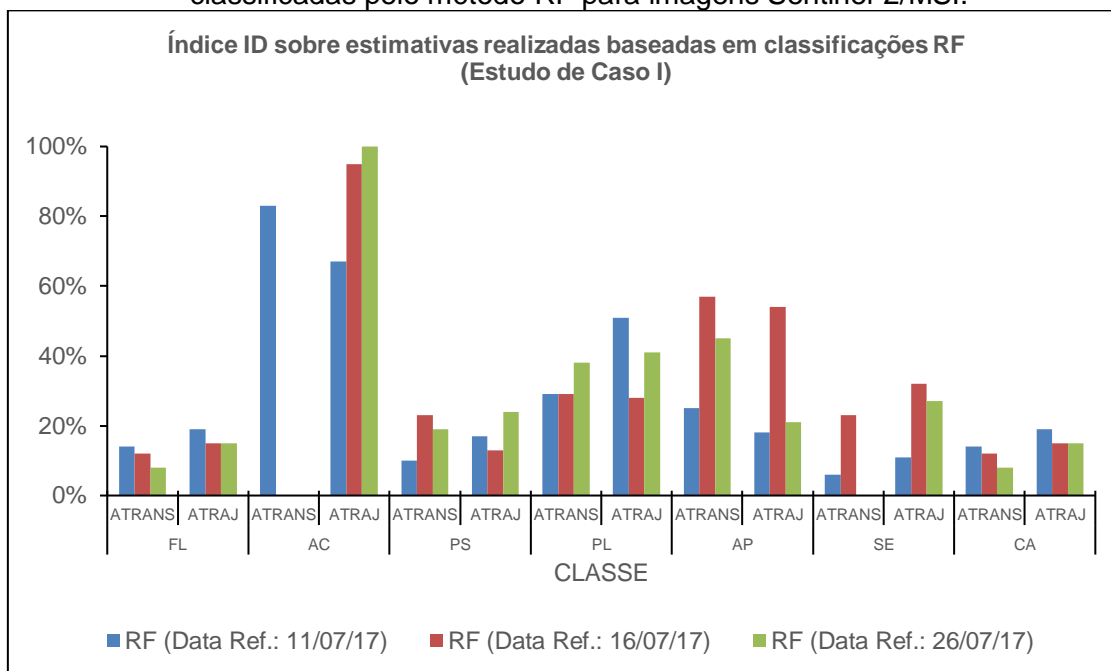


AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.



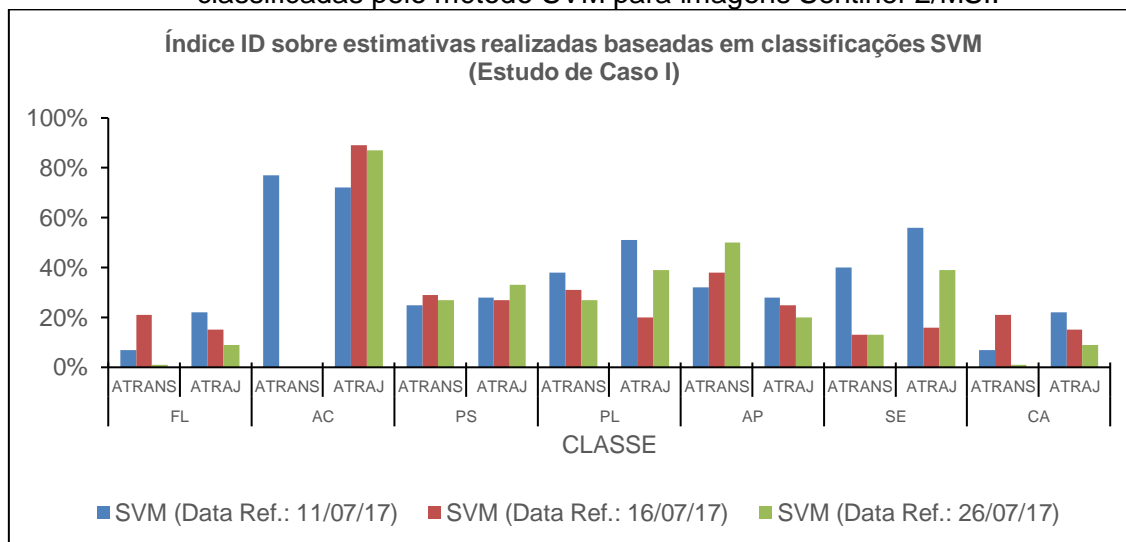
Figura 4.7 - Índice de desacordo para as estimativas realizadas sobre imagens classificadas pelo método RF para imagens Sentinel-2/MSI.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

Figura 4.8 - Índice de desacordo para as estimativas realizadas sobre imagens classificadas pelo método SVM para imagens Sentinel-2/MSI.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

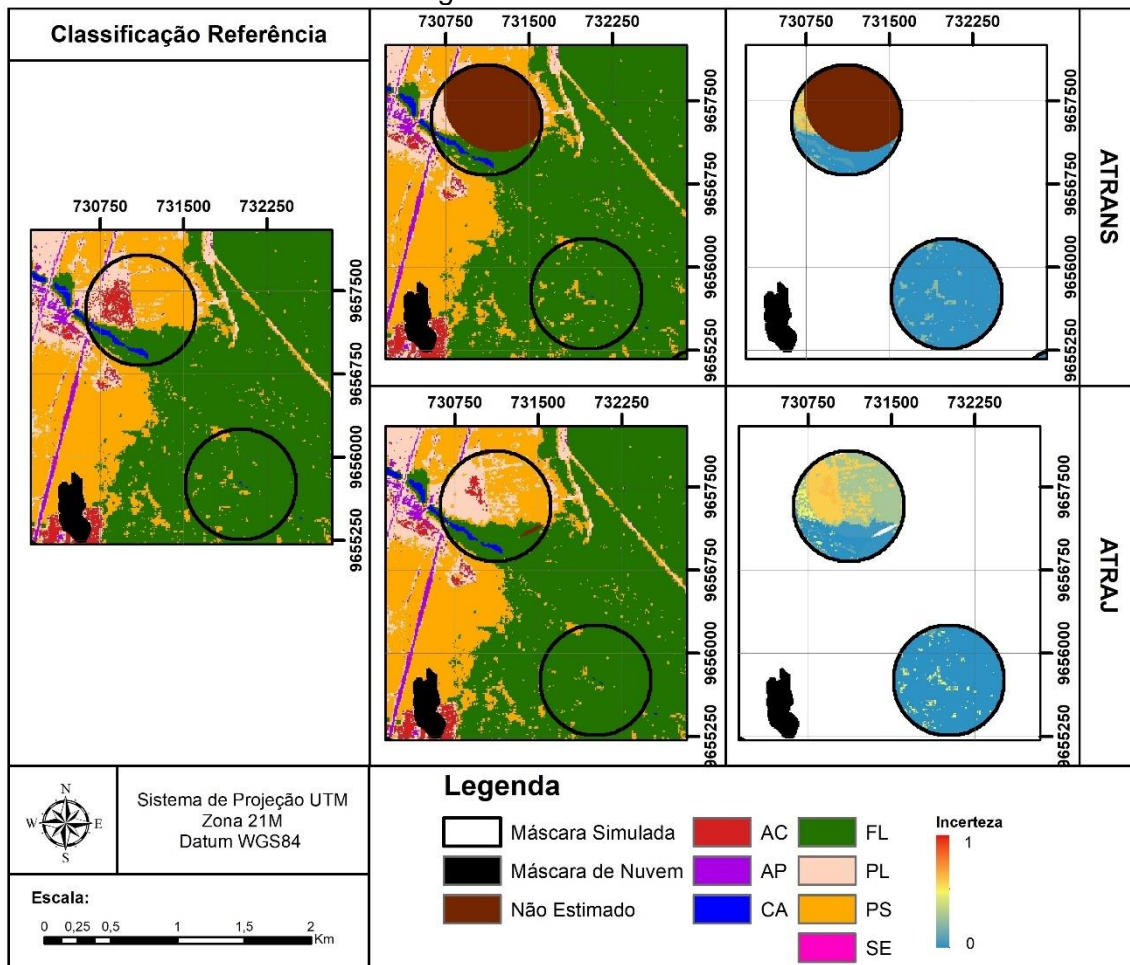
Vale ressaltar que apesar de ser capaz de estimar a classe de Área de Cultivo em mais imagens, o método ATRAJ apresentou altos valores de índice de desacordo (*ID*) chegando a 100% na imagem referente ao dia 26 de julho de 2017 obtida pela classificação RF (Figura 4.7). Outra classe que merece destaque é Área em Pousio que apresentou um aumento do índice *CP* da classe na maioria das classificações analisadas, chegando a, aproximadamente, 81% considerando a classificação MAXVER de 26 de julho de 2017. Por outro lado, a classe de Solo Exposto apresentou índices *CP* menores em todas as classificações consideradas.

Assim como destacado anteriormente, esse comportamento está diretamente relacionado com a presença de ruídos na classificação de referência, principalmente entre as classes de Área em Pousio e Área de Cultivo. Esses ruídos influenciaram no levantamento das ocorrências tanto dos transiogramas quanto de trajetórias na qual foram baseadas as estimativas. A classe de Pasto Limpo também sofreu efeitos da erros de classificação apresentando valores de índice *CP* de classe ligeiramente menores em algumas classificações quando comparado a estimativa pelo método ATRAJ à estimativa pelo método ATRANS. O comportamento observado nessas classes é ressaltado quando analisadas as estatísticas das incertezas geradas pelo método ATRAJ presentes no Apêndice G.

É possível notar que as classes com menor suscetibilidade a mudanças entre os períodos analisados e menor confusão nas classificações de referência apresentam valores de incerteza médios menores. Destacam-se nesse caso as classes de Formação Florestal e Corpo D'água. De maneira análoga, as classes com maior tendência a mudanças e maior confusão nas classificações de referência apresentam maiores valores de incerteza média. São exemplos as classes Área de Cultivo, Área em Pousio e Solo Exposto. A Figura 4.9 exemplifica esse comportamento, onde as imagens correspondem aos produtos das estimativas a partir da classificação MAXVER (data referência: 16 de julho de 2017).

Outro comportamento observado são os elevados índices de acurácia de classe e valores baixos de erros em classes que apresentam pouca variabilidade temporalmente como Formação Florestal e Corpo D'água. Nesses casos, ambos métodos se mostraram eficientes nas estimativas, apresentaram baixos valores de incerteza e com pouca variação nos valores entre eles.

Figura 4.9 – Comparação entre as estimativas ATRANS e ATRAJ e suas respectivas incertezas nas imagens Sentinel-2/MSI classificadas.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

## 4.2 Estudo de caso II: Imagens Landsat-5/TM

Este estudo de caso tem por objetivo verificar a capacidade dos métodos propostos em estimar as classes de uso e cobertura da terra aplicados às imagens Landsat-5/TM descritas na Seção 3.2.2. Dessa maneira, na Seção 4.2.1, é apresentada a taxa de pixels não estimados. Enquanto nas Seções 4.2.2 e 4.2.3 são apresentados os resultados para aplicação dos métodos ATRANS e ATRAJ, respectivamente. Os mapas que representam os produtos das estimativas para ambos os métodos desse estudo de caso encontram-se no Apêndice F.

### 4.2.1 Taxa de pixels não estimados

Assim como no primeiro estudo de caso, foi observado que o método de análise das trajetórias (ATRAJ) apresentou uma menor taxa de pixels não estimados, ou seja, pixels que continuaram com valores faltantes. A Tabela 4.7 descreve, em resumo, os valores em porcentagem de pixels não estimados para cada método, classificação e imagens adotados nesse estudo de caso.

Tabela 4.7 - Taxa de pixels não estimados sobre imagens Landsat-5 / TM classificadas.

Método	Data de Referência		
	%		
	21 junho 07	23 junho 08	29 junho 10
ATRAJ	2,1	2,1	2,1
ATTRANS	11,3	11,3	13,2

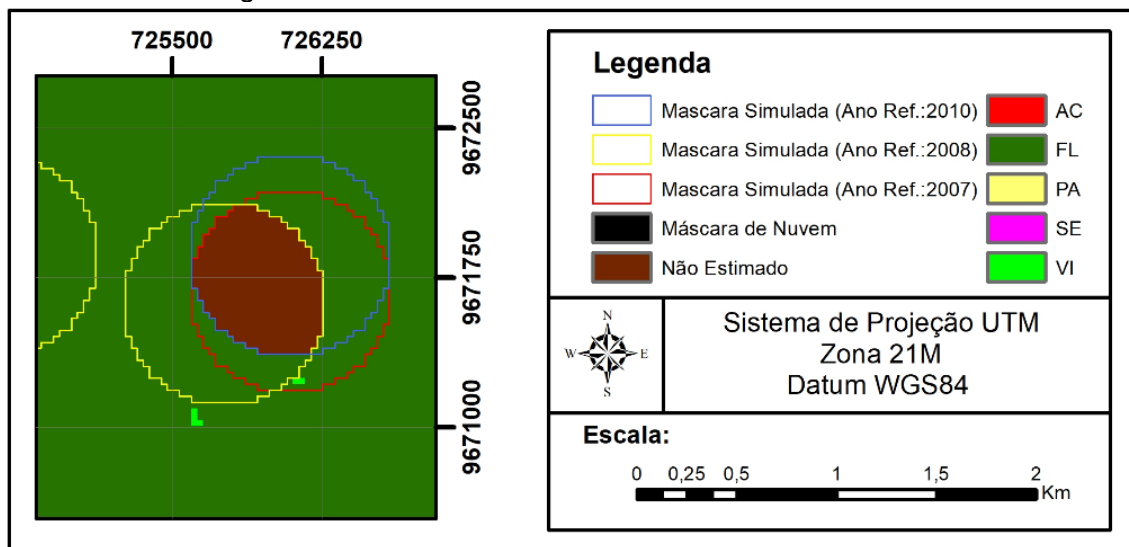
Fonte: Produção do autor.

Quando aplicado o método ATRAJ, 2,1% do número total de pixels referentes às máscaras simuladas não foram estimados para cada uma das imagens em todas as classificações analisadas. Assim como no primeiro estudo de casos, esse valor corresponde ao número de pixels sobrepostos simultaneamente em todas as máscaras simuladas da série, onde há inexistência de valores necessários para a estimativa. Neste estudo de caso, o método também somente não conseguiu realizar estimativas na ausência total de informação de classe ao longo de toda série. Um exemplo demonstrando a situação descrita é ilustrado na Figura 4.10, onde as imagens correspondem ao produto da estimativa pelo

método ATRAJ a partir da classificação SVM (data referência: 28 de junho de 2010).

Similarmente ao caso de estudo I, o método de análise dos transiogramas (ATRANS) possui taxas de pixels não estimados maiores que as do método ATRAJ, variando entre 11,3% e 13,2% nos cenários analisados. As mesmas situações observadas no primeiro estudo de caso se repetiram nesse para áreas que não foram estimadas. Assim, um exemplo demonstrando essas situações é ilustrado na Figura 4.11, onde as imagens correspondem aos produtos das estimativas pelo método ATRANS a partir da classificação SVM.

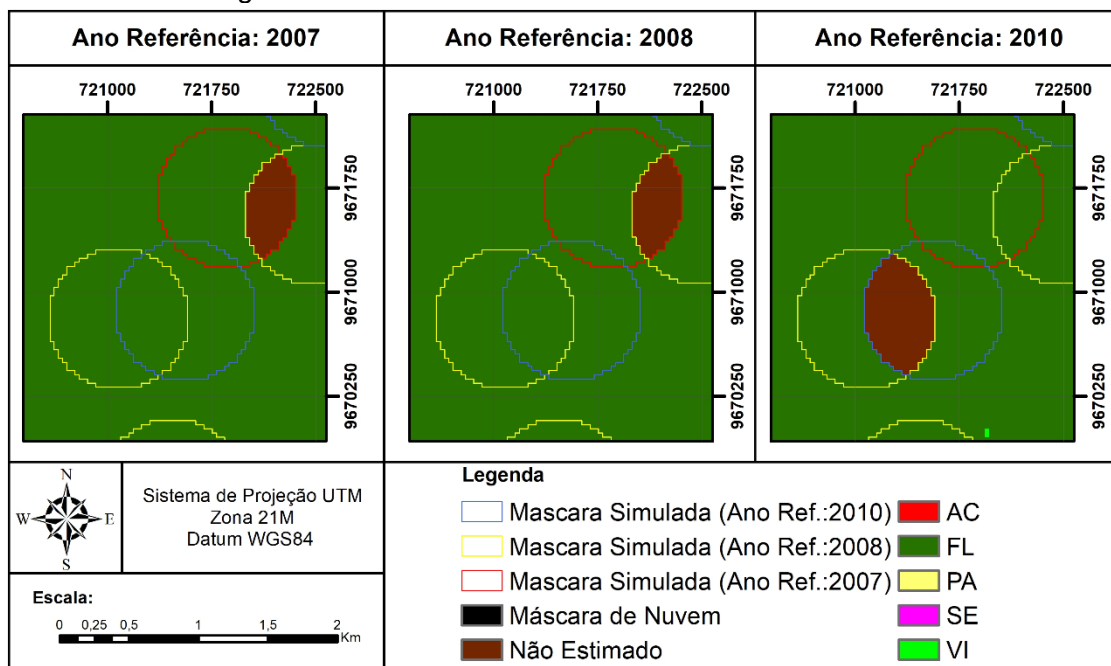
Figura 4.10 – Exemplo de área com pixels não estimados pelo método ATRAJ em imagens classificadas do Landsat-5/TM.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

Figura 4.11 – Exemplo de área com pixels não estimados pelo método ATRANS em imagens classificadas do Landsat-5/TM.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

#### 4.2.2 Avaliação dos resultados obtidos pelo método ATRANS

De maneira similar ao processo de amostragem realizada no primeiro estudo de caso, foram computadas as matrizes de concordância entre as imagens classificadas de referência e as respectivas estimativas. A partir das mesmas, foi calculado o índice de concordância global (*CG*) correspondente a cada uma das estimativas geradas a partir do método ATRANS são exibidos na Tabela 4.8.

De maneira geral, o método apresentou baixos índices de concordância entre as classificações de referência e suas respectivas estimativas. Analisando os resultados obtidos nas estimativas realizadas pelo método ATRANS aplicado às imagens Landsat-5/TM classificadas, nota-se os valores de concordância global (*CG*) superiores a 0,37. Tais valores podem ser visualizados na Tabela 4.8.

A partir da Tabela 4.9 é possível analisar os índices avaliativos das estimativas pelo método ATRANS ao variarem-se as classificações das imagens Landsat-5/TM analisadas. Nota-se que as classes de Formação Florestal e Pastagem

apresentaram bons valores dos índices avaliativos. Além disso, houve pouca variação entre os índices dessas classes quando comparadas imagens classificadas de mesma data. Entretanto, as classes de Vegetação Secundária em Estágio Inicial e Solo Exposto apresentaram índices muito variáveis com baixos valores de concordância parcial e elevados valores de índice de desacordo e erro por atribuição de classe. A classe Formação Florestal apresentou o maior valor médio de índice de concordância parcial e, conseqüentemente, o menor valor de índice de desacordo atingindo 0,98 e 0,02, respectivamente.

Tabela 4.8 - Índices de avaliação das estimativas pelo método ATRANS realizadas sobre imagens Landsat-5/TM classificadas.

Data de Referência	MAXVER	RF	SVM
	Concordância Global (CG)		
21 junho 07	0,57 <sup>1</sup>	0,39 <sup>1</sup>	0,43 <sup>1,3</sup>
23 junho 08	0,40 <sup>1,2</sup>	0,37 <sup>1,2,3</sup>	0,40 <sup>1,3</sup>
28 junho 10	0,45 <sup>1</sup>	0,41 <sup>1</sup>	0,37 <sup>1,3</sup>

(1) Nenhum pixel da classe AC foi estimado.

(2) Nenhum pixel da classe SE foi estimado.

(3) Nenhum pixel da classe VI foi estimado.

AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

Assim como no primeiro estudo de caso, ao se analisar a Tabela 4.9 e os transiogramas utilizados para as estimativas (Apêndice D), nota-se que algumas classes não foram capazes de serem estimadas. A classe Área de Cultivo não foi predominante em nenhum dos transiogramas apresentados, resultando na não estimativa de pixel para mesma em nenhuma das imagens. A mesma situação foi encontrada nas classes de Vegetação Secundária em Estágio Inicial e Solo Exposto em algumas das imagens analisadas. Iguamente ao estudo de caso com as imagens Sentinel-2/MSI, as classes cujo método apresentou maior dificuldade em estimar e, conseqüente, gerou as maiores incertezas são aquelas que apresentaram maior confusão nas classificações de referência.

Tabela 4.9 - Índices relativos ao método ATRANS para as classes de uso e cobertura da terra em estudo sobre imagens Landsat-5/TM classificadas.

Método ATRANS																					
Concordância Parcial (CP), Índice de Representação de Classe (RC), Índice de Desacordo (ID) e Erro de Atribuição de Classe (EA)																					
Classificação		FL				VI				PA				AC				SE			
Método	Ano de Referência	CP	RC	ID	EA	CP	RC	ID	EA	CP	RC	ID	EA	CP	RC	ID	EA	CP	RC	ID	EA
MAXVER	2007	1,00	0,75	0,00	0,25	0,53	0,42	0,47	0,58	0,67	0,45	0,33	0,55	*				0,67	0,71	0,33	0,29
	2008	0,93	0,67	0,07	0,33	0,27	0,57	0,73	0,43	0,80	0,26	0,20	0,74	*				*			
	2010	1,00	0,65	0,00	0,35	0,47	0,58	0,53	0,42	0,80	0,30	0,20	0,70	*				0,00	-	1,00	-
RF	2007	1,00	0,63	0,00	0,38	0,27	0,40	0,73	0,60	0,67	0,26	0,33	0,74	*				0,00	0,00	1,00	1,00
	2008	1,00	0,63	0,00	0,38	*				0,87	0,25	0,13	0,75	*				*			
	2010	0,93	0,56	0,07	0,44	0,33	0,56	0,67	0,44	0,80	0,31	0,20	0,69	*				0,00	0,00	1,00	1,00
SVM	2007	1,00	0,56	0,00	0,44	*				0,60	0,29	0,40	0,71	*				0,53	0,47	0,47	0,53
	2008	1,00	0,43	0,00	0,57	*				0,40	0,33	0,60	0,67	*				0,60	0,41	0,40	0,59
	2010	0,93	0,67	0,07	0,33	*				0,93	0,26	0,07	0,74	*				0,00	-	1,00	-
Média		0,98	0,61	0,02	0,39	0,37	0,51	0,63	0,49	0,73	0,30	0,27	0,70	-				0,36	0,40	0,64	0,60

\* Não houve estimativas para a classe analisada.

AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.



### 4.2.3 Avaliação dos resultados obtidos pelo método ATRAJ

De forma similar ao método anterior, a partir da amostragem, foram geradas as matrizes de concordância entre as imagens classificadas de referência e as estimadas. A partir das mesmas, foram calculados os índices de acurácia. Na Tabela 4.10, é exibido o índice de concordância global correspondente a cada uma das estimativas geradas.

Tabela 4.10 - Índices de avaliação das estimativas pelo método ATRAJ realizadas sobre imagens Landsat-5/TM classificadas.

Data de Referência	MAXVER	RF	SVM
	Concordância Global (CG)		
21 junho 07	0,51	0,52 <sup>1</sup>	0,41
23 junho 08	0,47 <sup>1</sup>	0,45 <sup>1</sup>	0,49 <sup>1</sup>
28 junho 10	0,52 <sup>1</sup>	0,45 <sup>1</sup>	0,49 <sup>1</sup>

(1) Nenhum pixel da classe AC foi estimado.

AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

De maneira geral, o método ATRAJ também apresentou baixos índices de concordância entre as classificações de referência e suas respectivas estimativas. As taxas de acertos de classes foram ligeiramente superiores aos obtidos do método ATRANS. Analisando os resultados obtidos nas estimativas realizadas pelo método ATRAJ, nota-se que os valores de exatidão global superior a 0,41 em todas as estimativas analisadas.

Na Tabela 4.11, é possível analisar os índices avaliativos das estimativas pelo método ATRAJ ao se variarem as classificações das imagens Landsat-5/TM analisadas. Assim como no primeiro estudo de caso, método ATRAJ foi capaz de estimar a classe de Área de Cultivo em duas das imagens classificadas ao contrário do método ATRANS onde não houve estimativas dessa classe em nenhuma das nove imagens. Entretanto, vale ressaltar que as estimativas apresentaram valores baixos índices de concordância parcial e elevado índice de desacordo.

Analisando a média dos índices avaliativos, a classe Formação Florestal apresentou o melhor índice *CP* e, por consequência, o menor índice *ID* registrando 0,99 e 0,01, respectivamente. O método ATRAJ também apresentou pouca variação dos índices quando comparadas classificações de mesma data. A classe Pastagem apresentou, em média, um bom índice *CP*.

Tabela 4.11 - Índices relativos ao método ATRAJ para as classes de uso e cobertura da terra em estudo sobre imagens Landsat-5/TM classificadas.

Método ATRAJ																					
Concordância Parcial (CP), Índice de Representação de Classe (RC), Índice de Desacordo (ID) e Erro de Atribuição de Classe (EA)																					
Classificação		FL				VI				PA				AC				SE			
Método	Ano de Referência	CP	RC	ID	EA	CP	RC	ID	EA	CP	RC	ID	EA	CP	RC	ID	EA	CP	RC	ID	EA
MAXVER	2007	1,00	0,71	0,00	0,29	0,40	0,60	0,60	0,40	0,80	0,31	0,20	0,69	0,00	-	1,00	-	0,33	1,00	0,67	0,00
	2008	0,93	0,64	0,07	0,36	0,20	0,60	0,80	0,40	0,80	0,38	0,20	0,63	*				0,40	0,38	0,60	0,63
	2010	1,00	0,68	0,00	0,32	0,33	0,42	0,67	0,58	0,93	0,39	0,07	0,61	*				0,33	1,00	0,67	0,00
RF	2007	1,00	0,68	0,00	0,32	0,27	0,57	0,73	0,43	0,93	0,36	0,07	0,64	*				0,40	0,86	0,60	0,14
	2008	1,00	0,65	0,00	0,35	0,20	0,50	0,80	0,50	0,73	0,32	0,27	0,68	*				0,33	0,42	0,67	0,58
	2010	1,00	0,58	0,00	0,42	0,33	0,63	0,67	0,38	0,87	0,33	0,13	0,68	*				0,07	1,00	0,93	0,00
SVM	2007	1,00	0,63	0,00	0,38	0,13	0,40	0,87	0,60	0,80	0,30	0,20	0,70	0,00	-	1,00	-	0,13	0,33	0,87	0,67
	2008	0,93	0,64	0,07	0,36	0,13	1,00	0,87	0,00	0,80	0,41	0,20	0,59	*				0,60	0,41	0,40	0,59
	2010	1,00	0,58	0,00	0,42	0,07	1,00	0,93	0,00	0,67	0,31	0,33	0,69	*				0,73	0,69	0,27	0,31
Média		0,99	0,64	0,01	0,36	0,23	0,63	0,77	0,37	0,81	0,35	0,19	0,65	0,00	-	1,00	-	0,37	0,68	0,63	0,32

\* Não houve estimativas para a classe analisada.

AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

#### 4.2.4 Avaliação comparativa entre os métodos propostos

Assim como no primeiro estudo de caso, ambos métodos apresentaram valores similares de coeficiente Kappa e exatidão global com poucas variações notáveis entre eles. Mais de 87% dos pixels estimados em cada uma das imagens individualmente foram estimados em concordância com as classificações de referência. Na Tabela 4.12 são apresentados os valores-P dos resultados dos testes estatísticos Z à um nível de significância de 5% (com  $H_0$ :  $Kappa_{Atrans} - Kappa_{Atraj} = 0$ ) comparando os índices Kappa entre os métodos de estimativa aplicados. Em todos os casos, aceitou-se a hipótese  $H_0$ , ou seja, os índices Kappa não são significativamente diferentes.

Tabela 4.12 - Valores-P resultantes da aplicação do teste estatístico Z comparativo entre os métodos de estimativa analisados no estudo de caso II.

Data de Referência	MAXVER	RF	SVM
	Valor-P		
21 junho 07	0,19 (1)	0,05 (2)	0,43 (1)
23 junho 08	0,23 (2)	0,20 (2)	0,12 (2)
28 junho 10	0,21 (2)	0,31 (2)	0,10 (2)

(1)  $H_1$ :  $Kappa_{Atrans} - Kappa_{Atraj} > 0$

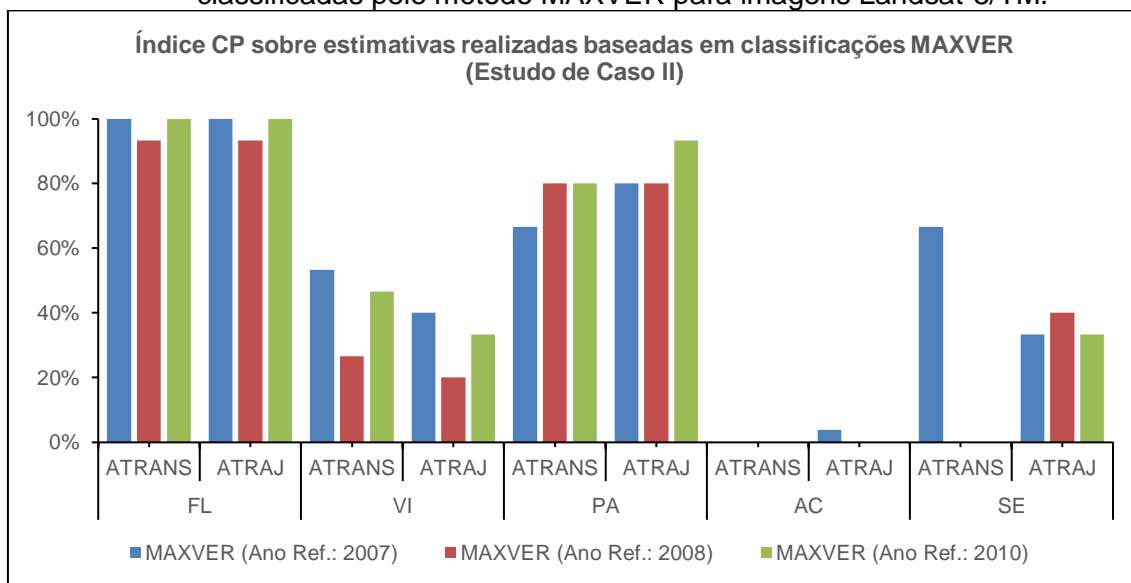
(2)  $H_1$ :  $Kappa_{Atrans} - Kappa_{Atraj} < 0$

AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

As comparações entre os índices  $CP$  por classe são exibidas na Figura 4.12, Figura 4.13 e Figura 4.14, e os índices  $ID$  na Figura 4.15, Figura 4.16 e Figura 4.17. A classe de Formação Florestal apresentou os melhores índices em todos os cenários analisados. Cabe ressaltar que não só esta é a classe dominante na área de estudo, como também a classe apresenta pouca tendência a mudança ao longo do tempo analisado. Essa classe registrou índice  $CP$  superior a 93,33% e índice  $ID$  inferior a 6,67% em todas as imagens estimadas analisadas. Os maiores índices  $ID$  e menores índices  $CP$  foram registrados nas classes Vegetação Secundária em Estágio Inicial e Solo Exposto.

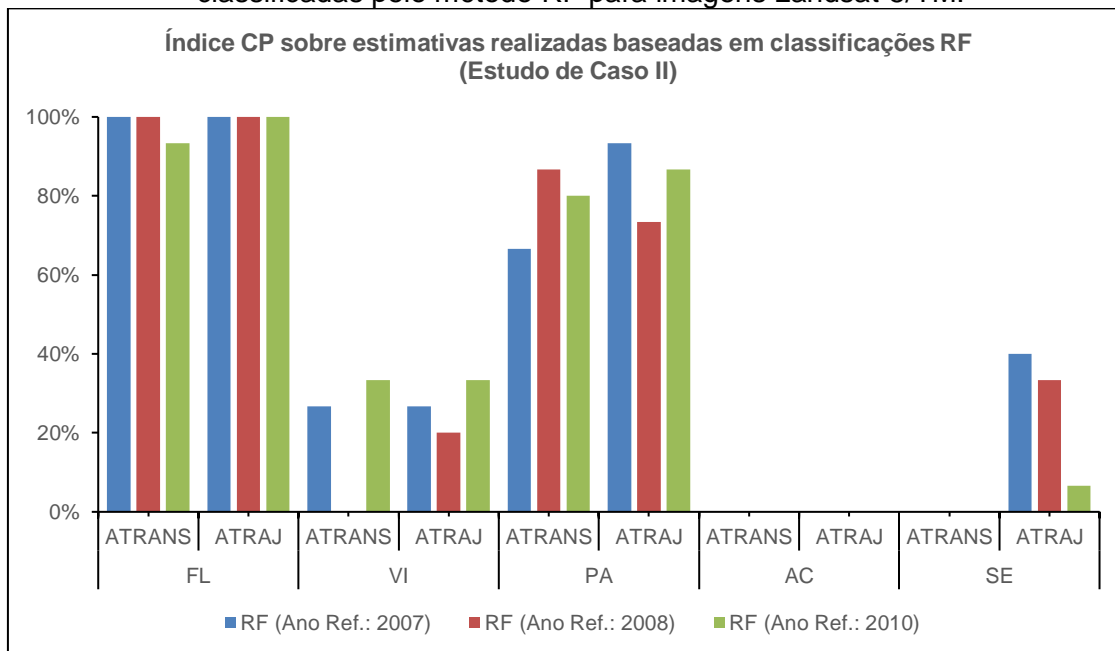
Figura 4.12 – Concordância parcial para as estimativas realizadas sobre imagens classificadas pelo método MAXVER para imagens Landsat-5/TM.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

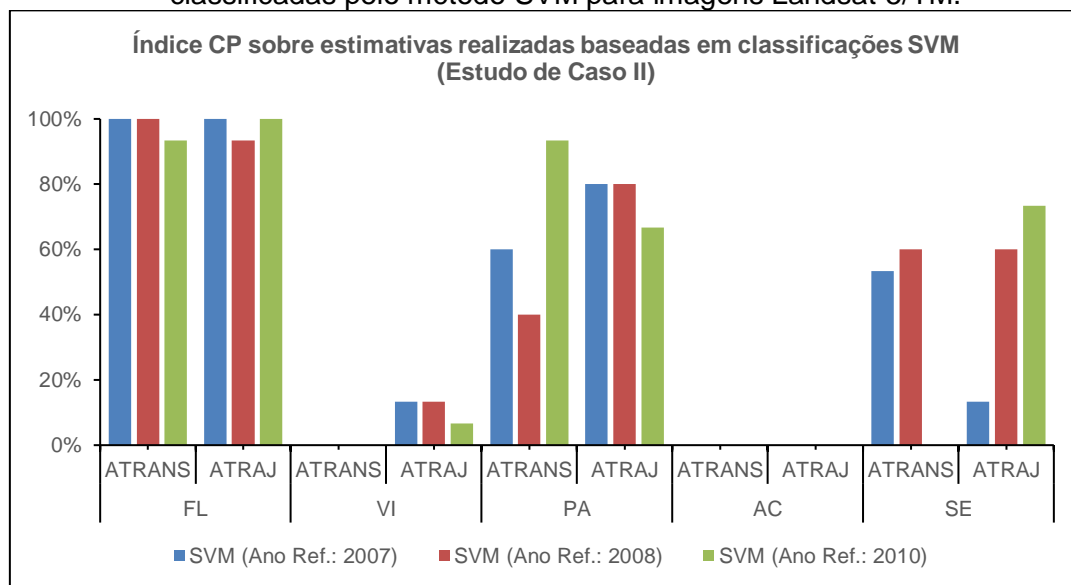
Figura 4.13 - Concordância parcial para as estimativas realizadas sobre imagens classificadas pelo método RF para imagens Landsat-5/TM.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.


Figura 4.14 - Concordância parcial para as estimativas realizadas sobre imagens classificadas pelo método SVM para imagens Landsat-5/TM.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.


Figura 4.15 – Índice de desacordo para as estimativas realizadas sobre imagens classificadas pelo método MAXVER para imagens Landsat-5/TM.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.


Figura 4.16 - Índice de desacordo para as estimativas realizadas sobre imagens classificadas pelo método RF para imagens Landsat-5/TM.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

Figura 4.17 - Índice de desacordo para as estimativas realizadas sobre imagens classificadas pelo método SVM para imagens Landsat-5/TM.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

Assim como no estudo de caso anterior, o método ATRAJ foi capaz de estimar a classe de Área de Cultivo em mais imagens quando comparado com o método ATRANS. Entretanto, o método também apresentou elevados índices de desacordo chegando a 100% na imagem referente ao dia 21 de junho de 2007 obtida pela classificação MAXVER e SVM (Figura 4.15 e Figura 4.17). Comportamento semelhante ocorreu para a classe de Vegetação Secundária em Estágio Inicial.

Foi observado que o comportamento de mudança das classes com menor tendência a alteração (Pastagem e Área Cultivada) e levantado através dos transiogramas (Apêndice D) e das trajetórias, por vezes não representava o comportamento dessas mesmas classes em menores escalas, ou seja, em certas áreas o padrão de mudança de classes de uso e cobertura da terra não era o mesmo que a maior parte na região de estudo. Um exemplo desse comportamento é ilustrado na Figura 4.18 em que as imagens correspondem classificação RF. Ao analisar a Tabela 4.13 e Tabela D.5 simultaneamente, nota-se que a tendência é a estimativa para pixels presentes na área indicada pela seta é ser atribuída à classe Pastagem para o método ATRANS e Solo Exposto para o método ATRAJ, dados as classes atribuídas ao mesmo pixel nas imagens de outras datas (os valores em negrito indicam a trajetória com maior número de ocorrências para cada classificação). Os pixels que na imagem classificada original no ano de referência de 2008 representam Área de Cultivo são dedicados a outras classes mesmo que o contexto de sua vizinhança não possuía as características da trajetória e transição da maioria dos pixels da região de estudo.

O comportamento observado nas classes de Solo Exposto e Pastagem é ressaltado quando analisadas as estatísticas das incertezas geradas pelo método ATRAJ presentes no Apêndice G. As classes que apresentam maiores índices de desacordo tendem a gerar maiores incertezas.

Novamente, as classes com maiores erros foram aquelas com maior probabilidade de mudanças e maior confusão nas classificações de referência apresentam maiores valores de incerteza média. São exemplos as classes Área



de Cultivo, Vegetação Secundária em Estágio Inicial e Solo Exposto. A Figura 4.19 exemplifica esse comportamento em que as imagens classificadas correspondem classificação MAXVER (data referência: 23 de junho de 2008).

Tabela 4.13 - Exemplo de trajetórias que possuíam a classe Solo Exposto atribuída na primeira e última imagens da série.


Trajetória	Classificação		
	#pixels		
	MAXVER	RF	SVM
SE-AC-SE	1768	1640	1821
SE-FL-SE	11	18	101
SE-PA-SE	1603	1038	948
SE-SE-SE	<b>3007</b>	<b>3093</b>	<b>5664</b>
SE-VI-SE	65	42	135

AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

Essas classes cuja classificação utilizada como referência já apresenta elevados erros de classificação por omissão e comissão afetaram diretamente o levantamento das mudanças de classe para ambos os métodos. Isso gerou levantamentos com baixa confiabilidade e, portanto, induzindo ao erro nas estimativas. Por isso o estudo de caso II apresentou resultado inferior ao produzido no estudo de caso I.


Figura 4.18 – Comparação entre as estimativas ATRANS e ATRAJ e suas respectivas imagens Landsat-5/TM classificadas originais.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

Figura 4.19 – Comparação entre as estimativas ATRANS e ATRAJ e suas respectivas incertezas nas imagens Landsat-5/TM classificadas.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

## 5 CONCLUSÕES E TRABALHOS FUTUROS

O objetivo central deste trabalho foi a proposição de métodos para tratamento de valores faltantes com uma abordagem pós-classificação a partir de um contexto espaço-temporal da distribuição das classes de uso e cobertura da terra. Por intermédio da análise dos transiogramas e trajetórias de classes, foram desenvolvidos dois métodos para estimativa de classes em áreas afetadas pela cobertura de nuvens e suas sombras.

De forma geral, pode-se concluir que as abordagens de estimativa de classes introduzidas neste trabalho apresentam grande potencial para tratamento de valores faltantes em séries de imagens classificadas em sensoriamento remoto. Poucos estudos são encontrados na literatura com uma abordagem pós-classificação relacionados ao problema de valores faltantes.

Assim, chegou-se à conclusão de que os métodos são efetivos, viáveis e de fácil aplicação. Além disso, mostrou-se que utilizar as classes de uso e cobertura da terra atribuídas a um pixel em períodos distintos no tempo é uma maneira eficiente de realizar a estimativa de classe sobre esse mesmo pixel quando ele apresenta um valor faltante. Além disso, ambos métodos foram capazes de computar a incerteza das estimativas geradas.

Em ambos os estudos de caso o método ATRAJ apresentou menor taxa de pixels não estimados. O método ATRANS deixou de estimar mais pixels devido natureza do método. Isso ocorre porque o método ATRANS não realiza estimativa baseado classes já estimadas e quando apresentam o um pixel com dois valores faltantes sucessivos na série. Por outro lado, o método ATRAJ só não realiza a estimativa quando não existe a ocorrência de trajetórias com a distribuição necessária na matriz de trajetórias ou quando um pixel é composto somente por valores faltantes ao longo de toda a série.

Já para avaliação dos métodos, adotou-se o índice de concordância global entre as classificações de referência e suas respectivas estimativas. No primeiro estudo de caso em que foram aplicados a imagens Sentinel-2/MSI, ambos métodos apresentaram resultados com valores de concordância global acima de 0,55. No segundo estudo de caso, em que os métodos foram aplicados a

classificações obtidas de imagens Landsat-5/TM, os resultados foram inferiores. Os valores do coeficiente global chegaram a 0,37. Foram observados três fatores que influenciaram os resultados menores: o menor número de classes de uso e cobertura da terra, índices de acurácia por classe menores nas classificações de referência e menor número de amostras devido a limitação da área de algumas classes como Área de Cultivo (AC).

Além disso, em se tratando de diferença significativa entre os métodos propostos, houve pouca variação significativa dos índices no primeiro estudo de caso, sendo o método ATRAJ significativamente maior em três das nove classificações analisadas. Enquanto no segundo estudo de caso, não houve diferença significativa entre os métodos proposto. Isto está relacionado ao tamanho da série, pois quanto menor a série mais similar o método ATRAJ fica do método ATRANS (visto que considerando-se uma série composta somente de duas imagens os métodos serão idênticos).

Ambos os métodos propostos se mostraram mais eficientes nas estimativas de classes que apresentaram menores erros de classificação na imagem de referência. Enquanto estimativas realizadas sobre classes que apresentaram menores acurácias por classe nas classificações de referência geraram estimativas com maiores valores de incerteza.

Tornou-se claro, também, a necessidade de as estimativas partirem de classificações com elevados índices de acurácia global e por classe. Ambos os estudos de caso apresentaram maiores índices de erro nas classes de uso e cobertura da terra com maior tendência a mudança dado o tempo analisado. No primeiro estudo de caso destacam-se as classes de Área de Cultivo, Área em Pousio, Pasto Limpo e Solo Exposto. Enquanto no segundo estudo de caso, destacam-se as classes de Área de Cultivo e Solo Exposto. Por isso, certas vezes essas classes sequer foram estimadas pelos métodos.

Com base nas descobertas apresentadas neste estudo, como trabalhos futuros, sugerem-se:

- aplicação em imagens classificadas com máscaras de nuvens e sombras de nuvens não-simuladas;

- estudos para análise de outras fontes de erros responsáveis pelos baixos valores de acurácia encontrados;
- análise do comportamento dos métodos diante de classificações com menos ruídos (aplicação de edição pós-classificação ou classificações por regiões);
- estudo de cenários com número de classes variáveis ao longo da série analisada;
- estudo da influência do número de imagens classificadas que compõem a série sobre os métodos de estimativa;
- estudo para introdução do contexto dos pixels da vizinhança nas estimativas;
- otimização dos algoritmos gerados;
- combinação de imagens obtidas de diferentes sensores remotos para composição das séries;
- comparação entre as estimativas realizadas a partir dos métodos propostos com aquelas obtidas da classificação de imagens com estimativas radiométricas feitas com métodos tradicionais (espacial, temporal ou espaço-temporal);
- realizar um estudo Monte Carlo levando-se em conta, por exemplo, a distribuição, a quantidade e o tamanho das nuvens simuladas;
- aplicação dos métodos onde áreas que possuem outras classes de uso e cobertura da terra predominantes.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ADAM, E.; MUTANGA, O.; ODINDI, J.; ABDEL-RAHMAN, E. M. Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: evaluating the performance of random forest and support vector machines classifiers. **International Journal of Remote Sensing**, v. 35, n. 10, p. 3440–3458, 2014.
- ADDINK, E. A.; STEIN, A. A comparison of conventional and geostatistical methods to replace clouded pixels in noaa-avhrr images. **International Journal of Remote Sensing**, v. 20, n. 5, p. 961–977, 1999.
- ALMEIDA, C. A.; COUTINHO, A. C.; ESQUERDO, J. C. D. 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.
- ANEESHA SATYA, B.; SHASHI, M.; DEVA, P. Future land use land cover scenario simulation using open source GIS for the city of Warangal, Telangana, India. **Applied Geomatics**, 2020.
- ARNAUD, M.; LEROY, M. SPOT 4: a new generation of SPOT satellites. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 46, p. 205–215, 1991.
- ASNER, G. P. Cloud cover in Landsat observations of the Brazilian Amazon. **International Journal of Remote Sensing**, v. 22, n. 18, p. 3855–3862, 2001.
- BAI, T. et al. Cloud detection for high-resolution satellite imagery using machine learning and multi-feature fusion. **Remote Sensing**, v. 8, n. 9, p.715, 2016.
- BECKERS, J. M.; RIXEN, M. EOF Calculations and data filling from incomplete oceanographic datasets. **Journal of Atmospheric and Oceanic Technology**, v. 20, n. 12, p. 1839–1856, 2003.
- BRAGA, B. C.; FREITAS, C. C. C.; SANT'ANNA, S. J. S. Distâncias estocásticas e mapas de incertezas aplicados à classificação de dados de múltiplos sensores. **Revista Brasileira de Cartografia**, v. 67, n. 7, p. 1391–1411, 2015.
- BUTTLAR, J. V; ZSCHEISCHLER, J.; MAHECHA, M. D. An extended approach for spatiotemporal gapfilling: dealing with large and systematic gaps in geoscientific datasets. **Processes Geophys**, v. 21, p. 203–215, 2014.
- CHAI, D.; NEWSAM, S.; ZHANG, H. K.; QIU, Y.; HUANG, J. Cloud and cloud shadow detection in Landsat imagery based on deep convolutional neural networks. **Remote Sensing of Environment**, v. 225, p. 307–316, 2019. Elsevier.

CHEN, B.; HUANG, B.; XU, B. Multi-source remotely sensed data fusion for improving land cover classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 124, p. 27–39, 2017.

CHEN, J.; ZHU, X.; VOGELMANN, J. E.; GAO, F.; JIN, S. A simple and effective method for filling gaps in Landsat ETM+ SLC-off images. **Remote Sensing of Environment**, v. 115, n. 4, p. 1053–1064, 2011.

CHENG, Z.; CAO, S. Markov processes in modeling land use and land cover change in Tibetan Plateau. In: INTERNATIONAL CONFERENCE ON REMOTE SENSING, ENVIRONMENT AND TRANSPORTATION ENGINEERING, 2011. **Proceedings...** 2011. p.457–459.

CLARK, M. L.; AIDE, T. M.; GRAU, H. R.; RINER, G. A scalable approach to mapping annual land cover at 250 m using MODIS time series data: a case study in the Dry Chaco ecoregion of South America. **Remote Sensing of Environment**, v. 114, n. 11, p. 2816–2832, 2010.

COLDITZ, R. R.; CONRAD, C.; WEHRMANN, T.; SCHMIDT, M.; DECH, S. TiSeG: a flexible software tool for time-series generation of MODIS data utilizing the Quality Assessment Science Data Set. **IEEE Transactions on Geoscience and Remote Sensing**, v. 46, n. 10, p. 3296–3308, 2008.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data**. 2.ed. Cambridge: CRC Press, 2009.

COPPIN, P.; JONCKHEERE, I.; NACKAERTS, K.; MUYS, B.; LAMBIN, E. Digital change detection methods in ecosystem monitoring: a review. **International Journal of Remote Sensing**, v. 25, n. 9, p. 1565–1596, 2004.

DARE, P. M. Shadow analysis in high-resolution satellite imagery of urban areas. **Photogrammetric Engineering and Remote Sensing**, v. 71, n. 2, p. 169–177, 2005.

ECKARDT, R.; BERGER, C.; THIEL, C.; SCHMULLIUS, C. Removal of optically thick clouds from multi-spectral satellite images using multi-frequency SAR data. **Remote Sensing**, v. 5, n. 6, p. 2973–3006, 2013.

ESCADA, M. I. S.; AMARAL, S.; RENNÓ, C. D.; PINHEIRO, T. S. **Levantamento do uso e cobertura da terra e da rede de infra-estrutura no distrito florestal da BR-163**. São José dos Campos: INPE, 2009.

EUROPEAN SPACE AGENCY - ESA. **Mission objectives**. Disponível em: <<https://sentinel.esa.int/web/sentinel/missions/sentinel-2/mission-objectives>>. Acesso em: 12 fev. 2019a.

EUROPEAN SPACE AGENCY - ESA. **MultiSpectral Instrument (MSI) overview**. Disponível em: <<https://earth.esa.int/web/sentinel/technical-guides/sentinel-2-msi/msi-instrument>>. Acesso em: 7 fev. 2019b.



- FEARNSIDE, P. M. Brazil's Cuiabá- Santarém (BR-163) highway: the environmental cost of paving a soybean corridor through the Amazon. **Environmental Management**, v. 39, n. 5, p. 601–614, 2007.
- FEARNSIDE, P. M. The roles and movements of actors in the deforestation of Brazilian Amazonia. **Ecology and Society**, v. 13, n. 1, 2008.
- FOLEY, J. A. et al. Amazonia revealed: forest degradation and loss of ecosystem goods and services in the Amazon Basin. **Frontiers in Ecology and the Environment**, v. 5, n. 1, p. 25–32, 2007.
- GARCIA, A. S.; BALLESTER, M. V. R. Land cover and land use changes in a Brazilian Cerrado landscape: drivers, processes, and patterns. **Journal of Land Use Science**, v. 11, n. 5, p. 538–559, 2016.
- GERBER, F.; JONG, R.; SCHAEPMAN, M. E.; SCHAEPMAN-STRUB, G.; FURRER, R. Predicting missing values in spatio-temporal remote sensing data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 56, n. 5, p. 2841–2853, 2018.
- GHASEMIAN, N.; AKHOONDZADEH, M. Introducing two random forest based methods for cloud detection in remote sensing images. **Advances in Space Research**, v. 62, n. 2, p. 288–303, 2018.
- GOLYANDINA, N.; OSIPOV, E. The “Caterpillar”-SSA method for analysis of time series with missing values. **Journal of Statistical Planning and Inference**, v. 137, n. 8, p. 2642–2653, 2007.
- GÓMEZ, C.; WHITE, J. C.; WULDER, M. A. Optical remotely sensed time series data for land cover classification: a review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 116, p. 55–72, 2016.
- GOMEZ-CHOVA, L.; TUIA, D.; MOSER, G.; CAMPS-VALLS, G. Multimodal classification of remote sensing images: a review and future directions. **Proceedings of the IEEE**, v. 103, n. 9, p. 1560–1584, 2015.
- GREEN, K.; KEMPKA, D.; LACKEY, L. Using remote sensing to detect and monitor land-cover and land-use change. **Photogrammetric Engineering and Remote Sensing**, v. 60, n. 3, p. 331–337, 1994.
- GREKOUSIS, G.; MOUNTRAKIS, G.; KAVOURAS, M. An overview of 21 global and 43 regional land-cover mapping products. **International Journal of Remote Sensing**, v. 36, n. 21, p. 5309–5335, 2015.
- GUO, L. et al. Evaluation of spatio-temporal variogram models for mapping Xco2 using satellite observations: a case study in China. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 8, n. 1, p. 376–385, 2015.

- HAMAD, R.; BALZTER, H.; KOLO, K. Predicting land use/land cover changes using a CA-Markov model under two different scenarios. **Sustainability (Switzerland)**, v. 10, n. 10, p. 1–23, 2018.
- HAN, H.; YANG, C.; SONG, J. Scenario simulation and the prediction of land use and land cover change in Beijing, China. **Sustainability (Switzerland)**, v. 7, n. 4, p. 4260–4279, 2015.
- HUDSON, W. D.; RAMM, C. W. Correct formulation of the Kappa coefficient of agreement (in remote sensing). **Photogrammetric Engineering & Remote Sensing**, v. 53, n. 4, p. 421–422, 1987.
- HUETE, A. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1–2, p. 195–213, 2002.
- HUGHES, M.; HAYES, D. Automated detection of cloud and cloud shadow in single-date Landsat imagery using neural networks and spatial post-processing. **Remote Sensing**, v. 6, n. 6, p. 4907–4926, 2014.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **IBGE download**. Disponível em: <<https://mapas.ibge.gov.br/bases-e-referenciais/bases-cartograficas/cartas>>. Acesso em: 13 fev. 2019.
- INSTITUTO BRASILEIRO DO MEIO AMBIENTE E DOS RECURSOS NATURAIS RENOVÁVEIS - IBAMA. **Floresta Nacional de Tapajós Plano de manejo**: volume I informações gerais. Brasília: IBAMA, 2004.
- ISHIDA, H.; OISHI, Y.; MORITA, K.; MORIWAKI, K.; NAKAJIMA, T. Y. Development of a support vector machine based cloud detection method for MODIS with the adjustability to various conditions. **Remote Sensing of Environment**, v. 205, p. 390–407, 2018.
- JAMALI, S.; JÖNSSON, P.; EKLUNDH, L.; ARDÖ, J.; SEAQUIST, J. Detecting changes in vegetation trends using time series segmentation. **Remote Sensing of Environment**, v. 156, p. 182–195, 2015.
- JENSEN, J. R. **Sensoriamento remoto do ambiente**: uma perspectiva em recursos terrestres. 2.ed. São José dos Campos, SP: Parêntese, 2009.
- JÖNSSON, P.; EKLUNDH, L. TIMESAT: a program for analyzing time-series of satellite sensor data. **Computers & Geosciences**, v. 30, n. 8, p. 833–845, 2004.
- JUSTICE, C. O. et al. The Moderate Resolution Imaging Spectroradiometer (MODIS): Land Remote Sensing for Global Change Research. **IEEE Transactions on Geoscience and Remote Sensing**, v. 36, n. 4, p. 1228–1249, 1998.

KANSAKAR, P.; HOSSAIN, F. A review of applications of satellite earth observation data for global societal benefit and stewardship of planet Earth. **Space Policy**, v. 36, p. 46–54, 2016.

KAUTH, R. J.; THOMAS, G. S. The tasselled cap - a graphic description of the spectral-temporal development of agricultural crops as seen by Landsat. In: SYMPOSIUM ON MACHINE PROCESSING OF REMOTELY SENSED DATA. **Proceedings...** 1976. p.41–51.

KNORN, J. et al. Land cover mapping of large areas using chain classification of neighboring Landsat satellite images. **Remote Sensing of Environment**, v. 113, n. 5, p. 957–964, 2009.

KOVALSKYY, V.; ROY, D. P. The global availability of Landsat 5 TM and Landsat 7 ETM+ land surface observations and implications for global 30m Landsat data product generation. **Remote Sensing of Environment**, v. 130, p. 280–293, 2013.

KRUG, T. **Statistical approaches to the estimation of missing values arising in remotely sensed data.** [S.l.]: University of Sheffield, 1992.

LABORDE, H.; DOUZAL, V.; PIÑA, H. A. R.; MORAND, S.; CORNU, J. F. Landsat-8 cloud-free observations in wet tropical areas: a case study in South East Asia. **Remote Sensing Letters**, v. 8, n. 6, p. 537–546, 2017.

LAMBIN, E. F.; ROUNSEVELL, M. D. A.; GEIST, H. J. Are agricultural land-use models able to predict changes in land-use intensity? **Agriculture, Ecosystems and Environment**, v. 82, n. 1/3, p. 321–331, 2000.

LE HÉGARAT-MASCLE, S.; ANDRÉ, C. Use of Markov random fields for automatic cloud/shadow detection on high resolution optical images. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 64, n. 4, p. 351–366, 2009.

LGUENSAT, R.; TANDEO, P.; FABLET, R.; GARELLO, R. Spatio-temporal interpolation of sea surface temperature using high resolution remote sensing data. In: OCEANS, 2014. **Proceedings...** IEEE, 2014. p.1–4.

LI, S.; SUN, D.; YU, Y. Automatic cloud-shadow removal from flood/standing water maps using MSG/SEVIRI imagery. **International Journal of Remote Sensing**, v. 34, n. 15, p. 5487–5502, 2013.

LI, W. Transiogram: a spatial relationship measure for categorical data. **International Journal of Geographical Information Science**, v. 20, n. 6, p. 693–699, 2006.

LIN, C. H.; TSAI, P. H.; LAI, K. H.; CHEN, J. Y. Cloud removal from multitemporal satellite images using information cloning. **IEEE Transactions on Geoscience and Remote Sensing**, v. 51, n. 1, p. 232–241, 2013.

- LINO, C. O.; LIMA, M. G. R.; HUBSCHER, G. L. CBERS — An international space cooperation program. **Acta Astronautica**, v. 47, p. 559–564, 2000. Elsevier.
- LIU, H.; ZHOU, Q. Developing urban growth predictions from spatial indicators based on multi-temporal images. **Computers, Environment and Urban Systems**, v. 29, n. 5, p. 580–594, 2005.
- LIU, S.; SU, H.; CAO, G.; WANG, S.; GUAN, Q. Learning from data: a post classification method for annual land cover analysis in urban areas. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 154, p. 202–215, 2019.
- LIU, X.; WANG, M. Filling the gaps of missing data in the merged VIIRS SNPP/NOAA-20 ocean color product using the DINEOF method. **Remote Sensing**, v. 11, n. 2, e178, 2019.
- LOPES, V. C.; PARENTE, L. L.; BAUMANN, L. R. F.; MIZIARA, F.; FERREIRA, L. G. Land-use dynamics in a Brazilian agricultural frontier region, 1985-2017. **Land Use Policy**, v. 97, 104740, 2020. Elsevier.
- LU, D.; MAUSEL, P.; BRONDÍZIO, E.; MORAN, E. Change detection techniques. **International Journal of Remote Sensing**, v. 25, n. 12, p. 2365–2401, 2004.
- LU, Y.; COOPS, N. C.; HERMOSILLA, T. Estimating urban vegetation fraction across 25 cities in pan-Pacific using Landsat time series data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 126, p. 11–23, 2017.
- MAHAJAN, S.; FATANIYA, B. Cloud detection methodologies: variants and development—a review. **Complex & Intelligent Systems**, v. 6, n. 2, p. 251–261, 2020.
- MARTINS, V. S.; NOVO, E. M. L. M.; LYAPUSTIN, A.; ARAGÃO, L. E. O. C.; FREITAS, S. R.; BARBOSA, C. C. F. Seasonal and interannual assessment of cloud cover and atmospheric constituents across the Amazon (2000–2015): Insights for remote sensing and climate analysis. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 145, part B, p. 309–327, 2018. Elsevier.
- MATEO-GARCÍA, G.; GÓMEZ-CHOVA, L.; AMORÓS-LÓPEZ, J.; MUÑOZ-MARÍ, J.; CAMPS-VALLS, G. Multitemporal cloud masking in the Google Earth Engine. **Remote Sensing**, v. 10, n. 7, p. 7–9, 2018.
- MATEO-GARCÍA, G.; LAPARRA, V.; LÓPEZ-PUIGDOLLERS, D.; GÓMEZ-CHOVA, L. Transferring deep learning models for cloud detection between Landsat-8 and Proba-V. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 160, p. 1–17, 2020.
- MATHER, P.; TSO, B. **Classification methods for remotely sensed data**. 2.ed. Boca Raton: CRC Press, 2009.

- MELGANI, F. Contextual reconstruction of cloud-contaminated multitemporal multispectral images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 44, n. 2, p. 442–455, 2006.
- MELGANI, F.; BRUZZONE, L. Classification of hyperspectral remote sensing. **IEEE Transactions on Geoscience and Remote Sensing**, v. 42, n. 8, p. 1778–1790, 2004.
- MENA, C. F. Trajectories of land-use and land-cover in the northern Ecuadorian Amazon: temporal composition, spatial configuration, and probability of change. **Photogrammetric Engineering and Remote Sensing**, v. 74, n. 6, p. 737–751, 2008.
- MERTENS, B.; LAMBIN, E. F. Land-cover-change trajectories in Southern Cameroon. **Annals of the Association of American Geographers**, v. 90, n. 3, p. 467–494, 2000.
- MESHESHA, D. **Spatial analysis of land use change and land degradation: image analysis, classification and change detection using remote sensing and GIS techniques**. Saarbrücken, Germany: VDM Verlag, 2009.
- MITSA, T. **Temporal data mining**. [S.l.]: Chapman and Hall/CRC, 2010.
- MORENO, Á.; GARCÍA-HARO, F. J.; MARTÍNEZ, B.; GILABERT, M. A. Noise reduction and gap filling of fAPAR time series using an adapted local regression filter. **Remote Sensing**, v. 6, n. 9, p. 8238–8260, 2014.
- NATH, S. S.; MISHRA, G.; KAR, J.; CHAKRABORTY, S; DEY, N. A survey of image classification methods and techniques. In: INTERNATIONAL CONFERENCE ON CONTROL, INSTRUMENTATION, COMMUNICATION AND COMPUTATIONAL TECHNOLOGIES, 2014. **Anais...** New Jersey: IEEE, 2014. p.554–557
- NETELER, M. Estimating daily land surface temperatures in mountainous environments by reconstructed MODIS LST data. **Remote Sensing**, v. 2, n. 1, p. 333–351, 2010.
- NOVO, E. M. L. DE M. **Sensoriamento remoto: princípios e aplicações**. 4.ed. São Paulo, SP, 2010.
- O'BRIEN, D. M. Size distributions of clouds in real time from satellite imagery. **International Journal of Remote Sensing**, v. 8, n. 6, p. 817–837, 1987.
- OLIVEIRA, J. C.; EPIPHANIO, J. C. N. Noise reduction in MODIS NDVI time series data based on spatial-temporal analysis. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2012. **Proceedings...** IEEE, 2012. p.2372–2375.
- OLIVEIRA, J. C.; EPIPHANIO, J. C. N.; RENNÓ, C. D. Window regression: a spatial-temporal analysis to estimate pixels classified as low-quality in MODIS NDVI time series. **Remote Sensing**, v. 6, n. 4, p. 3123–3142, 2014.

- PEREIRA, L. O.; FREITAS, C. C.; SANT'ANNA, S. J. S.; REIS, M. S. ALOS/PALSAR data evaluation for land use and land cover mapping in the Amazon region. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 9, n. 12, p. 5413–5423, 2016.
- PEREIRA, L. O.; FREITAS, C. C.; SANTAANNA, S. J. S.; REIS, M. S. Evaluation of optical and radar images integration methods for LULC classification in Amazon region. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 11, n. 9, p. 3062–3074, 2018.
- PETIT, C.; SCUDDER, T.; LAMBIN, E. Quantifying processes of land-cover change by remote sensing: resettlement and rapid land-cover changes in south-eastern Zambia. **International Journal of Remote Sensing**, v. 22, n. 17, p. 3435–3456, 2001.
- PLANK, V. G. The size distribution of cumulus clouds in representative Florida populations. **Journal of Applied Meteorology**, v. 8, n. 1, p. 46–67, 1969.
- PLATNICK, S. et al. The MODIS cloud products: algorithms and examples from terra. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 2, p. 459–473, 2003.
- POGGIO, L.; GIMONA, A.; BROWN, I. Spatio-temporal MODIS EVI gap filling under cloud cover: an example in Scotland. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 72, p. 56–72, 2012.
- PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto no estudo da vegetação**. 2.ed. São Paulo, SP: Oficina de Textos, 2012.
- PRUDENTE, V. H. R.; MARTINS, V. S.; VIEIRA, D. C.; SILVA, N. R. F.; ADAMI, M.; SANCHES, I. D. Limitations of cloud cover for optical remote sensing of agricultural areas across South America. **Remote Sensing Applications: Society and Environment**, v. 20, 100414, 2020. Elsevier.
- QIU, S.; HE, B.; ZHU, Z.; LIAO, Z.; QUAN, X. Improving Fmask cloud and cloud shadow detection in mountainous area for Landsats 4–8 images. **Remote Sensing of Environment**, v. 199, p. 107–119, 2017.
- QUARMBY, N. A. Towards continental scale crop area estimation. **International Journal of Remote Sensing**, v. 13, n. 5, p. 981–989, 1992.
- REIS, M. S. **Detecção de mudanças de uso e cobertura da terra utilizando dados óticos e de micro-ondas em uma região da Amazônia brasileira**. 2014. 331p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2014.
- REIS, M. S.; DUTRA, L. V.; ESCADA, M. I. S.; SANT'ANNA, S. J. S. Avoiding invalid transitions in land cover trajectory classification with a compound maximum a posteriori approach. **IEEE Access**, v. 8, p. 98787–98799, 2020a.

REIS, M. S.; DUTRA, L. V.; SANT'ANNA, S. J. S.; ESCADA, M. I. S. Multi-source change detection with PALSAR data in the Southern of Pará state in the Brazilian Amazon. **International Journal of Applied Earth Observation and Geoinformation**, v. 84, p. 101945, 2020b.

REIS, M. S.; DUTRA, L.; SANT'ANNA, S.; ESCADA, M. Examining multi-legend change detection in Amazon with pixel and region based methods. **Remote Sensing**, v. 9, n. 1, p. 77, 2017.

REIS, M. S.; ESCADA, M.; DUTRA, L.; SANT'ANNA, S.; VOGT, N. Towards a reproducible LULC hierarchical class legend for use in the southwest of Pará State, Brazil: a comparison with remote sensing data-driven hierarchies. **Land**, v. 7, n. 2, p. 65, 2018.

RIBEIRO, J. P. F. M.; BAPTISTA, G. M. DE M. Análise da severidade de queimadas na Amazônia por meio de dados hiperespectrais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17., 2015. **Anais...** São José dos Campos: INPE, 2015. p.447–484.

RICHTER, R.; MÜLLER, A. De-shadowing of satellite/airborne imagery. **International Journal of Remote Sensing**, v. 26, n. 15, p. 3137–3148, 2005.

RODRÍGUEZ-JEANGROS, N.; HERING, A. S.; KAISER, T.; MCCRAY, J. E. SCaMF-RM: a fused high-resolution land cover product of the rocky mountains. **Remote Sensing**, v. 9, n. 10, p. 13–15, 2017.

RODTS, S. M. A. A.; DUYNKERKE, P. G.; JONKER, H. J. J. J. Size distributions and dynamical properties of shallow cumulus clouds from aircraft observations and satellite data. **Journal of the Atmospheric Sciences**, v. 60, n. 16, p. 1895–1912, 2003.

ROERINK, G. J.; MENENTI, M.; VERHOEF, W. Reconstructing cloudfree NDVI composites using Fourier analysis of time series. **International Journal of Remote Sensing**, v. 21, n. 9, p. 1911–1917, 2000.

ROSA, R. **Introdução ao sensoriamento remoto**. 7.ed. Uberlândia, MG: EDUFU, 2009.

ROSSI, R. E.; DUNGAN, J. L.; BECK, L. R. Kriging in the shadows: geostatistical interpolation for remote sensing. **Remote Sensing of Environment**, v. 49, n. 1, p. 32–40, 1994.

ROSSOW, W. B. Measuring cloud properties from space: a review. **Journal of Climate**, v. 2, n. 3, p. 201–213, 1989.

ROY, D. P. et al. Web-enabled Landsat Data (WELD): Landsat ETM+ composited mosaics of the conterminous United States. **Remote Sensing of Environment**, v. 114, n. 1, p. 35–49, 2010.

ROZON, C. et al. Spatial and temporal evolution of family-farming land use in the Tapajós region of the Brazilian Amazon. **Acta Amazonica**, v. 45, n. 2, p. 203–214, 2015.

SALBERG, A. B.; JENSSEN, R. Land-cover classification of partly missing data using support vector machines. **International Journal of Remote Sensing**, v. 33, n. 14, p. 4471–4481, 2012.

SANG, L.; ZHANG, C.; YANG, J.; ZHU, D.; YUN, W. Simulation of land use spatial pattern of towns and villages based on CA-Markov model. **Mathematical and Computer Modelling**, v. 54, n. 3–4, p. 938–943, 2011.

SANO, E. E.; FERREIRA, L. G.; ASNER, G. P.; STEINKE, E. T. Spatial and temporal probabilities of obtaining cloud-free Landsat images over the Brazilian tropical savanna. **International Journal of Remote Sensing**, v. 28, n. 12, p. 2739–2752, 2007.

SCHARLEMANN, J. P. W. et al. Global data for ecology and epidemiology: a novel algorithm for temporal Fourier processing MODIS data. **PLoS ONE**, v. 3, n. 1, p. 1–13, 2008. Disponível em: <<https://dx.plos.org/10.1371/journal.pone.0001408>>. .

SCHOWENGERDT, R. A. **Remote sensing: models and methods for image processing**. 3.ed. San Diego, CA: Academic, 2007.

SESHADRI, K. V. S.; RAO, M.; JAYARAMAN, V.; THYAGARAJAN, K.; MURTHI, K. R. S. Resourcesat-1: A global multi-observation mission for resources monitoring. **Acta Astronautica**, v. 57, p. 534–539, 2005. Elsevier.

SILVA JUNIOR, C. A.; NANNI, M. R.; SILVA, A. A.; CEZAR, E.; ROMAGNOLI, F. Conversion of land use and cover in northwest Amazon (Brazil). **Pesquisa Agropecuária Tropical**, v. 44, n. 3, p. 230–237, 2014.

SIMIONI, J. P. D.; GUASSELLI, L. A. Simulation of changes in land-use/land cover on wetlands through CA-Markov model. **Revista Brasileira de Geografia Física**, v. 11, n. 6, p. 2057–2066, 2018.

SIMPSON, J. J.; STITT, J. R. A procedure for the detection and removal of cloud shadow from AVHRR data over land. **IEEE Transactions on Geoscience and Remote Sensing**, v. 36, n. 3, p. 880–897, 1998.

SOLBERG, A. H. S.; JAIN, A. K.; TAXT, T. Multisource classification of remotely sensed data: fusion of Landsat TM and SAR images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 32, n. 4, p. 768–778, 1994.

SONG, C.; WOODCOCK, C. E.; SETO, K. C.; LENNEY, M. P.; MACOMBER, S. A. Classification and change detection using Landsat TM data. **Remote Sensing of Environment**, v. 75, n. 2, p. 230–244, 2001.



SOTHE, C.; ALMEIDA, C.; LIESENBERG, V.; SCHIMALSKI, M. Evaluating Sentinel-2 and Landsat-8 data to map successional forest stages in a subtropical forest in southern Brazil. **Remote Sensing**, v. 9, n. 8, p. 838, 2017.

TAHSIN, S.; MEDEIROS, S. C.; HOOSHYAR, M.; SINGH, A. Optical cloud pixel recovery via machine learning. **Remote Sensing**, v. 9, n. 6, e527, 2017.

TOWNSHEND, J. R. G. Land cover. **International Journal of Remote Sensing**, v. 13, n. 6/7, p. 1319–1328, 1992.

TOWNSHEND, J. R. G.; JUSTICE, C.; LI, W.; GURNEY, C.; MCMANUS, J. Global land cover classification by remote sensing: present capabilities and future possibilities. **Remote Sensing of Environment**, v. 35, n. 2/3, p. 243–255, 1991.

TRIGG, S. N.; CURRAN, L. M.; MCDONALD, A. K. Utility of Landsat 7 satellite data for continued monitoring of forest cover change in protected areas in Southeast Asia. **Singapore Journal of Tropical Geography**, v. 27, n. 1, p. 49–66, 2006.

TSENG, D. C.; TSENG, H. T.; CHIEN, C. L. Automatic cloud removal from multi-temporal SPOT images. **Applied Mathematics and Computation**, v. 205, n. 2, p. 584–600, 2008.

TURNER, B. L.; LAMBIN, E. F.; REENBERG, A. The emergence of land change science for global environmental change and sustainability. **Proceedings of the National Academy of Sciences of the United States of America**, v. 104, n. 52, p. 20666–20671, 2007.

TURNER, B. L.; MEYER, W. B.; SKOLE, D. L. Global land-use/land-cover change: Towards an integrated study. **Ambio**, v. 23, n. 1, p. 91–95, 1994.

UNITED STATES GEOLOGICAL SURVEY - USGS. **Landsat 4-5 TM collection 2 level 2 data format control book** - Version 3.0. Disponível em: <[https://prd-wret.s3.us-west-2.amazonaws.com/assets/palladium/production/atoms/files/LSDS-1336\\_Landsat4-5\\_TM\\_Collection2\\_Level2\\_DFCB-v3.pdf](https://prd-wret.s3.us-west-2.amazonaws.com/assets/palladium/production/atoms/files/LSDS-1336_Landsat4-5_TM_Collection2_Level2_DFCB-v3.pdf)>. Acesso em: 4 fev. 2020.

VERBESSELT, J.; HYNDMAN, R.; NEWNHAM, G.; CULVENOR, D. Detecting trend and seasonal changes in satellite image time series. **Remote Sensing of Environment**, v. 114, n. 1, p. 106–115, 2010a.

VERBESSELT, J.; HYNDMAN, R.; ZEILEIS, A.; CULVENOR, D. Phenological change detection while accounting for abrupt and gradual trends in satellite image time series. **Remote Sensing of Environment**, v. 114, n. 12, p. 2970–2980, 2010b.

VERBURG, P. H.; SCHOT, P. P.; DIJST, M. J.; VELDKAMP, A. Land use change modelling: current practice and research priorities. **GeoJournal**, v. 61, n. 4, p. 309–324, 2004.

VERGER, A.; BARET, F.; WEISS, M. Near real-time vegetation monitoring at global scale. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 8, p. 3473–3481, 2014.

VERGER, A.; BARET, F.; WEISS, M.; KANDASAMY, S.; VERMOTE, E. The CACAO method for smoothing, gap filling, and characterizing seasonal anomalies in satellite time series. **IEEE Transactions on Geoscience and Remote Sensing**, v. 51, n. 4, p. 1963–1972, 2013.

VIVONE, G.; ADDESSO, P.; CONTE, R.; LONGO, M.; RESTAINO, R. A class of cloud detection algorithms based on a MAP-MRF approach in space and time. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 8, p. 5100–5115, 2014.

VUOLO, F.; NG, W.-T.; ATZBERGER, C. Smoothing and gap-filling of high resolution multi-spectral time series: example of Landsat data. **International Journal of Applied Earth Observation and Geoinformation**, v. 57, p. 202–213, 2017.

WANG, D. et al. Spatio-temporal pattern analysis of land use/cover change trajectories in Xihe watershed. **International Journal of Applied Earth Observation and Geoinformation**, v. 14, n. 1, p. 12–21, 2012.

WEBB, A. **Statistical Pattern Recognition**. 2 ed. Chichester: John Wiley & Sons, 2002.

WEISS, D. J. et al. An effective approach for gap-filling continental scale remotely sensed time-series. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 98, p. 106–118, 2014.

WU, W.; GE, L.; LUO, J.; HUAN, R.; YANG, Y. A spectral-temporal patch-based missing area reconstruction for time-series images. **Remote Sensing**, v. 10, n. 10, p. 1–20, 2018.

WULDER, M. A.; COOPS, N. C.; ROY, D. P.; WHITE, J. C.; HERMOSILLA, T. Land cover 2.0. **International Journal of Remote Sensing**, v. 39, n. 12, p. 4254–4284, 2018.

WULDER, M. A.; HILKER, T.; WHITE, J. C.; COOPS, N. C.; MASEK, J. G.; PFLUGMACHER, D.; CREVIER, Y. Virtual constellations for global terrestrial monitoring. **Remote Sensing of Environment**, v. 170, p. 62–76, 2015. Elsevier.

WULDER, M. A.; MASEK, J. G.; COHEN, W. B.; LOVELAND, T. R.; WOODCOCK, C. E. Opening the archive: How free data has enabled the science and monitoring promise of Landsat. **Remote Sensing of Environment**, v. 122, p. 2–10, 2012. Elsevier.

ZENG, Z. et al. A regional gap-filling method based on spatiotemporal variogram model of CO<sub>2</sub> columns. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 6, p. 3594–3603, 2014.

- ZEWDIE, W.; CSAPLOVICS, E. Remote sensing based multi-temporal land cover classification and change detection in northwestern ethiopia. **European Journal of Remote Sensing**, v. 48, p. 121–139, 2015.
- ZHAI, H.; ZHANG, H.; ZHANG, L.; LI, P. Cloud/shadow detection based on spectral indices for multi/hyperspectral optical remote sensing imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 144, p. 235–253, 2018.
- ZHANG, Y.; GUINDON, B.; CIHLAR, J. An image transform to characterize and compensate for spatial variations in thin cloud contamination of Landsat images. **Remote Sensing of Environment**, v. 82, n. 2–3, p. 173–187, 2002.
- ZHOU, Q.; LI, B.; KURBAN, A. Trajectory analysis of land cover change in arid environment of China. **International Journal of Remote Sensing**, v. 29, n. 4, p. 1093–1107, 2008.
- ZHU, X.; LIU, D.; CHEN, J. A new geostatistical approach for filling gaps in Landsat ETM+ SLC-off images. **Remote Sensing of Environment**, v. 124, p. 49–60, 2012.
- ZHU, Z et al. Benefits of the free and open Landsat data policy. **Remote Sensing of Environment**, v. 224, p. 382–385, 2019.
- ZHU, Z. Change detection using landsat time series: a review of frequencies, preprocessing, algorithms, and applications. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 130, p. 370–384, 2017.
- ZHU, Z.; WANG, S.; WOODCOCK, C. E. Improvement and expansion of the Fmask algorithm: cloud, cloud shadow, and snow detection for Landsats 4–7, 8, and Sentinel 2 images. **Remote Sensing of Environment**, v. 159, p. 269–277, 2015.
- ZHU, Z.; WOODCOCK, C. E. Automated cloud, cloud shadow, and snow detection in multitemporal Landsat data: an algorithm designed specifically for monitoring land cover change. **Remote Sensing of Environment**, v. 152, p. 217–234, 2014a.
- ZHU, Z.; WOODCOCK, C. E. Continuous change detection and classification of land cover using all available Landsat data. **Remote Sensing of Environment**, v. 144, p. 152–171, 2014b.
- ZHU, Z.; WOODCOCK, C. E. Object-based cloud and cloud shadow detection in Landsat imagery. **Remote Sensing of Environment**, v. 118, p. 83–94, 2012.
- ZOMLOT, Z.; VERBEIREN, B.; HUYSMANS, M.; BATELAAN, O. Trajectory analysis of land use and land cover maps to improve spatial–temporal patterns, and impact assessment on groundwater recharge. **Journal of Hydrology**, v. 554, p. 558–569, 2017.

## APÊNDICE A – PSEUDOCÓDIGOS UTILIZADOS PARA ESTIMATIVA DE VALORES FALTANTES EM SENSORIAMENTO REMOTO

Nesse apêndice são encontrados os pseudocódigos utilizados na estimativa de classes em áreas com valores faltantes utilizando o método ATRANS proposto nesse trabalho.

### A.1 – Pseudocódigo para estimativa pelo método ATRANS.

---

#### a) **Algoritmo:** Estimativa pelo método ATRANS

**Entrada:** Imagens Classificadas com valores Faltantes (F)

Máscaras (M)

Número de Imagens (N)

Conjunto de probabilidades de Transição de Classes ( $\{A\}$ )

**Saída:** Imagens Classificadas com Valores Estimados (F)

---

```
1 Para img = 1, ..., Nr_imagens(R) - 1 faça
2   Para lin = 1, ..., Nr_linhas(R) faça
3     Para col = 1, ..., Nr_colunas(R) faça
4       Se (img = 1) então
5         Se ((Mt[lin,col] = valor faltante) e (Mt+1[lin,col] =
6           valor válido)) então
7           Se Nr_argmax(P{A}) = 1 então
8             Ft[lin,col] = Estimativa da classe no tempo t dada
9             classe no tempo t+1
10            Fim-se
11           Senão
12             Se Nr_argmax(P(Classes)t) = 1 então
13               Ft[lin,col] = Estimativa da classe no tempo t
14               dada distribuição de classes no tempo t
15            Fim-se
16           Senão
17             Ft[lin,col] = Estimativa da classe aleatória
```

```

15             Fim-se
16             Fim-se
17             Fim-se
18             Fim-se
19             Senão
20             Se ((Mt[lin,col] = valor faltante) e (Mt-1[lin,col] =
valor válido)) então
21                 Se Nr_argmax(P{A}) = 1 então
22                     Ft[lin,col] = Estimativa da classe no tempo t dada
classe no tempo t-1
23                     Fim-se
24                     Senão
25                         Se Nr_argmax(P(Classes)t) = 1 então
26                             Ft[lin,col] = Estimativa da classe no tempo t
dada distribuição de classes no tempo t
27                             Fim-se
28                             Senão
29                                 Ft[lin,col] = Estimativa da classe aleatória
30                                 Fim-se
31                                 Fim-se
32                                 Fim-se
33                                 Fim-se
34                                 Fim-para
35                                 Fim-para
36                                 Fim-para
37                                 Retorna F

```

---

## APÊNDICE B - DETALHES DAS CLASSES DE USO E COBERTURA DO SOLO PARA IMAGENS SENTINEL-2/MSI


Nesse apêndice são encontrados os detalhes das classes de uso e cobertura da terra utilizadas na classificação das imagens Sentinel-2/MSI. São apresentadas as chaves de interpretação bem como a definição para cada classe adotada no trabalho.

Conforme descrito na Seção 3.4, foram utilizados dados coletados a partir do trabalho de campo realizado entre os dias 13 e 20 de setembro de 2017 dentro da área de estudo. Foram visitados 163 pontos e para cada um foi realizado o registro fotográfico além da identificação da tipologia de uso e cobertura do solo e armazenamento da latitude e longitude através do uso de um GPS (*Global Positioning System*) (datum WGS84).

Juntamente com os dados de imagens de série histórica, buscou-se identificar padrões espectrais em cada uma das imagens para cada classe. Dessa maneira foram selecionadas as chaves de interpretação baseadas na composição R(11)G(8)B(4) das imagens como apresentadas nas representações de cada classe descrita.

**Área de Cultivo (AC):** representados por áreas com cultivos de grãos. Nas imagens Sentinel-2/MSI, são representadas por regiões em tons de verde claro e textura lisa (Figura B.1).

Figura B.1 - Amostra de Área de Cultivo em imagem Sentinel-2/MSI.



Fonte: Produção do autor.

**Área em Pousio (AP):** regiões de uso agrícola que se encontram em período entre cultivos. São caracterizadas por áreas com presença de vegetação seca, geralmente esparsa, e plantas invasoras (Figura B.2). Na imagem Sentinel-2/MSI, apresenta tons de magenta e levemente esverdeados, com textura lisa (Figura B.3).

Figura B.2 – Exemplo de Área em Pousio.



Fonte: Produção do autor.

Figura B.3 - Amostra de Área de Pousio na imagem Sentinel-2/MSI.



Fonte: Produção do autor.


**Corpo D'água (CA):** áreas caracterizadas pela presença de grandes quantidades de água superficial (Figura B.4). Representado por corpos hídricos como, por exemplo: rios, córregos, represas, lagoas, entre outros. Na imagem Sentinel-2/MSI, apresentam tons de preto e, por vezes, com presença de tons de verde escuro com textura lisa (Figura B.5).

Figura B.4 – Exemplo de Corpo D'água.



Fonte: Produção do autor.


Figura B.5 - Amostra de Corpo D'água na imagem Sentinel-2/MSI.



Fonte: Produção do autor.

**Formação Florestal (FL):** regiões caracterizadas pela elevada concentração de espécies arbustivas de médio a grande porte (Figura B.6). Podem ser representadas por áreas com vegetação nativa ou secundária (em regeneração). Nas imagens Sentinel-2/MSI, apresentam tons verde claro e, por vezes, escuro com textura rugosa (Figura B.7).


Figura B.6 - Exemplo de Formação Florestal.



Fonte: Produção do autor.



Figura B.7 - Amostra de Formação Florestal na imagem Sentinel-2/MSI.



Fonte: Produção do autor.


**Pasto Limpo (PL):** áreas com vegetação gramínea típicas de pastagens dedicadas, normalmente, a atividades pecuárias (Figura B.8). Nas imagens Sentinel-2/MSI, apresenta coloração magenta clara, com tons de verde e roxo (Figura B.9).

Figura B.8 - Exemplo de Pasto Limpo.



Fonte: Produção do autor.

Figura B.9 - Amostra de Pasto Limpo na imagem Sentinel-2/MSI.



Fonte: Produção do autor.


**Pasto Sujo (PS):** regiões com vegetação característica de pastagens, com a presença de espécies arbustivas e arbóreas invasoras (Figura B.10). Na imagem Sentinel-2/MSI, apresenta cor verde clara e textura lisa (Figura B.11).

Figura B.10 - Exemplo de Pasto Sujo.



Fonte: Produção do autor.

Figura B.11 - Amostra de Pasto Sujo na imagem Sentinel-2/MSI.



Fonte: Produção do autor.


**Solo Exposto (SE):** composto por áreas com solo exposto superficialmente (Figura B.12). Normalmente, trata-se de regiões de preparadas para o cultivo ou pós-colheita. Nas imagens Sentinel-2/MSI, são representadas por regiões em tons de magenta claro e textura lisa ou rugosa (Figura B.13).

Figura B.12 - Exemplo de Solo Exposto.



Fonte: Produção do autor.

Figura B.13- Amostra de Solo Exposto na imagem Sentinel-2/MSI.




Fonte: Produção do autor.

## APÊNDICE C – MATRIZ DE CONFUSÃO E ÍNDICE DAS CLASSIFICAÇÕES UTILIZADAS

Nesse apêndice são encontradas as matrizes de confusão das classificações utilizadas como referência para elaboração desse trabalho. As matrizes são apresentadas valores percentuais, onde cada círculo possui área proporcional ao valor de cada elemento da matriz. Estas matrizes são vistas nas Figura C.1 à Figura C.18. Também são apresentados, na Tabela C.1, os índices de avaliação (Kappa e Exatidão Global), além dos índices de avaliação por classe (Tabelas C.2 e C.3) de cada uma das classificações as quais foram utilizadas como referência (Figuras C.19 e C.20). Além disso, nessa seção são apresentados os produtos de classificação que serviram de base para aplicação dos métodos.


Figura C.1 - Matriz de confusão da classificação da imagem Sentinel-2/MSI de 11 de julho de 2017 pelo método MAXVER.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.


Figura C.2 - Matriz de confusão da classificação da imagem Sentinel-2/MSI de 16 de julho de 2017 pelo método MAXVER.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.


Figura C.3 - Matriz de confusão da classificação da imagem Sentinel-2/MSI de 26 de julho de 2017 pelo método MAXVER.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.


Figura C.4 - Matriz de confusão da classificação da imagem Sentinel-2/MSI de 11 de julho de 2017 pelo método RF.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.


Figura C.5 - Matriz de confusão da classificação da imagem Sentinel-2/MSI de 16 de julho de 2017 pelo método RF.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.


Figura C.6 - Matriz de confusão da classificação da imagem Sentinel-2/MSI de 26 de julho de 2017 pelo método RF.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

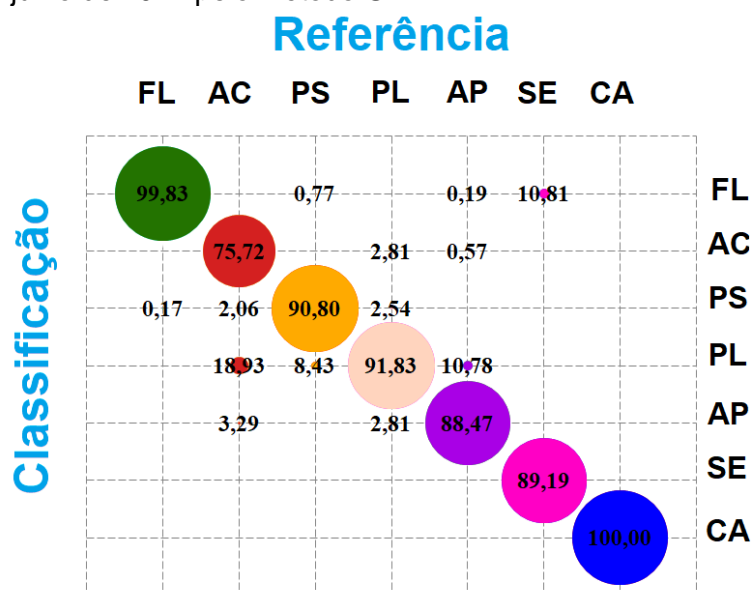
Figura C.7 - Matriz de confusão da classificação da imagem Sentinel-2/MSI de 11 de julho de 2017 pelo método SVM.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.


Figura C.8 - Matriz de confusão da classificação da imagem Sentinel-2/MSI de 16 de julho de 2017 pelo método SVM.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

Figura C.9 - Matriz de confusão da classificação da imagem Sentinel-2/MSI de 26 de julho de 2017 pelo método SVM.

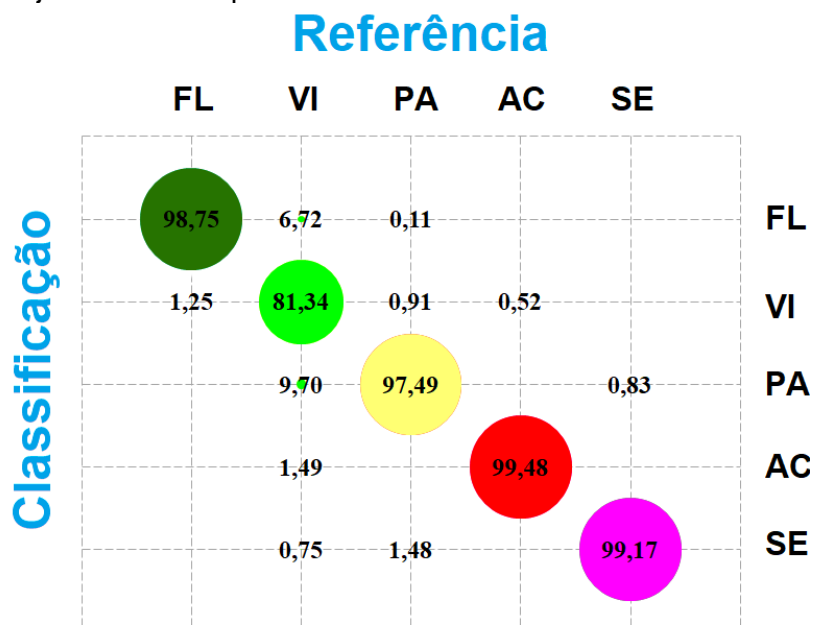


AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.




Figura C.10 - Matriz de confusão da classificação da imagem Landsat-5/TM de 21 de junho de 2007 pelo método MAXVER.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.


Figura C.11 - Matriz de confusão da classificação da imagem Landsat-5/TM de 23 de junho de 2008 pelo método MAXVER.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.


Figura C.12 - Matriz de confusão da classificação da imagem Landsat-5/TM de 29 de junho de 2010 pelo método MAXVER.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.


Figura C.13 - Matriz de confusão da classificação da imagem Landsat-5/TM de 21 de junho de 2007 pelo método RF.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.


Figura C.14 - Matriz de confusão da classificação da imagem Landsat-5/TM de 23 de junho de 2008 pelo método RF.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.


Figura C.15 - Matriz de confusão da classificação da imagem Landsat-5/TM de 29 de junho de 2010 pelo método RF.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.


Figura C.16 - Matriz de confusão da classificação da imagem Landsat-5/TM de 21 de junho de 2007 pelo método SVM.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.


Figura C.17 - Matriz de confusão da classificação da imagem Landsat-5/TM de 23 de junho de 2008 pelo método SVM.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

Figura C.18 - Matriz de confusão da classificação da imagem Landsat-5/TM de 29 de junho de 2010 pelo método SVM.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor

Tabela C.1 – Índices de avaliação para as classificações de referência.

Identificação Classificação		Índice Kappa			Exatidão Global		
Satélite/Sensor	Data Referência	MAXVER	RF	SVM	MAXVER	RF	SVM
Sentinel-2/MSI	11 julho 17	0,93	0,95	0,96	0,96	0,97	0,98
	16 julho 17	0,92	0,92	0,93	0,96	0,96	0,96
	26 julho 17	0,95	0,95	0,94	0,97	0,97	0,97
Landsat-5/TM	21 junho 07	0,97	0,95	0,93	0,98	0,97	0,96
	23 junho 08	0,95	0,97	0,96	0,97	0,98	0,98
	28 junho 10	0,92	0,94	0,93	0,95	0,96	0,96

Fonte: Produção do autor.

Tabela C.2 – Índices de avaliação por classe para as classificações de referência das imagens Sentinel-2/MSI.

Acurácia do Produtor (AP) e Acurácia do Usuário (AU)															
%															
Classificação		FL		AC		PS		PL		AP		SE		CA	
Método	Data de Referência	AC	AU	AC	AU	AC	AU	AC	AU	AC	AU	AC	AU	AC	AU
MAXVER	11 julho 17	98,82	99,82	95,79	86,40	96,11	90,18	74,43	98,18	100,00	70,83	100,00	100,00	100,00	100,00
	16 julho 17	99,22	99,98	87,24	68,83	98,08	85,19	76,97	90,13	91,30	91,30	100,00	100,00	100,00	100,00
	26 julho 17	99,68	99,90	95,73	87,45	95,73	88,02	92,42	87,23	87,79	99,09	99,76	100,00	97,14	100,00
RF	11 julho 17	99,90	99,26	90,91	88,55	92,48	94,90	86,37	95,76	99,31	86,97	100,00	100,00	97,59	100,00
	16 julho 17	99,72	99,98	61,32	88,17	95,79	89,77	82,73	81,10	91,30	85,79	100,00	98,67	100,00	100,00
	26 julho 17	99,88	99,48	84,83	94,21	89,57	90,87	93,51	88,80	92,51	97,10	100,00	100,00	97,14	100,00
SVM	11 julho 17	99,96	99,42	94,90	94,27	93,29	98,03	87,75	93,47	95,16	81,25	100,00	100,00	98,80	100,00
	16 julho 17	99,83	99,55	75,72	88,46	90,80	93,68	91,83	82,35	88,47	94,16	89,19	100,00	100,00	100,00
	26 julho 17	98,84	99,34	93,36	78,17	87,20	92,00	95,24	87,13	85,83	98,28	95,38	100,00	97,14	100,00

AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.


Tabela C.3 – Índices de avaliação por classe para as classificações de referência das imagens Landsat-5/TM.

Acurácia do Produtor (AP) e Acurácia do Usuário (AU)											
%											
Classificação		FL		VI		PA		AC		SE	
Método	Ano de Referência	AP	AU	AP	AU	AP	AU	AP	AU	AP	AU
MAXVER	2007	98,75	99,66	81,34	70,32	97,49	97,27	99,48	98,97	99,17	98,95
	2008	98,81	99,56	51,94	48,91	94,22	83,11	94,43	99,80	99,93	100,00
	2010	97,61	100,00	74,35	30,21	80,22	91,23	78,95	94,80	98,91	96,78
RF	2007	99,90	99,53	91,79	97,62	96,35	85,43	99,48	98,47	96,35	85,43
	2008	99,86	99,49	49,61	84,21	95,44	83,51	97,59	99,62	99,93	99,49
	2010	99,24	99,63	80,63	85,56	77,49	94,05	97,83	96,05	99,80	91,90
SVM	2007	99,63	95,70	85,82	85,19	78,77	99,00	99,48	97,97	98,64	94,86
	2008	99,93	99,33	46,51	75,00	85,41	83,38	98,33	99,25	100,00	97,99
	2010	99,18	99,82	56,54	64,67	75,78	90,01	97,21	96,02	99,80	91,73

AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

Figura C.19 - Classificações de referência das imagens Sentinel-2/MSI.




AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.



Figura C.20 - Classificações de referência das imagens Landsat-5/TM.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

## APÊNDICE D – TRANSIOGRAMAS DE PROBABILIDADE DE MUDANÇAS DE CLASSES DE USO E COBERTURA DA TERRA

Nesse apêndice são encontradas os transiogramas com as probabilidades de mudança de classe de cada uma das classificações analisados em ambos os estudos de caso. Os transiogramas são mostrados nas Tabelas D.1 a D.6. Os valores em destaque (negrito) correspondem àqueles com maior probabilidade.

Tabela D.1 - Transiograma de probabilidade de mudança de classe para classificação MAXVER das imagens Sentinel-2/MSI.

	Data Referência	Classe	Mudança para classe							
			FL	AC	PS	PL	AP	SE	CA	
Mudança da classe	11/07 - 16/07	FL	<b>0,988</b>	0,000143	0,0117	0,000264	0,0000289	0,00000204	0,00000591	
	16/07 - 26/07	FL	<b>0,987</b>	0,00000618	0,0121	0,000771	0,000119	0,0	0,0000639	
	11/07 - 16/07	AC	0,0110	0,236	0,0722	<b>0,349</b>	0,331	0,000228	0,0000846	
	16/07 - 26/07	AC	0,00855	0,217	0,0755	<b>0,516</b>	0,183	0,000121	0,0000364	
	11/07 - 16/07	PS	0,153	0,00671	<b>0,789</b>	0,0492	0,00245	0,0	0,000258	
	16/07 - 26/07	PS	0,165	0,00109	<b>0,752</b>	0,0802	0,00158	0,0000116	0,0	
	11/07 - 16/07	PL	0,00834	0,110	0,112	<b>0,628</b>	0,142	0,000647	0,0000952	
	16/07 - 26/07	PL	0,00527	0,0154	0,105	<b>0,760</b>	0,114	0,000927	0,0000273	
	11/07 - 16/07	AP	0,0000190	0,0214	0,00758	0,132	<b>0,776</b>	0,0625	0,00000758	
	16/07 - 26/07	AP	0,000627	0,0282	0,00449	0,212	<b>0,741</b>	0,0135	0,0000178	
	11/07 - 16/07	SE	0,000	0,002	0,000	0,123	0,363	<b>0,512</b>	0,0000876	
	16/07 - 26/07	SE	0,000	0,001	0,0000178	0,0763	0,259	<b>0,664</b>	0,0	
	11/07 - 16/07	CA	0,0400	0,000389	0,000545	0,0101	0,0154	0,0	<b>0,933</b>	
	16/07 - 26/07	CA	0,292	0,000358	0,00551	0,0135	0,0222	0,0	<b>0,667</b>	

AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

Tabela D.2 - Transiograma de probabilidade de mudança de classe para classificação RF das imagens Sentinel-2/MSI.

	Data Referência	Classe	Mudança para classe							
			FL	AC	PS	PL	AP	SE	CA	
Mudança da classe	11/07 - 16/07	FL	<b>0,992</b>	0,0000222	0,00735	0,0000711	0,0000824	0,00000196	0,000356	
	16/07 - 26/07	FL	<b>0,987</b>	0,00000597	0,0114	0,00143	0,0000550	0,0	0,000166	
	11/07 - 16/07	AC	0,00281	0,165	0,0511	<b>0,428</b>	0,343	0,00980	0,0000105	
	16/07 - 26/07	AC	0,00690	0,309	0,0632	<b>0,451</b>	0,171	0,0	0,0	
	11/07 - 16/07	PS	0,107	0,00499	<b>0,798</b>	0,0900	0,000334	0,0	0,0	
	16/07 - 26/07	PS	0,117	0,000842	<b>0,740</b>	0,141	0,00144	0,00000428	0,0	
	11/07 - 16/07	PL	0,00957	0,0352	0,168	<b>0,665</b>	0,120	0,00222	0,00000962	
	16/07 - 26/07	PL	0,00569	0,0431	0,0740	<b>0,688</b>	0,189	0,0000202	0,0	
	11/07 - 16/07	AP	0,0000113	0,00600	0,000278	0,0599	<b>0,781</b>	0,153	0,0000113	
	16/07 - 26/07	AP	0,0410	0,0756	0,00159	0,206	<b>0,673</b>	0,00199	0,0	
	11/07 - 16/07	SE	0,0	0,0	0,0000127	0,00110	0,166	<b>0,832</b>	0,0000127	
	16/07 - 26/07	SE	0,271	0,00384	0,0004668	0,107	<b>0,309</b>	0,308	0,0	
	11/07 - 16/07	CA	0,0706	0,0	0,0000813	0,00333	0,00374	0,000163	<b>0,922</b>	
	16/07 - 26/07	CA	0,338	0,0	0,0000775	0,00659	0,0	0,0	<b>0,655</b>	

AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

Tabela D.3 - Transiograma de probabilidade de mudança de classe entre para classificação SVM das imagens Sentinel-2/MSI.

	Data Referência	Classe	Mudança para classe						
			FL	AC	PS	PL	AP	SE	CA
Mudança da classe	11/07 - 16/07	FL	<b>0,989</b>	0,0000292	0,00890	0,000716	0,00114	0,0000251	0,000481
	16/07 - 26/07	FL	<b>0,981</b>	0,0000519	0,0121	0,00573	0,00112	0,0	0,000130
	11/07 - 16/07	AC	0,0135	0,152	0,0951	0,366	<b>0,372</b>	0,00165	0,0
	16/07 - 26/07	AC	0,00196	0,351	0,0644	<b>0,418</b>	0,164	0,0000209	0,0
	11/07 - 16/07	PS	0,121	0,00638	<b>0,709</b>	0,162	0,001741	0,0	0,0
	16/07 - 26/07	PS	0,130	0,00196	<b>0,752</b>	0,110	0,00621	0,00000478	0,0
	11/07 - 16/07	PL	0,0209	0,0511	0,115	<b>0,661</b>	0,150	0,00187	0,0
	16/07 - 26/07	PL	0,00687	0,0269	0,140	<b>0,676</b>	0,149	0,0000161	0,0
	11/07 - 16/07	AP	0,102	0,0124	0,00122	0,0997	<b>0,665</b>	0,120	0,0
	16/07 - 26/07	AP	0,0247	0,0807	0,00192	0,180	<b>0,710</b>	0,00317	0,0
	11/07 - 16/07	SE	0,0711	0,0	0,0	0,00002	0,370	<b>0,559</b>	0,0
	16/07 - 26/07	SE	0,063	0,00664	0,0	0,050	0,323	<b>0,557</b>	0,0
	11/07 - 16/07	CA	0,0329	0,0	0,0	0,0	0,0	0,0	<b>0,967</b>
	16/07 - 26/07	CA	0,298	0,0	0,0000811	0,00211	0,0	0,0	<b>0,699</b>

AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

Tabela D.4 - Transiograma de probabilidade de mudança de classe para classificação MAXVER das imagens Landsat-5/TM.

	Data Referência	Classe	Mudança para classe				
			FL	VI	PA	AC	SE
Mudança da classe	2007 - 2008	FL	<b>0,973</b>	0,0138	0,00977	0,0000154	0,00360
	2008 - 2010	FL	<b>0,974</b>	0,0129	0,00386	0,00615	0,00320
	2007 - 2008	VI	0,334	<b>0,541</b>	0,103	0,000938	0,0213
	2008 - 2010	VI	0,225	<b>0,585</b>	0,104	0,0702	0,0150
	2007 - 2008	PA	0,0283	0,155	<b>0,704</b>	0,00645	0,107
	2008 - 2010	PA	0,0224	0,347	<b>0,479</b>	0,0965	0,0548
	2007 - 2008	AC	0,00100	0,125	<b>0,499</b>	0,0356	0,339
	2008 - 2010	AC	0,0	0,0471	0,0721	0,0266	<b>0,854</b>
	2007 - 2008	SE	0,0103	0,0801	<b>0,481</b>	0,0683	0,361
	2008 - 2010	SE	0,0180	0,239	<b>0,346</b>	0,170	0,227

AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor

Tabela D.5 - Transiograma de probabilidade de mudança de classe para classificação RF das imagens Landsat-5/TM.

	Data Referência	Classe	Mudança para classe				
			FL	VI	PA	AC	SE
Mudança da classe	2007 - 2008	FL	<b>0,988</b>	0,00345	0,00650	0,000117	0,00194
	2008 - 2010		<b>0,973</b>	0,00977	0,00889	0,00460	0,00343
	2007 - 2008	VI	0,501	<b>0,315</b>	0,138	0,00347	0,0423
	2008 - 2010		0,319	<b>0,400</b>	0,171	0,0925	0,0179
	2007 - 2008	PA	0,149	0,0916	<b>0,587</b>	0,0105	0,162
	2008 - 2010		0,111	0,205	<b>0,511</b>	0,106	0,0673
	2007 - 2008	AC	0,00378	0,113	<b>0,455</b>	0,0420	0,387
	2008 - 2010		0,00315	0,0880	0,0883	0,0571	<b>0,763</b>
	2007 - 2008	SE	0,0129	0,0718	<b>0,428</b>	0,0710	0,416
	2008 - 2010		0,0111	0,200	<b>0,390</b>	0,169	0,230

AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor

Tabela D.6 - Transiograma de probabilidade de mudança de para classificação SVM das imagens Landsat-5/TM.

	Data Referência	Classe	Mudança para classe				
			FL	VI	PA	AC	SE
Mudança da classe	2007 - 2008	FL	<b>0,974</b>	0,0029	0,0144	0,000129	0,00816
	2008 - 2010		<b>0,974</b>	0,0076	0,00792	0,00506	0,00586
	2007 - 2008	VI	<b>0,537</b>	0,211	0,192	0,00144	0,0585
	2008 - 2010		0,283	0,288	<b>0,295</b>	0,0955	0,0381
	2007 - 2008	PA	0,165	0,0806	<b>0,539</b>	0,00795	0,207
	2008 - 2010		0,109	0,182	<b>0,529</b>	0,115	0,0651
	2007 - 2008	AC	0,00281	0,0659	<b>0,461</b>	0,0321	0,438
	2008 - 2010		0,000631	0,0372	0,0949	0,0325	<b>0,835</b>
	2007 - 2008	SE	0,0353	0,0613	0,373	0,0573	<b>0,473</b>
	2008 - 2010		0,0614	0,099	<b>0,443</b>	0,132	0,265

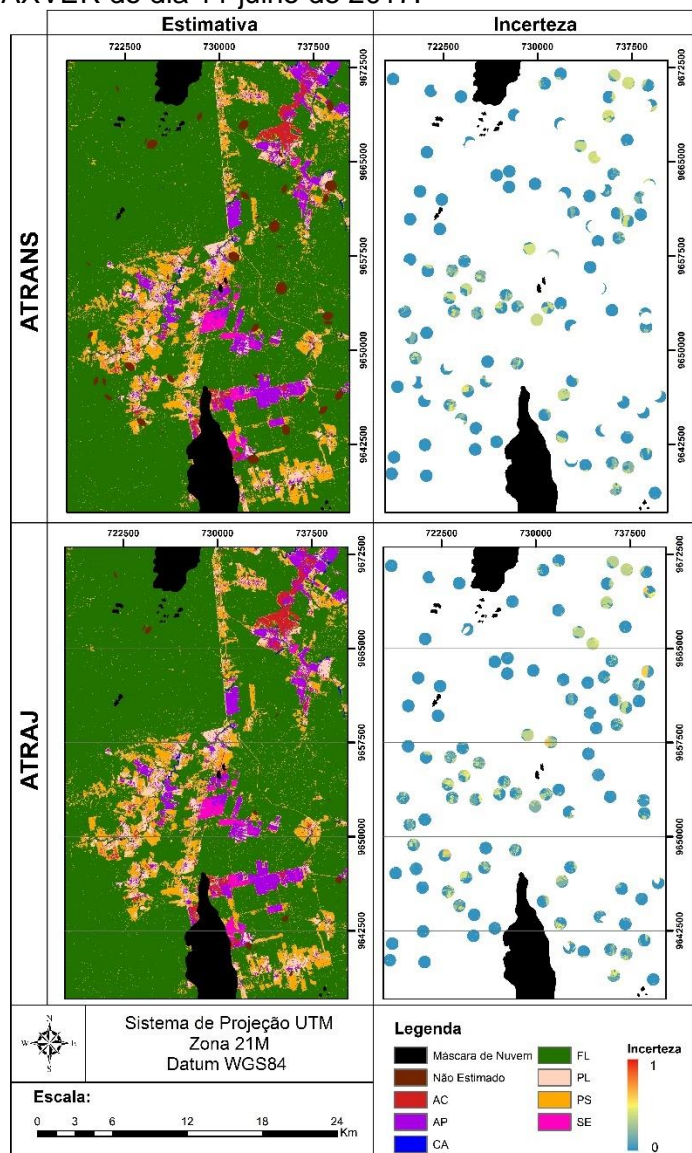
AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor

## APÊNDICE E – PRODUTOS DAS ESTIMATIVAS APLICADAS AO ESTUDO DE CASO I

Nesse apêndice são encontrados os resultados das estimativas de classes faltantes após a aplicação dos métodos ATRANS e ATRAJ no primeiro estudo de caso (imagens do Sentinel-2/MSI). Estes resultados juntamente com as incertezas das estimativas são mostrados nas Figuras E.1 a E.9

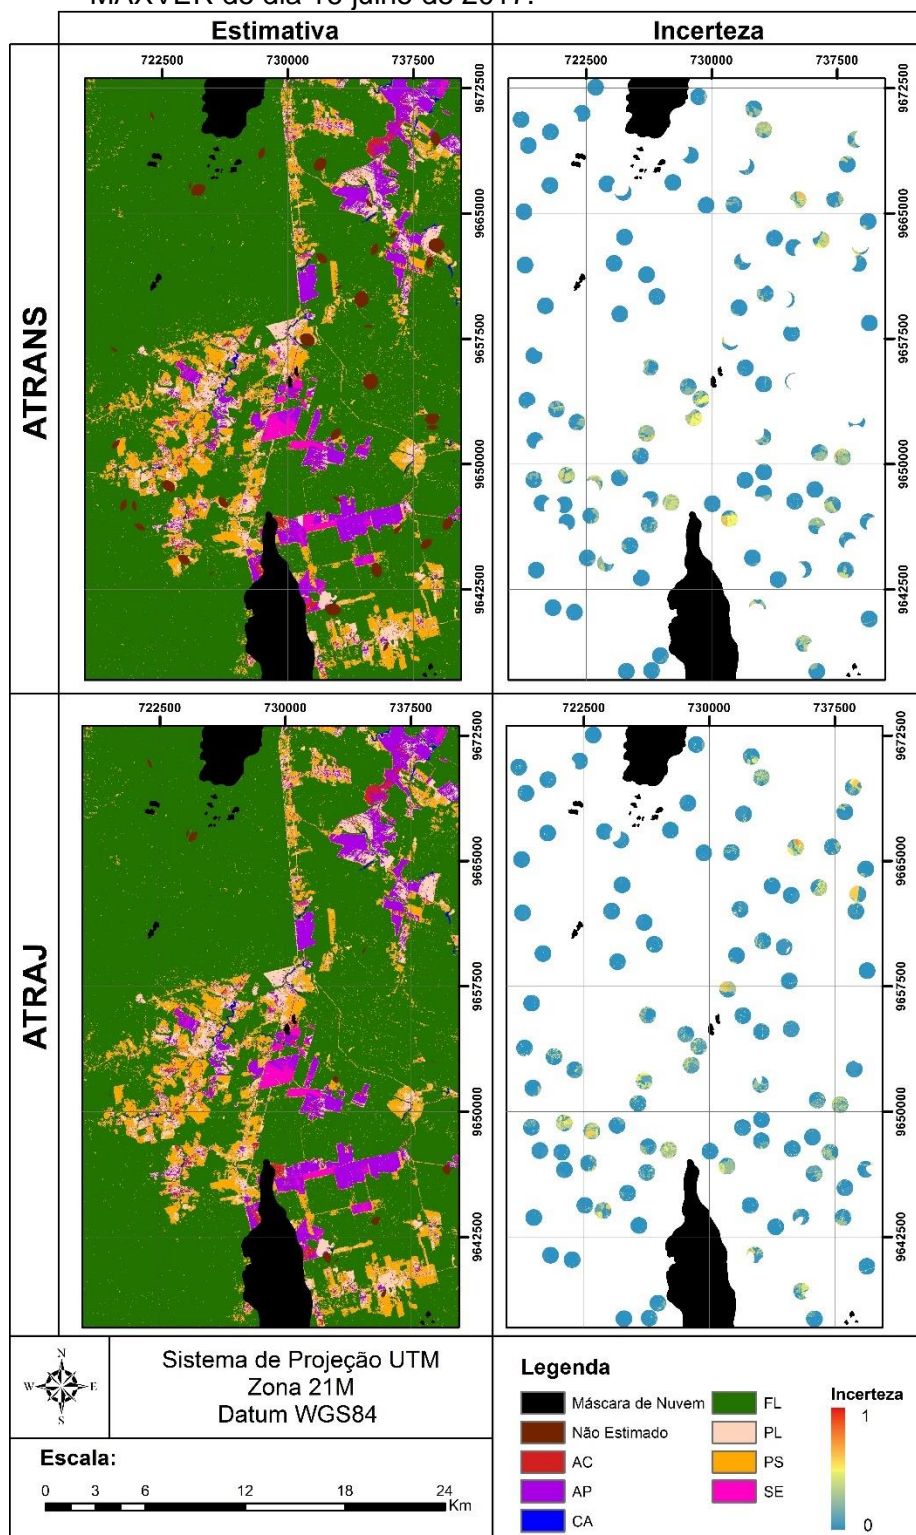
Figura E.1 - Estimativa e incerteza da imagem Sentinel-2/MSI classificada pelo método MAXVER do dia 11 julho de 2017.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.


Figura E.2 - Estimativa e incerteza da imagem Sentinel-2/MSI classificada pelo método MAXVER do dia 16 julho de 2017.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

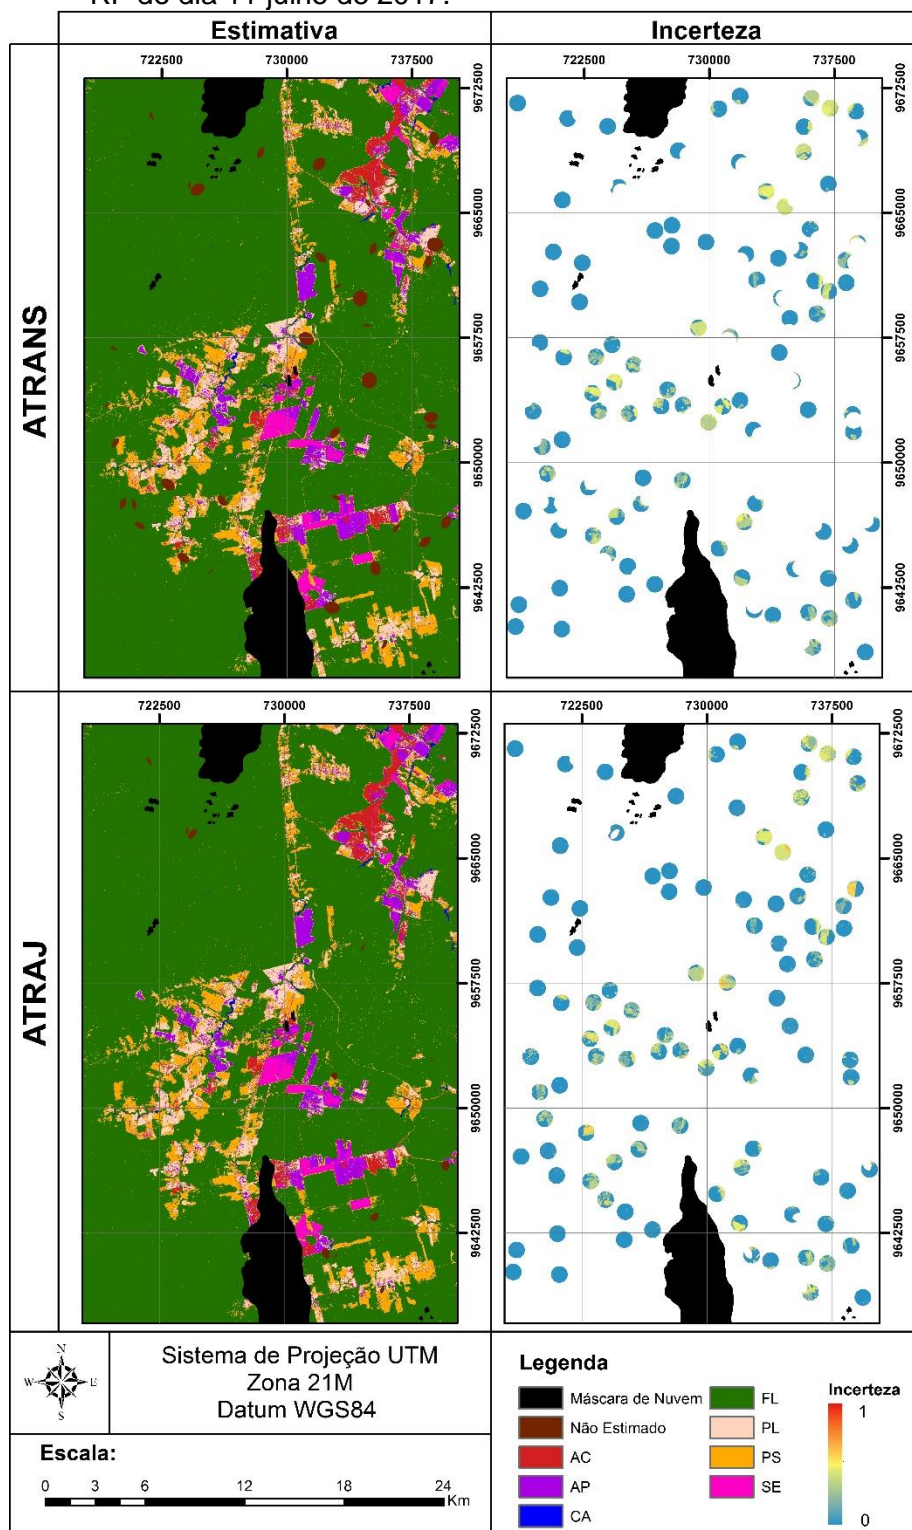
Figura E.3 - Estimativa e incerteza da imagem Sentinel-2/MSI classificada pelo método MAXVER do dia 26 julho de 2017.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

Figura E.4 - Estimativa e incerteza da imagem Sentinel-2/MSI classificada pelo método RF do dia 11 julho de 2017.

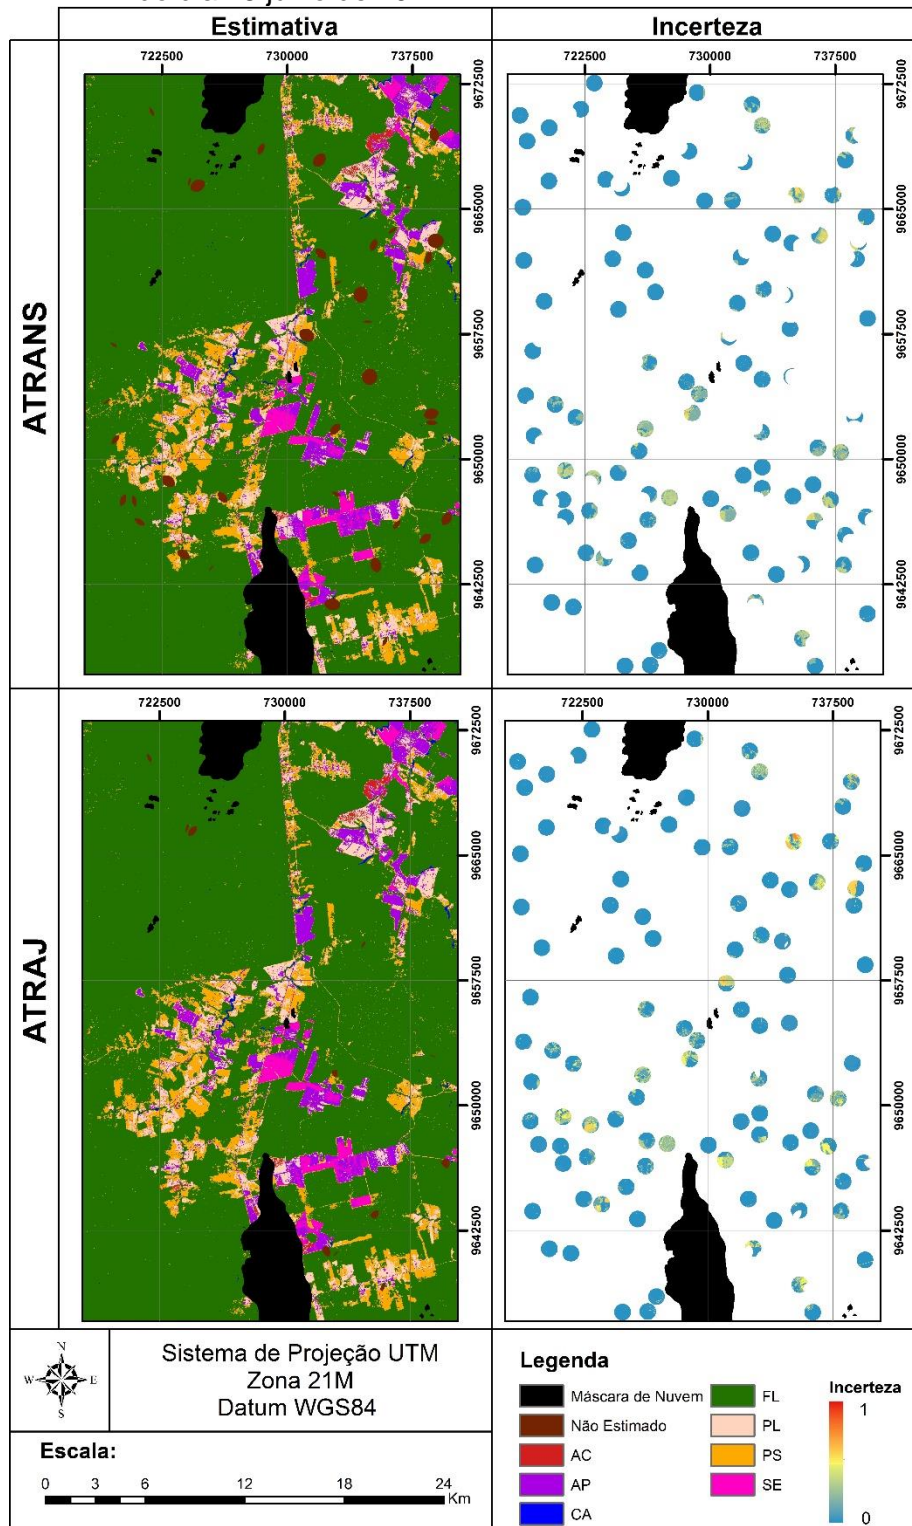


AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.




Figura E.5 - Estimativa e incerteza da imagem Sentinel-2/MSI classificada pelo método RF do dia 16 julho de 2017.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

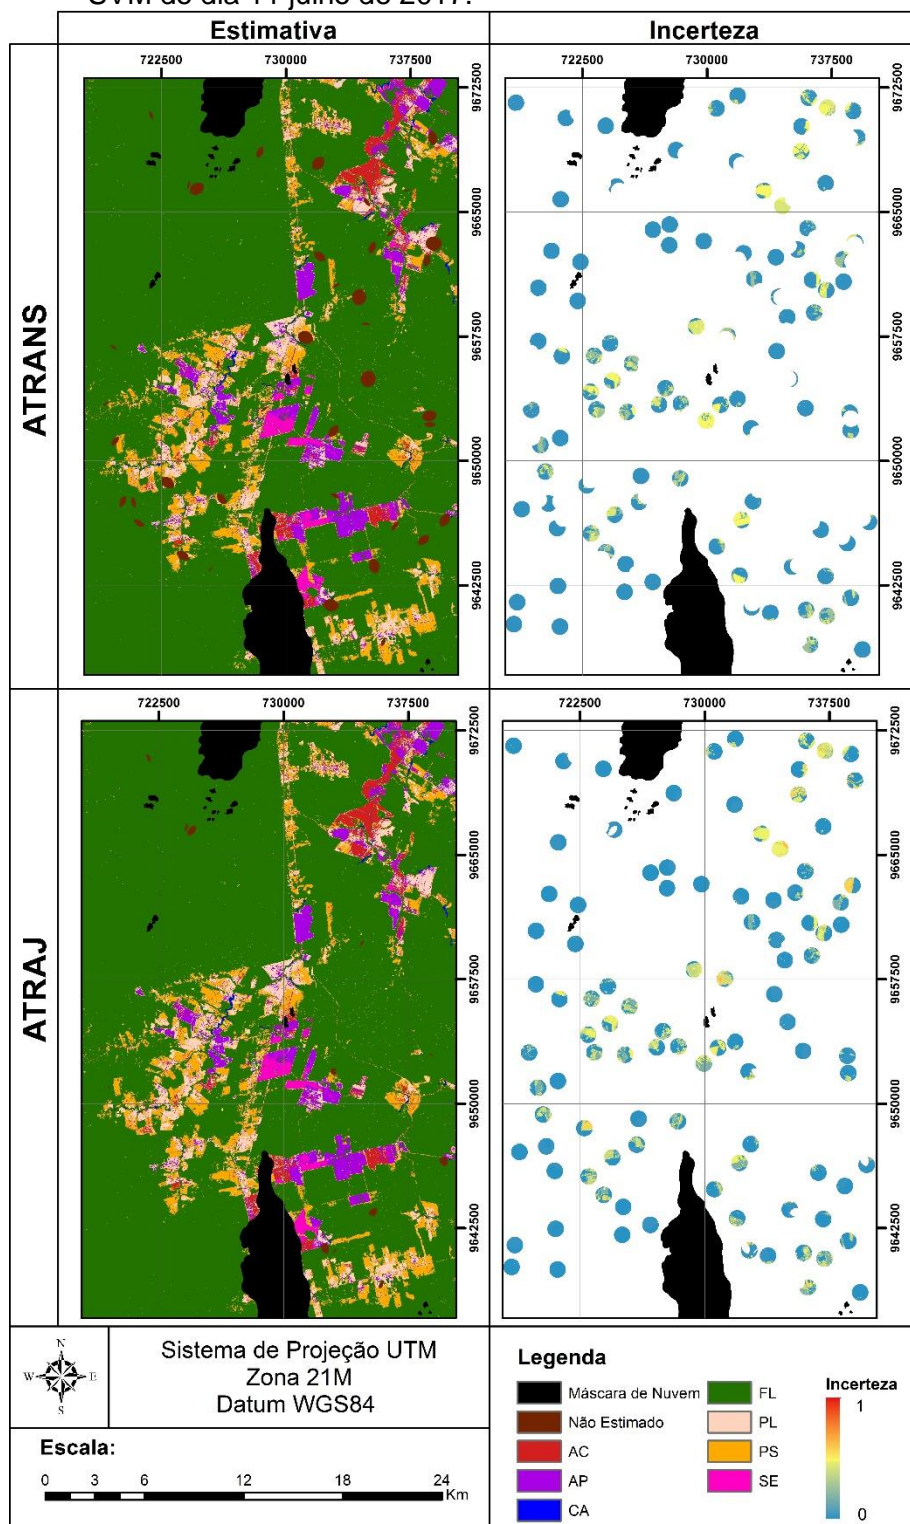
Figura E.6 - Estimativa e incerteza da imagem Sentinel-2/MSI classificada pelo método RF do dia 26 julho de 2017.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

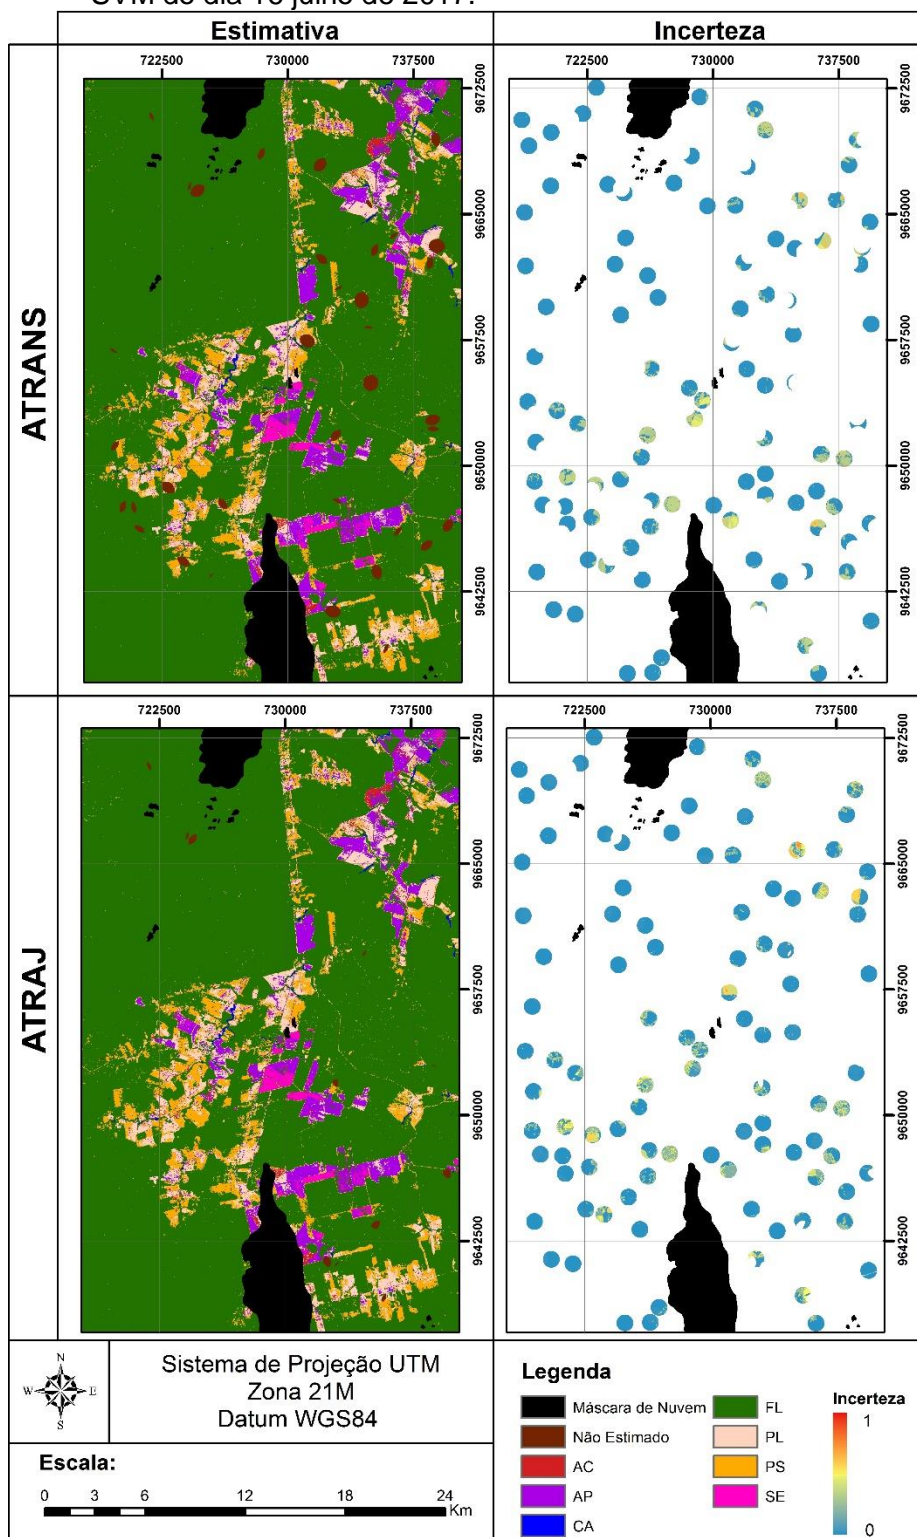
Figura E.7 - Estimativa e incerteza da imagem Sentinel-2/MSI classificada pelo método SVM do dia 11 julho de 2017.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.


Figura E.8 - Estimativa e incerteza da imagem Sentinel-2/MSI classificada pelo método SVM do dia 16 julho de 2017.



AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

Figura E.9 - Estimativa e incerteza da imagem Sentinel-2/MSI classificada pelo método SVM do dia 26 julho de 2017.



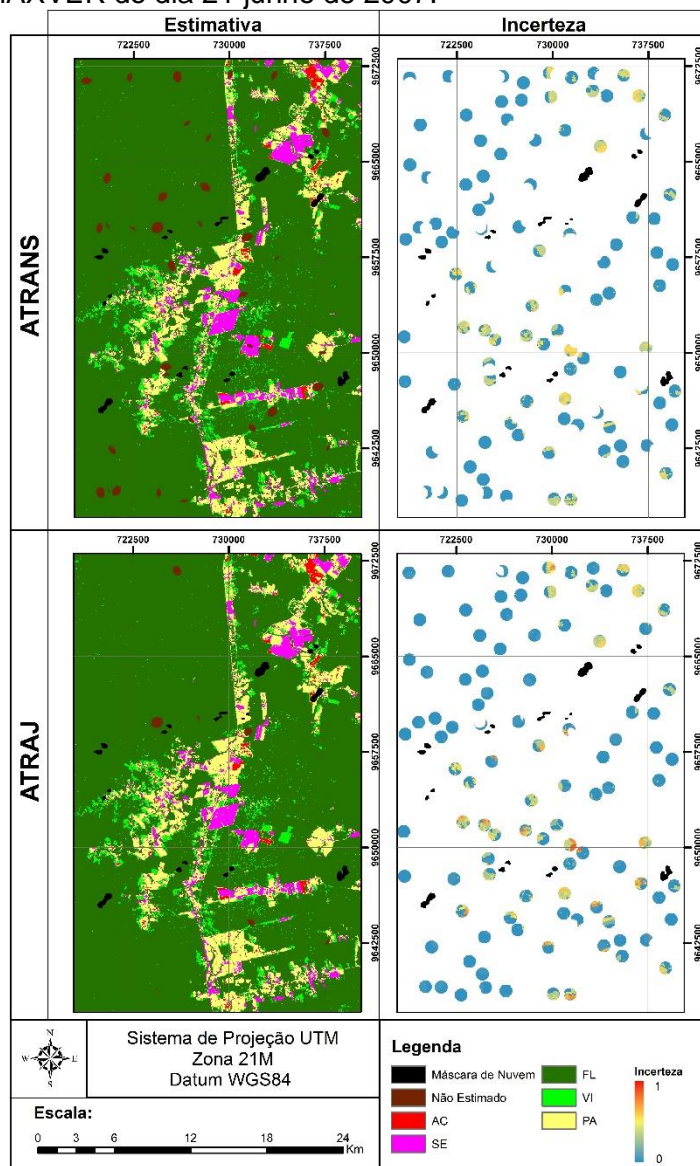
AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

## APÊNDICE F – PRODUTOS DAS ESTIMATIVAS APLICADAS AO ESTUDO DE CASO II

Nesse apêndice são encontrados os resultados das estimativas de classes faltantes após a aplicação dos métodos ATRANS e ATRAJ no segundo estudo de caso (imagens do Landsat-5/TM). Estes resultados juntamente com as incertezas das estimativas são mostrados nas Figuras F.1 a F.9

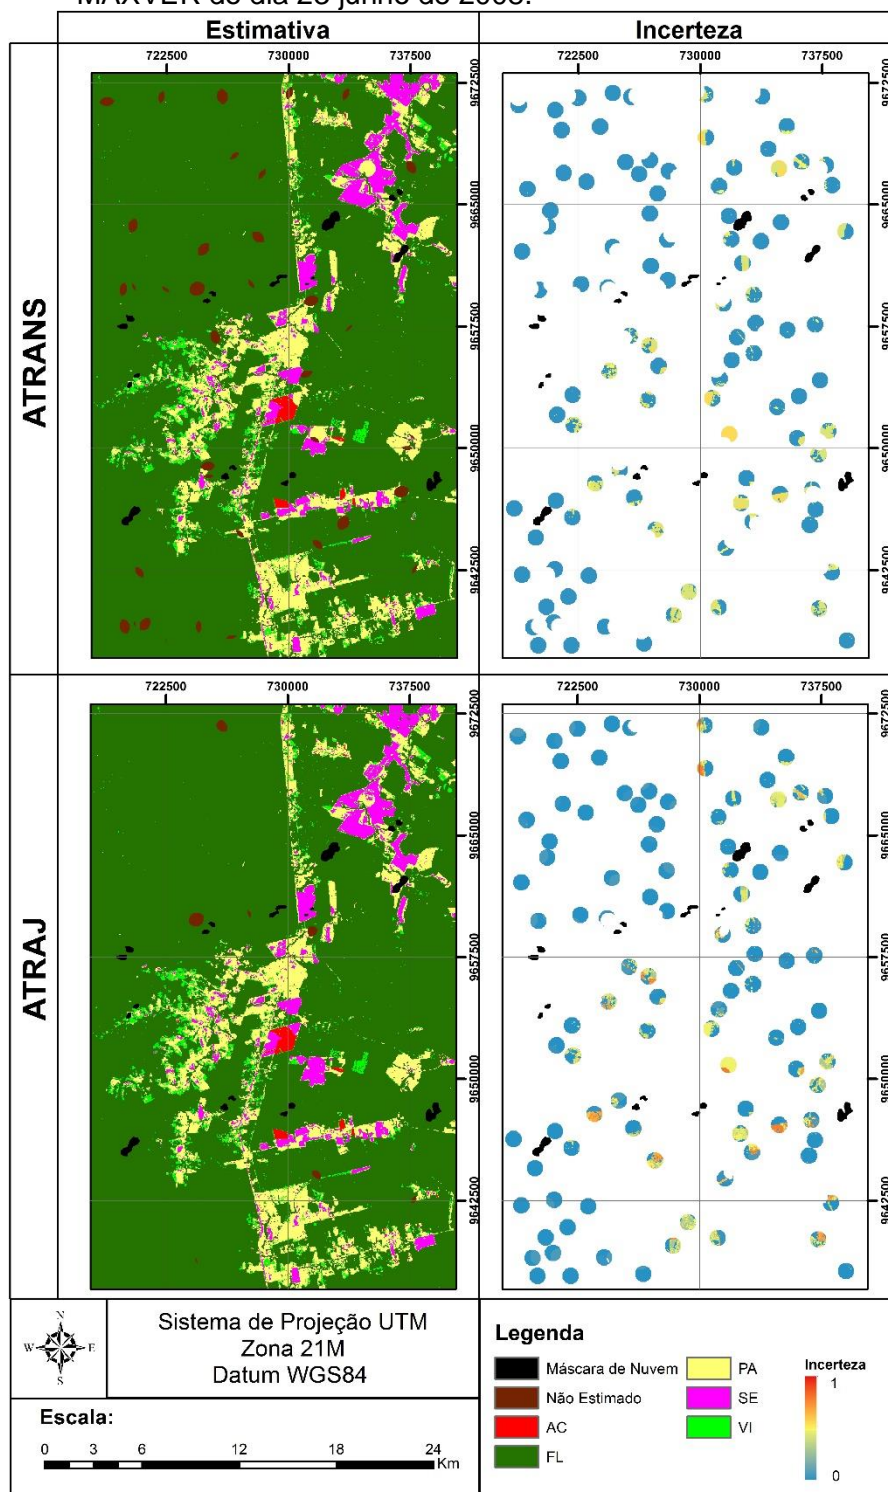
Figura F.1 - Estimativa e incerteza da imagem Landsat-5/TM classificada pelo método MAXVER do dia 21 junho de 2007.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

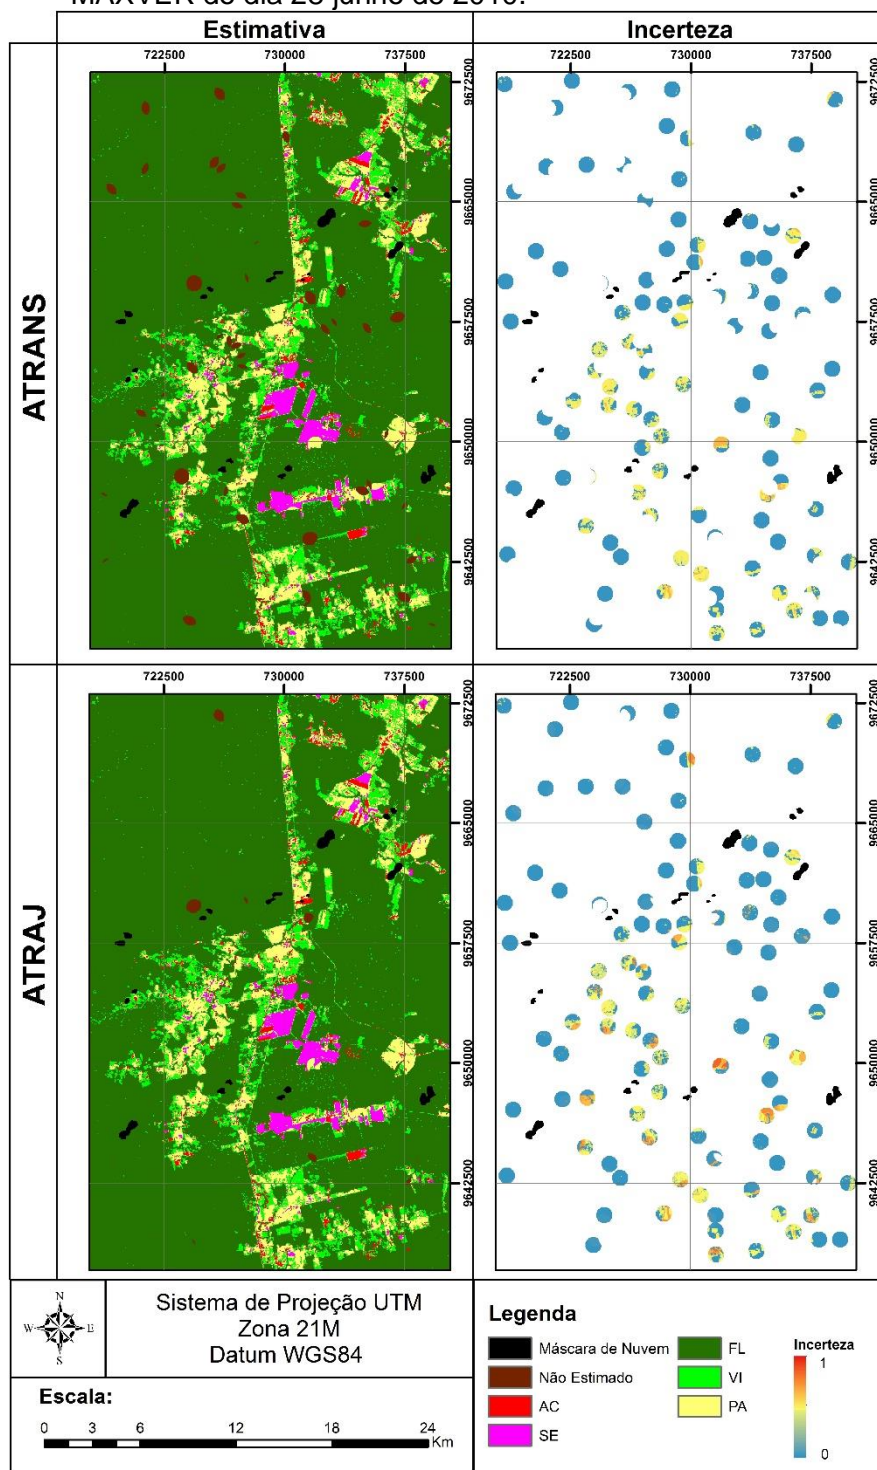
Figura F.2 - Estimativa e incerteza da imagem Landsat-5/TM classificada pelo método MAXVER do dia 23 junho de 2008.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

Figura F.3 - Estimativa e incerteza da imagem Landsat-5/TM classificada pelo método MAXVER do dia 28 junho de 2010.

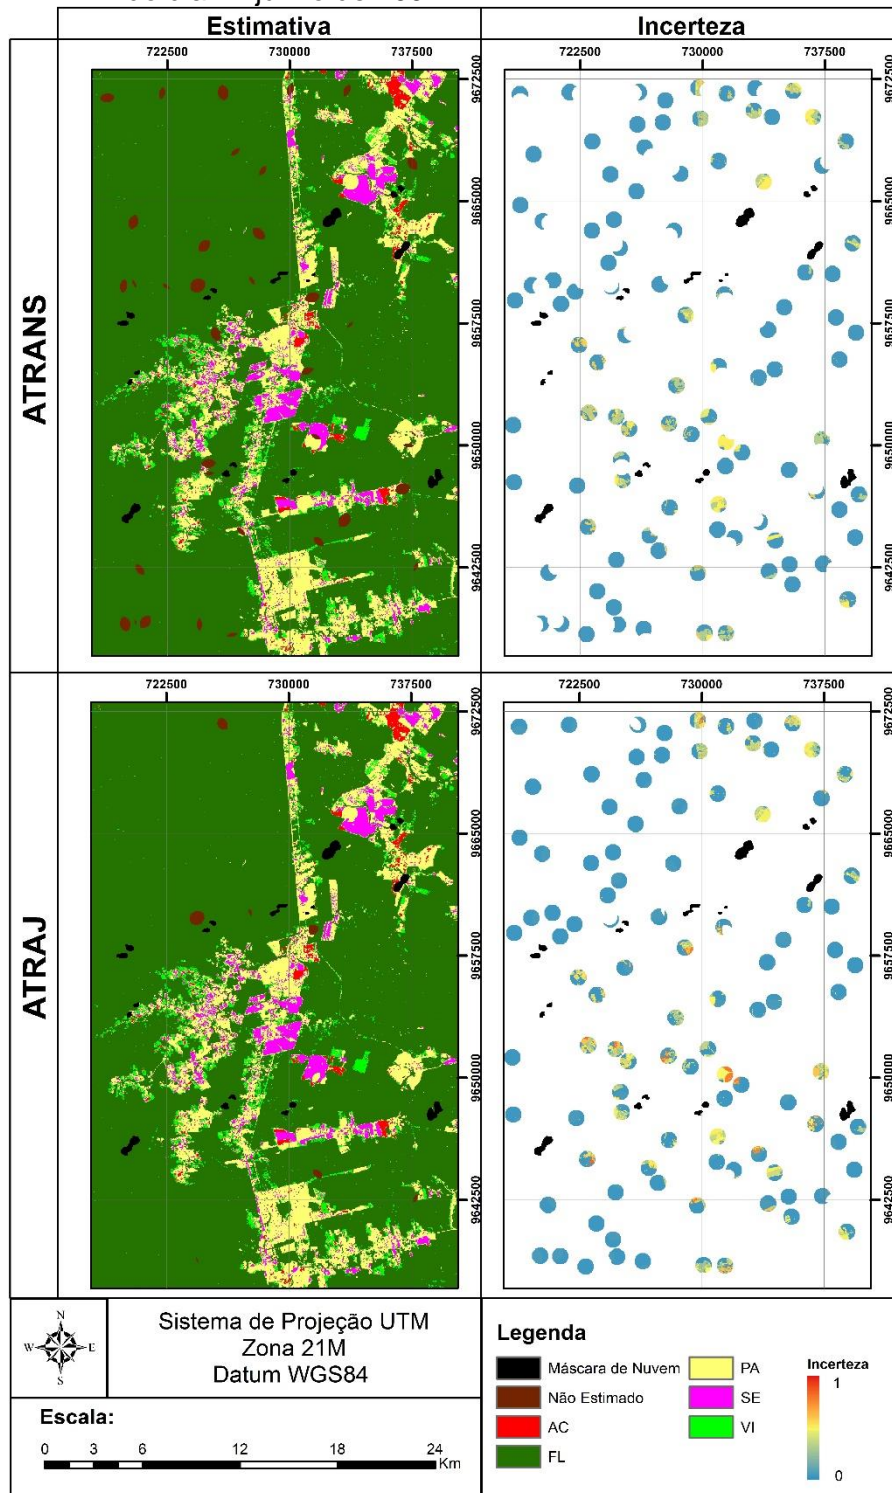


AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.




Figura F.4 - Estimativa e incerteza da imagem Landsat-5/TM classificada pelo método RF do dia 21 junho de 2007.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.


Figura F.5 - Estimativa e incerteza da imagem Landsat-5/TM classificada pelo método RF do dia 23 junho de 2008.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

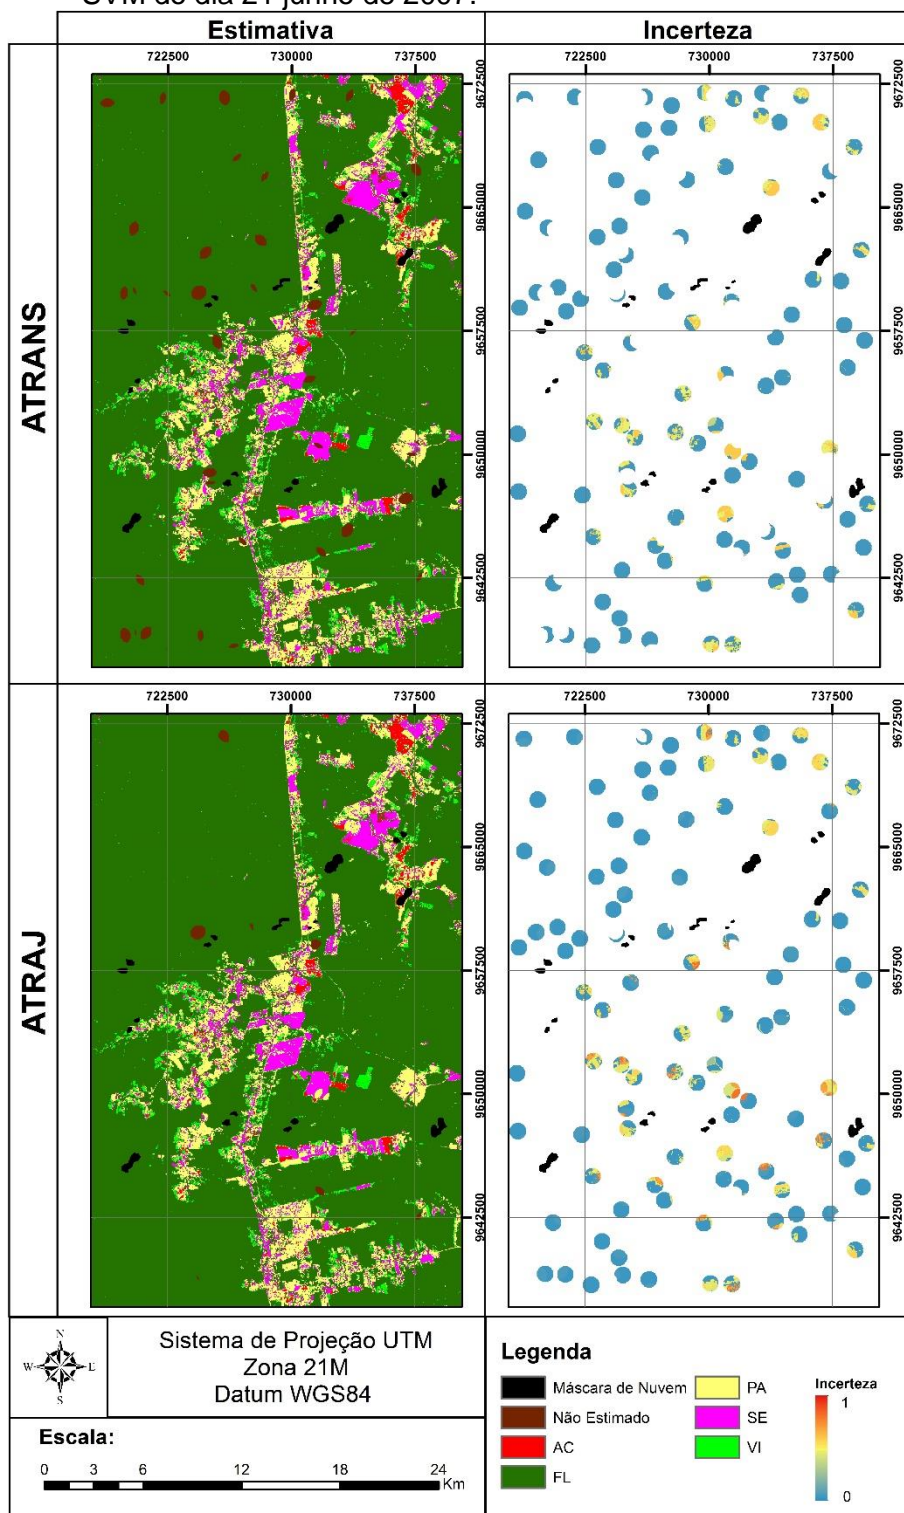
Figura F.6 - Estimativa e incerteza da imagem Landsat-5/TM classificada pelo método RF do dia 28 junho de 2010.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

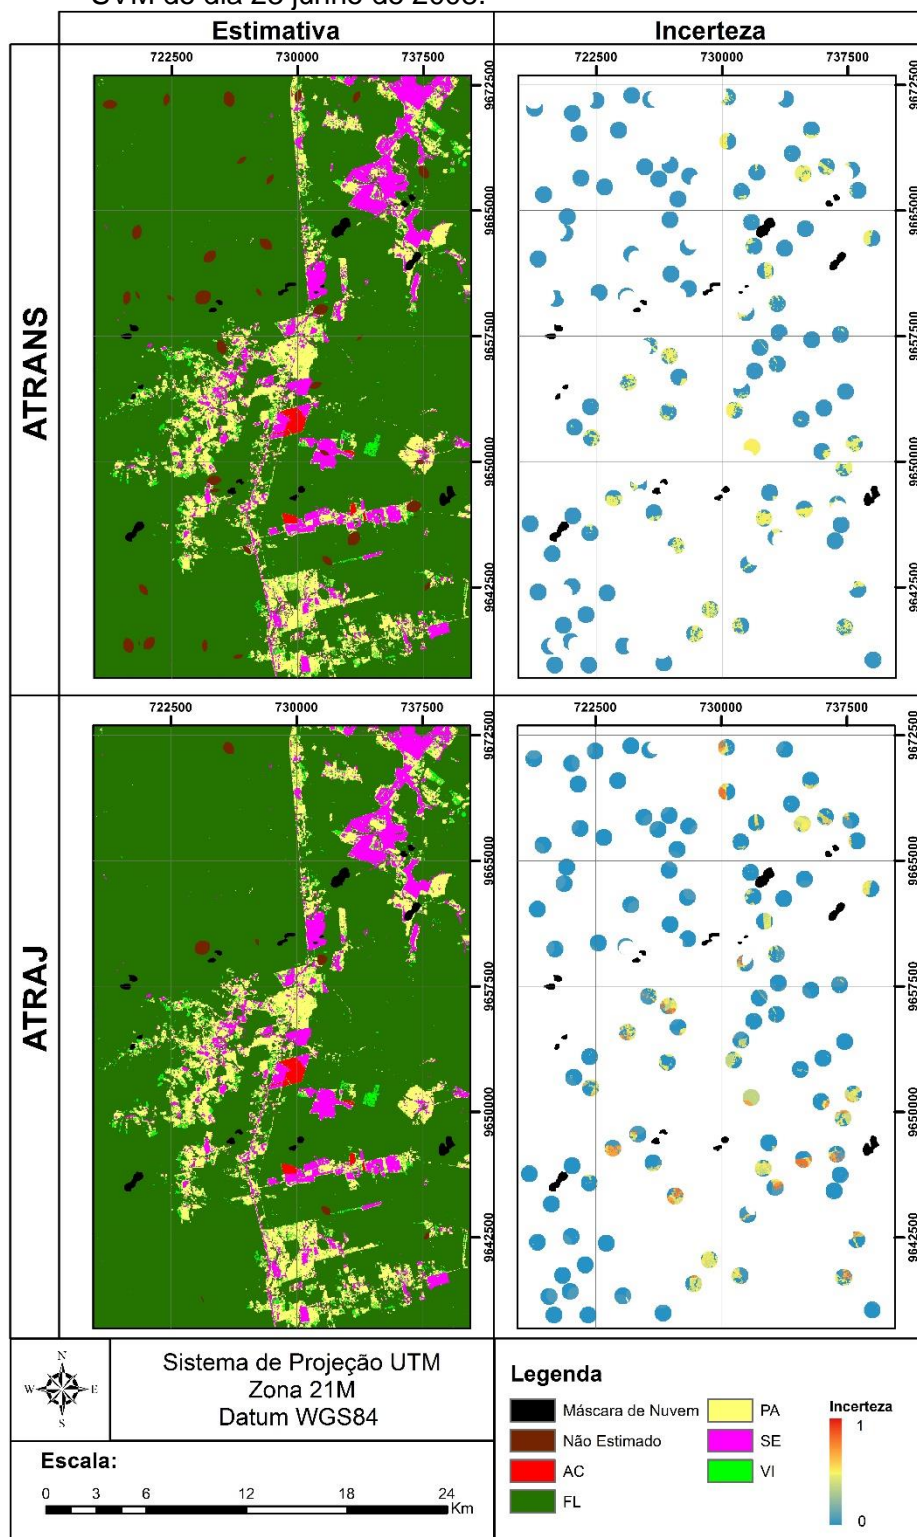
Figura F.7 - Estimativa e incerteza da imagem Landsat-5/TM classificada pelo método SVM do dia 21 junho de 2007.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

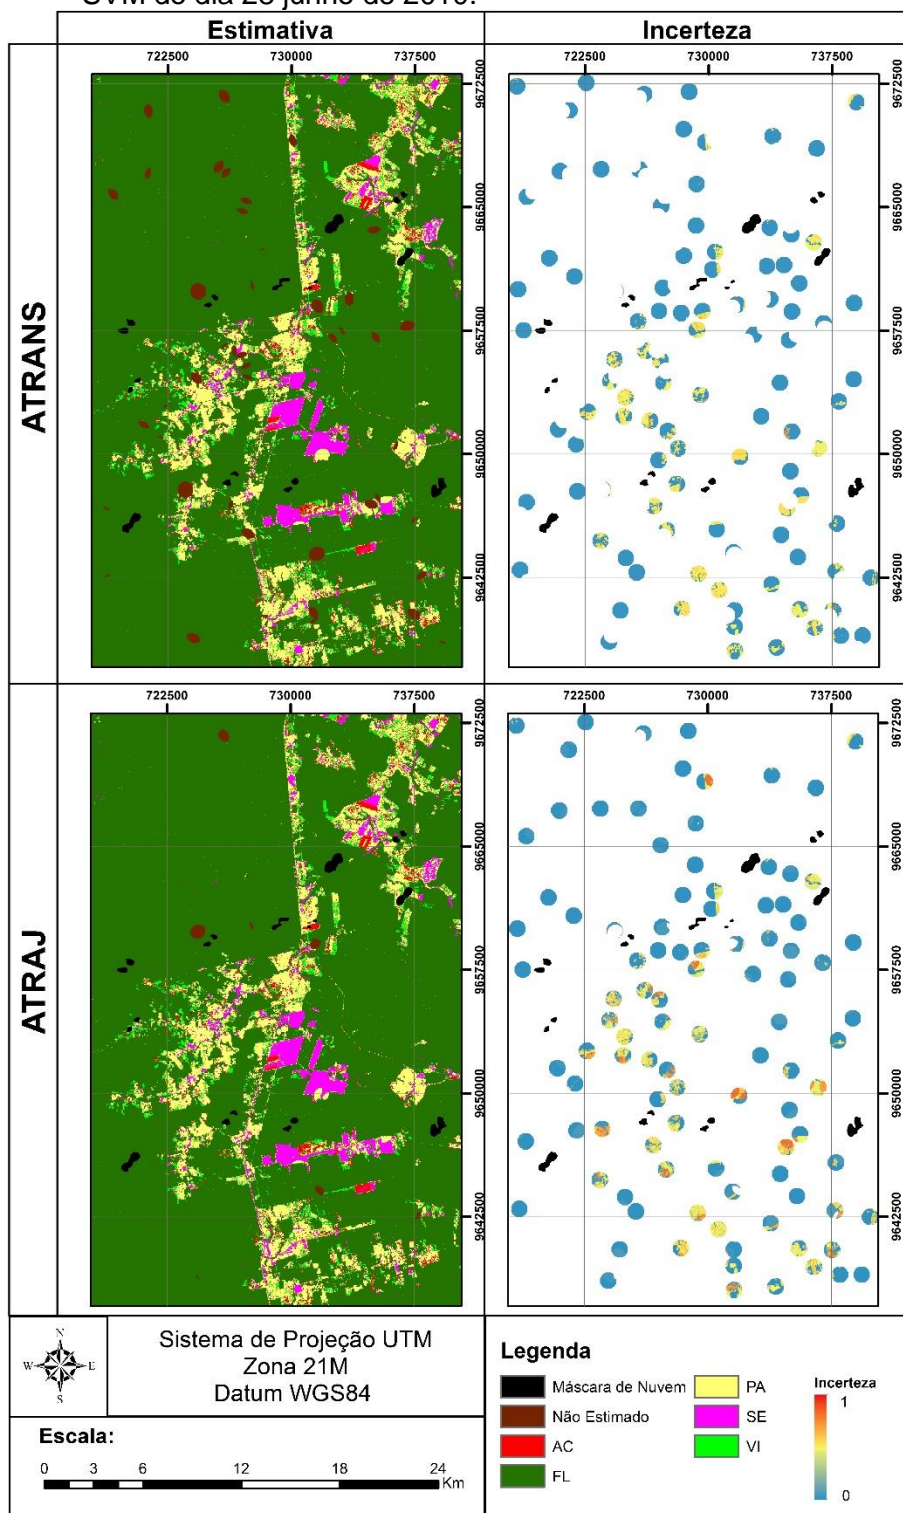
Figura F.8 - Estimativa e incerteza da imagem Landsat-5/TM classificada pelo método SVM do dia 23 junho de 2008.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

Figura F.9 - Estimativa e incerteza da imagem Landsat-5/TM classificada pelo método SVM do dia 28 junho de 2010.



AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

## APÊNDICE G – ESTATÍSTICAS DAS INCERTEZAS SOBRE O MÉTODO DA ANÁLISE DE TRAJETÓRIAS (ATRAJ)

Nesse apêndice são encontradas as estatísticas das incertezas calculadas sobre as classes estimadas a partir do método de análise de trajetórias para ambos os estudos de caso (imagens do Sentinel-2/MSI e do Landsat-5/TM). Estas estatísticas são apresentadas nas Tabelas G.1 a G.18.

Tabela G.1 – Estatísticas das incertezas por classe para classificação MAXVER da imagem Sentinel-2/MSI de 11 de julho de 2017.

Classe	Incerteza			
	Mínimo	Máximo	Média	Desvio-padrão
FL	0,014	0,64	0,024	0,054
AC	0,34	0,64	0,38	0,043
PS	0,10	0,51	0,19	0,12
PL	0,34	0,72	0,42	0,11
AP	0,083	0,51	0,36	0,088
SE	0,13	0,46	0,16	0,015
CA	0,00	0,63	0,22	0,21

AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

Tabela G.2 – Estatísticas das incertezas por classe para classificação MAXVER da imagem Sentinel-2/MSI de 16 de julho de 2017.

Classe	Incerteza			
	Mínimo	Máximo	Média	Desvio-padrão
FL	0,0092	0,47	0,028	0,079
AC	0,16	0,64	0,44	0,17
PS	0,090	0,51	0,18	0,14
PL	0,25	0,67	0,38	0,16
AP	0,0	0,74	0,31	0,18
SE	0,077	0,57	0,099	0,085
CA	0,020	0,36	0,062	0,077

AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

Tabela G.3 – Estatísticas das incertezas por classe para classificação MAXVER da imagem Sentinel-2/MSI de 26 de julho de 2017.

Classe	Incerteza			
	Mínimo	Máximo	Média	Desvio-padrão
FL	0,0070	0,46	0,016	0,040
AC	*			
PS	0,18	0,48	0,23	0,083
PL	0,048	0,72	0,29	0,17
AP	0,19	0,74	0,26	0,13
SE	0,16	0,57	0,20	0,12
CA	0,21	0,33	0,22	0,038

\* Não houve estimativas para a classe.

AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

Tabela G.4 – Estatísticas das incertezas por classe para classificação RF da imagem Sentinel-2/MSI de 11 de julho de 2017.

Classe	Incerteza			
	Mínimo	Máximo	Média	Desvio-padrão
FL	0,0046	0,44	0,015	0,055
AC	0,16	0,75	0,39	0,11
PS	0,15	0,48	0,23	0,12
PL	0,30	0,62	0,38	0,12
AP	0,16	0,64	0,48	0,073
SE	0,060	0,72	0,22	0,17
CA	0,013	0,39	0,20	0,18

AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

Tabela G.5 – Estatísticas das incertezas por classe para classificação RF da imagem Sentinel-2/MSI de 16 de julho de 2017.

Classe	Incerteza			
	Mínimo	Máximo	Média	Desvio-padrão
FL	0,0054	0,28	0,012	0,029
AC	0,50	0,75	0,55	0,10
PS	0,10	0,50	0,23	0,15
PL	0,10	0,58	0,38	0,16
AP	0,14	0,75	0,39	0,20
SE	0,0065	0,68	0,19	0,17
CA	0,040	0,51	0,088	0,080

AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.



Tabela G.6 – Estatísticas das incertezas por classe para classificação RF da imagem Sentinel-2/MSI de 26 de julho de 2017.

Classe	Incerteza			
	Mínimo	Máximo	Média	Desvio-padrão
FL	0,0070	0,52	0,011	0,024
AC	0,55	0,55	0,55	0,0
PS	0,19	0,51	0,28	0,11
PL	0,21	0,73	0,29	0,13
AP	0,29	0,75	0,42	0,13
SE	0,61	0,72	0,62	0,02
CA	0,24	0,35	0,26	0,04

AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

Tabela G.7 – Estatísticas das incertezas por classe para classificação SVM da imagem Sentinel-2/MSI de 11 de julho de 2017.

Classe	Incerteza			
	Mínimo	Máximo	Média	Desvio-padrão
FL	0,0071	0,67	0,027	0,086
AC	0,20	0,72	0,42	0,11
PS	0,15	0,45	0,22	0,11
PL	0,35	0,59	0,43	0,099
AP	0,0	0,63	0,47	0,10
SE	0,16	0,56	0,17	0,059
CA	0,024	0,31	0,087	0,11

AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

Tabela G.8 – Estatísticas das incertezas por classe para classificação SVM da imagem Sentinel-2/MSI de 16 de julho de 2017.

Classe	Incerteza			
	Mínimo	Máximo	Média	Desvio-padrão
FL	0,0065	0,39	0,015	0,045
AC	0,48	0,72	0,53	0,10
PS	0,16	0,50	0,25	0,13
PL	0,18	0,65	0,38	0,16
AP	0,17	0,73	0,35	0,17
SE	0,038	0,51	0,048	0,056
CA	0,029	0,17	0,045	0,038

AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

Tabela G.9 – Estatísticas das incertezas por classe para classificação SVM da imagem Sentinel-2/MSI de 28 de julho de 2017.

Classe	Incerteza			
	Mínimo	Máximo	Média	Desvio-padrão
FL	0,0091	0,50	0,017	0,046
AC	0,46	0,71	0,49	0,058
PS	0,16	0,52	0,26	0,13
PL	0,23	0,59	0,32	0,12
AP	0,17	0,73	0,36	0,14
SE	0,14	0,56	0,18	0,11
CA	0,14	0,31	0,16	0,054

AC = Área de Cultivo, AP = Área em Pousio, CA = Corpo D'água, FL = Formação Florestal, PL = Pasto Limpo, PS = Pasto Sujo e SE = Solo Exposto.

Fonte: Produção do autor.

Tabela G.10 – Estatísticas das incertezas por classe para classificação MAXVER da imagem Landsat-5/TM de 21 de junho de 2007.

Classe	Incerteza			
	Mínimo	Máximo	Média	Desvio-padrão
FL	0,017	0,54	0,027	0,040
VI	0,43	0,75	0,57	0,094
PA	0,28	0,85	0,46	0,18
AC	0,66	0,66	0,66	0,00
SE	0,22	0,77	0,42	0,16

AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

Tabela G.11 – Estatísticas das incertezas por classe para classificação MAXVER da imagem Landsat-5/TM de 23 de junho de 2008.

Classe	Incerteza			
	Mínimo	Máximo	Média	Desvio-padrão
FL	0,0065	0,59	0,034	0,099
VI	0,30	0,70	0,46	0,19
PA	0,18	0,78	0,44	0,20
AC	*			
SE	0,49	0,77	0,55	0,069

\* Não houve estimativas para a classe.

AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

Tabela G.12 – Estatísticas das incertezas por classe para classificação MAXVER da imagem Landsat-5/TM de 28 de junho de 2010.

Classe	Incerteza			
	Mínimo	Máximo	Média	Desvio-padrão
FL	0,020	0,51	0,030	0,038
VI	0,29	0,75	0,48	0,13
PA	0,49	0,85	0,55	0,10
AC	*			
SE	0,037	0,68	0,63	0,16
* Não houve estimativas para a classe.				

AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

Tabela G.13 – Estatísticas das incertezas por classe para classificação RF da imagem Landsat-5/TM de 21 de junho de 2007.

Classe	Incerteza			
	Mínimo	Máximo	Média	Desvio-padrão
FL	0,032	0,55	0,047	0,068
VI	0,53	0,83	0,61	0,10
PA	0,26	0,79	0,44	0,16
AC	*			
SE	0,33	0,80	0,50	0,12
* Não houve estimativas para a classe.				

AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

Tabela G.14 – Estatísticas das incertezas por classe para classificação RF da imagem Landsat-5/TM de 23 de junho de 2008.

Classe	Incerteza			
	Mínimo	Máximo	Média	Desvio-padrão
FL	0,0028	0,62	0,030	0,093
VI	0,51	0,63	0,53	0,045
PA	0,28	0,79	0,49	0,17
AC	*			
SE	0,45	0,80	0,50	0,095
* Não houve estimativas para a classe.				

AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

Tabela G.15 – Estatísticas das incertezas por classe para classificação RF da imagem Landsat-5/TM de 28 de junho de 2010.

Classe	Incerteza			
	Mínimo	Máximo	Média	Desvio-padrão
FL	0,015	0,67	0,048	0,11
VI	0,39	0,83	0,63	0,088
PA	0,46	0,79	0,55	0,11
AC	*			
SE	0,059	0,47	0,25	0,15

\* Não houve estimativas para a classe.

AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

Tabela G.16 – Estatísticas das incertezas por classe para classificação SVM da imagem Landsat-5/TM de 21 de junho de 2007.

Classe	Incerteza			
	Mínimo	Máximo	Média	Desvio-padrão
FL	0,0296	0,61	0,045	0,070
VI	0,51	0,86	0,62	0,12
PA	0,432	0,82	0,56	0,12
AC	0,75	0,75	0,75	0,00
SE	0,2	0,71	0,47	0,12

AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

Tabela G.17 – Estatísticas das incertezas por classe para classificação SVM da imagem Landsat-5/TM de 23 de junho de 2008.

Classe	Incerteza			
	Mínimo	Máximo	Média	Desvio-padrão
FL	0,0038	0,64	0,033	0,099
VI	0,67	0,67	0,67	0,0
PA	0,36	0,79	0,53	0,14
AC	*			
SE	0,35	0,81	0,52	0,21

\* Não houve estimativas para a classe.

AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

Tabela G.18 – Estatísticas das incertezas por classe para classificação SVM da imagem Landsat-5/TM de 28 de junho de 2010.

Classe	Incerteza			
	Mínimo	Máximo	Média	Desvio-padrão
FL	0,016	0,86	0,044	0,096
VI	0,58	0,66	0,65	0,012
PA	0,42	0,82	0,53	0,12
AC	*			
SE	0,042	0,81	0,67	0,14

\* Não houve estimativas para a classe.

AC = Área de Cultivo, FL = Formação Florestal, PA = Pastagem, SE = Solo Exposto e VI = Vegetação Secundária em Estágio Inicial de Regeneração.

Fonte: Produção do autor.

## **PUBLICAÇÕES TÉCNICO-CIENTÍFICAS EDITADAS PELO INPE**

### **Teses e Dissertações (TDI)**

Teses e Dissertações apresentadas nos Cursos de Pós-Graduação do INPE.

### **Manuais Técnicos (MAN)**

São publicações de caráter técnico que incluem normas, procedimentos, instruções e orientações.

### **Notas Técnico-Científicas (NTC)**

Incluem resultados preliminares de pesquisa, descrição de equipamentos, descrição e ou documentação de programa de computador, descrição de sistemas e experimentos, apresentação de testes, dados, atlas, e documentação de projetos de engenharia.

### **Relatórios de Pesquisa (RPQ)**

Reportam resultados ou progressos de pesquisas tanto de natureza técnica quanto científica, cujo nível seja compatível com o de uma publicação em periódico nacional ou internacional.

### **Propostas e Relatórios de Projetos (PRP)**

São propostas de projetos técnico-científicos e relatórios de acompanhamento de projetos, atividades e convênios.

### **Publicações Didáticas (PUD)**

Incluem apostilas, notas de aula e manuais didáticos.

### **Publicações Seriadas**

São os seriados técnico-científicos: boletins, periódicos, anuários e anais de eventos (simpósios e congressos). Constam destas publicações o International Standard Serial Number (ISSN), que é um código único e definitivo para identificação de títulos de seriados.

### **Programas de Computador (PDC)**

São as sequências de instruções ou códigos, expressos em uma linguagem de programação compilada ou interpretada, a ser executada por um computador para alcançar um determinado objetivo. São aceitos tanto programas fonte quanto executáveis.

### **Pré-publicações (PRE)**

Todos os artigos publicados em periódicos, anais e como capítulos de livros.