



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21b/2016/01.28.18.56-TDI

**DETECÇÃO DE MUDANÇAS DA COBERTURA DA
TERRA NA REGIÃO DA FLORESTA NACIONAL DE
TAPAJÓS UTILIZANDO DADOS DE MÚLTIPLOS
SENSORES**

Daniela Souza dos Anjos

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Luciano Vieira Dutra, e Sidnei João Siqueira Sant'Anna, aprovada em 23 de fevereiro de 2016.

URL do documento original:

<http://urlib.net/8JMKD3MGP3W34P/3L42DJE>

INPE
São José dos Campos
2016

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

Fax: (012) 3208-6919

E-mail: pubtc@inpe.br

COMISSÃO DO CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELECTUAL DO INPE (DE/DIR-544):

Presidente:

Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação (CPG)

Membros:

Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (CST)

Dr. André de Castro Milone - Coordenação de Ciências Espaciais e Atmosféricas (CEA)

Dra. Carina de Barros Melo - Coordenação de Laboratórios Associados (CTE)

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

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

Dr. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

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

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon

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

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Duca Barbedo - Serviço de Informação e Documentação (SID)

Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SID)

EDITORAÇÃO ELETRÔNICA:

Marcelo de Castro Pazos - Serviço de Informação e Documentação (SID)

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



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21b/2016/01.28.18.56-TDI

**DETECÇÃO DE MUDANÇAS DA COBERTURA DA
TERRA NA REGIÃO DA FLORESTA NACIONAL DE
TAPAJÓS UTILIZANDO DADOS DE MÚLTIPLOS
SENSORES**

Daniela Souza dos Anjos

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Luciano Vieira Dutra, e Sidnei João Siqueira Sant'Anna, aprovada em 23 de fevereiro de 2016.

URL do documento original:

<http://urlib.net/8JMKD3MGP3W34P/3L42DJE>

INPE
São José dos Campos
2016

Dados Internacionais de Catalogação na Publicação (CIP)

Anjos, Daniela Souza dos.

An58d Detecção de mudanças da cobertura da terra na região da floresta nacional de tapajós utilizando dados de múltiplos sensores / Daniela Souza dos Anjos. – São José dos Campos : INPE, 2016.

xxvi + 157 p. ; (sid.inpe.br/mtc-m21b/2016/01.28.18.56-TDI)

Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016.

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

1. Detecção de mudança. 2. Multisensor. 3. SAR. 4. Floresta tropical. I.Título.

CDU 528.8:502.2/811.5



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

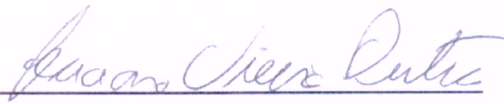
This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): **Daniela Souza dos Anjos**

Título: "DETECÇÃO DE MUDANÇAS DA COBERTURA DA TERRA NA REGIÃO DA FLORESTA NACIONAL DE TAPAJOS UTILIZANDO DADOS DE MÚLTIPLOS SENSORES".

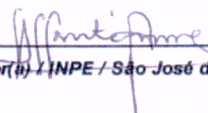
Aprovado (a) pela Banca Examinadora
em cumprimento ao requisito exigido para
obtenção do Título de **Doutor(a)** em
Sensoriamento Remoto

Dr. Luciano Vieira Dutra



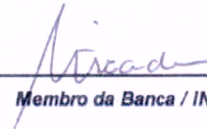
Presidente / Orientador(a) / INPE / SJCampos - SP

Dr. Sidnei João Siqueira Sant'Anna



Orientador(a) / INPE / São José dos Campos - SP

Dra. Maria Isabel Sobral Escada



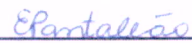
Membro da Banca / INPE / SJCampos - SP

Dr. Carlos Alberto Felgueiras



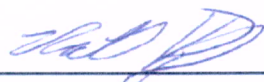
Membro da Banca / INPE / SJCampos - SP

Dra. Eliana Pantaleão



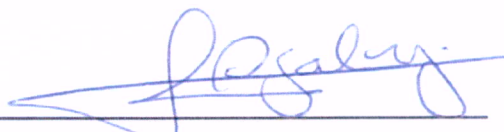
Convidado(a) / UFU / Patos de Minas - MG

Dr. Nathan David Vogt



Convidado(a) / IPAM / São José dos Campos - SP

Dr. Rogerio Galante Negri



Convidado(a) / UNESP / São José dos Campos - SP

Este trabalho foi aprovado por:

maioria simples

unanimidade

“Como são belos sobre as montanhas os pés do mensageiro que anuncia a felicidade, que traz as boas novas e anuncia a libertação, que diz a Sião: Teu Deus reina!”

Isaías 52:7

*A meus pais Jaime e Margarida, as minhas irmãs Camila e Fabrícia e àquele
que me espera pacientemente Mazdak Khavajian.*

AGRADECIMENTOS

Agradeço a Deus pelo dom da vida, pela sabedoria, discernimento e paciência que mais do que nunca foram fundamentais.

A minha família, por estarem sempre presentes em minha vida, principalmente nos momentos difíceis.

Ao meu noivo Mazdak Khavajian pelo amor, pelo apoio e principalmente pela paciência com que me espera.

Aos meus orientadores Professores Doutores Luciano Vieira Dutra, Sidnei João Siqueira Sant'Anna e Dengsheng Lu.

Aos Doutores Eliana Pantaleão, Nathan Vogt, Rogério Negri, Maria Isabel Escada e Carlos Felgueiras pelas valiosas contribuições.

A todos os professores do corpo docente do Programa de Pós-Graduação em Sensoriamento Remoto pela fundamental importância em minha formação acadêmica.

Aos Professores Doutores Messias Meneguette Jr. e João Osvaldo Rodrigues Nunes, que me orientaram durante o mestrado, e a todos os professores que passaram pela minha vida acadêmica e me fazendo querer ser um de vocês.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão das bolsas de doutorado no Brasil e de doutorado sanduíche durante o desenvolvimento desta pesquisa

Ao Instituto Nacional de Pesquisas Espaciais (INPE) e a Michigan State University (MSU) pela estrutura concedida a mim para o desenvolvimento deste trabalho.

Ao Instituto Chico Mendes de Conservação da Biodiversidade - ICMBio (MMA) por meio da Autorização SISBIO de número 38157-2 e ao Programa de Grande

Escala da Biosfera-Atmosfera na Amazônia (*Large-Scale Biosphere Atmosphere Experiment in Amazonia- LBA*).

Aos colegas da senzala, Flavia Toledo Martins, Maria Antônia Falcão, Mariane Reis, Patrícia Genovez e Leonardo Torres pelas conversas, discussões e pelos cafés.

Aos amigos Michelle Parreira, Sherfis Ruwer, Thaisa Pegoraro, Ramon Bicudo, Dalton Ferreira e Julliana Ribeiro por terem sido a minha família nos USA durante o doutorado sanduíche.

A todos os meus amigos pelos momentos de alegria e diversão, mas principalmente pela paciência e companheirismo nos momentos de cansaço, apreensão e dificuldades.

Vocês são parte fundamental deste trabalho.

Obrigada.

RESUMO

Florestas tropicais são áreas de grande relevância para o ambiente global e estudos capazes de detectar e tipificar as mudanças ocorridas nestas regiões têm se mostrado de grande importância. O sensoriamento remoto tem sido a maior fonte de dados para processos de detecção de mudanças, porém, a constante cobertura de nuvens que afeta regiões de floresta torna difícil a obtenção de dados ópticos de qualidade em datas específicas. O uso de dados de diferentes sensores em processos de detecção de mudanças se mostra como uma alternativa ao problema, mas apresenta, entretanto, diversas dificuldades, principalmente quando envolve a integração de dados de Radares de Abertura Sintética (SAR - do inglês Synthetic Aperture Radar) e dados ópticos. Neste contexto, o presente trabalho se propõe a avaliar a acurácia da detecção de mudanças na região da Floresta Nacional do Tapajós, na Amazônia Brasileira, entre os anos de 2009 e 2013, ao se empregar dados multissensores (SAR e óptico). Para tanto, dados Radarsat-2 e EO-1 ALI foram utilizados. Dentre os diversos métodos de detecção de mudanças existentes os métodos de comparação pós-classificação e classificação direta, baseados em classificações *pixel a pixel*, foram selecionados para o estudo por se adequarem aos diferentes tipos de dados utilizados. Diferentes conjuntos de atributos foram classificados repetidas vezes, por meio dos classificadores supervisionados Máquina de Vetor de Suporte (SVM do inglês Support Vector Machine) e Máxima Verossimilhança (Maxver), na busca do melhor conjunto de dados para cada método de detecção de mudança. De acordo com trabalhos de campo realizados na região 9 classes de cobertura da terra, para cada ano, foram adotadas no estudo, o que resultou em 81 potenciais classes de mudança e não mudança. No entanto, para o intervalo de estudo, apenas 14 dentre essas 81 classes foram encontradas em campo. Devido a essa diferença um método de validação das amostras obtidas em campo foi proposto. Após essa validação as classes não encontradas em campo, mas detectadas pela comparação pós-classificação foram agrupadas, de acordo com conhecimento a priori, em possíveis e não encontradas e impossíveis ou improváveis. Este agrupamento tornou os resultados dos diferentes métodos de detecção de mudança adotados comparáveis. No entanto, as classes criadas transformaram as matrizes de confusão associadas aos mapas de mudança obtidos por comparação pós-classificação em matrizes não quadradas, para as quais os índices de validação precisaram ser repensados. A repetição das classificações de cada conjunto de dados, a partir de diferentes amostras de treinamento, fez com que informações de incerteza também pudessem ser associadas aos mapas de mudança. Os resultados obtidos através da detecção de mudança por classificação direta se destacaram e comprovaram a potencialidade dos dados multissensor, SAR e óptico, na obtenção de mapas de mudança acurados para regiões de floresta.

LAND COVER CHANGE DETECTION IN TAPAJÓS NATIONAL FOREST USING MULTISENSOR DATA

ABSTRACT

Tropical forests are areas of great relevance to the global environment. Studies to detect and classify the changes in forest regions have proved to be of great importance in protecting these areas. Remote sensing has been a major source of data for change detection processes. However, the constant cloud cover that affects these regions turns difficult to obtain quality optical data on specific dates. The use of different data types in change detection process is shown as an alternative to solve the problem. However, many difficulties are encountered in this process, particularly when it involves SAR and optical data integration. In this context, this study aims to evaluate the capabilities of multisensor data integration (SAR and optical) for a change detection study in forest areas. Radarsat-2 data and EO-1 ALI were used. The study comprises a region belonging to the Tapajós National Forest in the Brazilian Amazon, between the years 2009 and 2013. The change detection methods by post classification comparison and direct classification, *pixel to pixel* based, were selected for the study. These methods are appropriate for different types of data used. Different sets of attributes were classified in order to select the best set of data for each change detection method. The supervised classifiers Support Vector Machine and Maximum Likelihood were used in the study. Polarimetric decompositions of Cloude e Pottier and Freeman e Durden were introduced in an attempt to improve the accuracy of SAR classifications. A method to validate the 14 change/no change classes found in the field for the time interval is proposed. This is necessary because the 9 land cover classes for each year result in 81 potential change/no change classes. After the validation of the 14 change/no change classes, used in the study, the classes detected by the post classification comparison method but not found in the field could be merged. This merge makes the change detection results by post classification comparison and direct classification methods comparable. However, the confusion matrices obtained after the clustering become non square matrices. For these classifications the validation indices needed to be rethought. Due to repetition of the classifications, for each data set using different training samples, uncertainty information is also associated with final maps. The results obtained by direct classification change detection stand out and prove the capacity of using multi-sensor data, SAR and optical, for detecting changes in forest area.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 – Atenuação atmosférica em dados micro-ondas devido à chuva. .	14
Figura 2.2 – Penetração dos diferentes tipos de sinal em uma floresta hipotética.	16
Figura 3.1 – Localização da área de estudo (Imagem EO-1 ALI R-MS2, G-MS4', B-MS7).	39
Figura 3.2 – a) Imagem Radarsat FQ06 (R-HH, G-HV e B-VV), b) Imagem Radarsat FQ06 (R-HH, G-HV e B-VV), c) Imagem EO-1 ALI (R-MS2, G-MS4', B-MS7).	44
Figura 3.3 – a) Localização das fotos nos anos de 2009 e 2013 e b) localização dos pontos de controle de alta precisão utilizados para fins de registro.	45
Figura 3.4 – Localização das estações pluviométricas próximas a área de estudo.	46
Figura 3.5 – Média mensal de chuva, na área de estudo, entre os anos de 2009 e 2013.	47
Figura 4.1 – Fluxograma das atividades do grupo I.	50
Figura 4.2 – Fluxograma das atividades do grupo II.	50
Figura 4.3 – Exemplo das classes de cobertura da terra definidas para o estudo: a) Agricultura; b) Solo Exposto, c) Pasto Limpo, d) Pasto Sujo; e) Superfícies Impermeáveis; f) Floresta Madura; g) Sucessão Secundária Inicial; h) Sucessão Secundária Intermediária; e i) Água.	55
Figura 4.4 – Localização das amostras para o ano de 2009: a) treinamento e b) validação, ambas sobre os dados Radarsat - 2 em modo FQ06 (composição RGB – HH/HV/VV).	56
Figura 4.5 – a) Localização das amostras para o ano de 2013: a) treinamento e b) validação, ambas sobre os dados EO-1 ALI (banda MS-2).	57
Figura 4.6 – a) Localização das amostras de treinamento para mudança e não mudança entre 2009 e 2013 e b) localização das amostras de validação para mudança entre 2009 e 2013, ambas sobre a banda 3 dos dados EO-1 ALI.	75
Figura 4.7 – a) Encadeamento das etapas realizadas para classificação avaliação dos mapas de mudança obtidos pelos métodos comparação pós-classificação e classificação direta.	78
Figura 5.1 – Valores de exatidão global mínima, média e máxima das classificações de cobertura da terra a partir de dados SAR para o ano de 2009.	85
Figura 5.2 – Valores de exatidão global mínima, média e máxima das classificações de cobertura da terra a partir de dados SAR associados a decomposições polarimétricas para o ano de 2009.	85
Figura 5.3 – Valores de exatidão global mínima, média e máxima das classificações de cobertura da terra a partir de dados ópticos para o ano de 2013.	86

Figura 5.4 – a) Melhor classificação SAR em modo FQ06 a partir do classificador Maxver e b) mapa de incerteza da classificação ($Eg = 0,296$; $\sigma = 0,012$).	91
Figura 5.5 – Matriz de confusão da melhor classificação SAR em modo FQ06 a partir do classificador Maxver ($Eg = 0,296$; $\sigma = 0,012$).	92
Figura 5.6 – a) Melhor classificação SAR em modo FQ06 a partir do classificador SVM e b) mapa de incerteza da classificação ($Eg = 0,293$; $\sigma = 0,012$).	93
Figura 5.7 – Matriz de confusão da melhor classificação SAR em modo FQ06 obtida pelo classificador SVM ($Eg = 0,293$; $\sigma = 0,012$).	94
Figura 5.8 – a) Melhor classificação SAR em modo FQ13 a partir do classificador Maxver e b) mapa de incerteza da classificação ($Eg = 0,272$; $\sigma = 0,011$).	95
Figura 5.9 – Matriz de confusão da melhor classificação SAR em modo FQ13 a partir do classificador Maxver ($Eg = 0,272$; $\sigma = 0,011$).	96
Figura 5.10 – a) Melhor classificação SAR em modo FQ13 a partir do classificador SVM e b) mapa de incerteza da classificação ($Eg = 0,290$; $\sigma = 0,012$).	97
Figura 5.11 – Matriz de confusão da melhor classificação SAR em modo FQ13 a partir do classificador SVM ($Eg = 0,290$; $\sigma = 0,012$).	98
Figura 5.12 – a) Mapa contendo a melhor classificação SAR com decomposição polarimétrica obtida (classificador SVM, modo FQ06, canais (HV+VH)/2, VV, P _V , P _D e P _S) e b) mapa de incerteza da classificação ($Eg = 0,325$; $\sigma = 0,013$).	100
Figura 5.13 – Matriz de confusão da melhor classificação SAR com decomposição polarimétrica obtida (classificador SVM, modo FQ06, canais (HV+VH)/2, VV, P _V , P _D e P _S) ($Eg = 0,325$; $\sigma = 0,013$).	101
Figura 5.14 – a) Melhor classificação EO-1 ALI a partir do classificador Maxver e b) mapa de incerteza da classificação ($Eg = 0,904$; $\sigma = 0,008$).	102
Figura 5.15 – Matriz de confusão da melhor classificação EO-1 ALI a partir do classificador Maxver ($Eg = 0,904$; $\sigma = 0,008$).	103
Figura 5.16 – a) Melhor classificação EO-1 ALI a partir do classificador SVM e b) mapa de incerteza da classificação ($Eg = 0,933$; $\sigma = 0,007$).	104
Figura 5.17 – Matriz de confusão da melhor classificação EO-1 ALI a partir do classificador SVM ($Eg = 0,933$; $\sigma = 0,007$).	105
Figura 5.18 – a) Mapa de mudanças entre os anos de 2009 e 2013 gerado por comparação pós-classificação das classificações Maxver FQ06 e EO-1 ALI mais acuradas e b) incerteza da detecção de mudança ($Eg = 0,251$).	111
Figura 5.19 – a) Mapa de mudanças entre os anos de 2009 e 2013 gerado por comparação pós-classificação das classificações Maxver FQ13 e EO-1 ALI mais acuradas b) incerteza da detecção de mudança ($Eg = 0,264$).	112
Figura 5.20 – Matrizes de confusão dos mapas de mudanças gerados por comparação pós-classificação, a partir das classificações Maxver mais acuradas a) FQ06 e EO-1 ALI ($Eg = 0,251$) e b) FQ13 e EO-1 ALI ($Eg = 0,264$).	113

Figura 5.21 – a) Mapa de mudanças entre os anos de 2009 e 2013 gerado por comparação pós-classificação das classificações SVM FQ06 e EO-1 ALI mais acuradas b) incerteza da detecção de mudança ($Eg = 0,222$).....	114
Figura 5.22 – a) Mapa de detecção de mudanças entre os anos de 2009 e 2013 gerado por comparação pós-classificação, das classificações SVM FQ13 e EO-1 ALI mais acuradas b) incerteza da detecção de mudança ($Eg = 0,268$).....	115
Figura 5.23 – Matrizes de confusão dos mapas de mudanças gerados por comparação pós-classificação, a partir das classificações SVM mais acuradas a) FQ06 e EO-1 ALI ($Eg = 0,222$) e b) FQ13 e EO-1 ALI ($Eg = 0,268$).	116
Figura 5.24 – a) Mapa de detecção de mudanças entre os anos de 2009 e 2013 gerado por comparação pós-classificação, das classificações SVM para dados SAR associados a dados de decomposição polarimétrica e EO-1 ALI mais acuradas b) incerteza da detecção de mudança ($Eg = 0,233$).....	117
Figura 5.25 – Matriz de confusão do mapa de mudanças gerado por comparação pós-classificação, a partir das classificações SVM dos dados SAR associados a dados de decomposição polarimétrica e EO-1 ALI mais acuradas ($Eg = 0,233$).	118
Figura 5.26 – a) Mapa de mudanças entre os anos de 2009 e 2013 gerado por classificação direta a partir do classificador Maxver para dados FQ06 e EO-1 ALI b) incerteza da detecção de mudança ($Eg = 0,836$; $\sigma = 0,011$).....	123
Figura 5.27 – a) Mapa de mudanças entre os anos de 2009 e 2013 gerado por classificação direta a partir do classificador Maxver para dados FQ13 e EO-1 ALI b) incerteza da detecção de mudança ($Eg = 0,821$; $\sigma = 0,01$).....	124
Figura 5.28 – Matrizes de confusão dos mapas de mudanças gerados por classificação direta, a partir das classificações Maxver para os dados a) FQ06 e EO-1 ALI ($Eg = 0,836$; $\sigma = 0,011$) e b) FQ13 e EO-1 ALI ($Eg = 0,821$; $\sigma = 0,01$).	125
Figura 5.29 – a) Mapa de mudanças entre os anos de 2009 e 2013 gerado por classificação direta a partir do classificador SVM para dados FQ06 e EO-1 ALI b) incerteza da detecção de mudança ($Eg = 0,820$; $\sigma = 0,012$).	126
Figura 5.30 – a) Mapa de detecção de mudanças entre os anos de 2009 e 2013 gerado por classificação direta a partir do classificador SVM para dados FQ13 e EO-1 ALI b) incerteza da detecção de mudança ($Eg = 0,798$; $\sigma = 0,009$)..	127
Figura 5.31 – Matrizes de confusão dos mapas de mudanças gerados por classificação direta, a partir das classificações SVM para os dados a) FQ06 e EO-1 ALI ($Eg = 0,82$; $\sigma = 0,012$) e b) FQ13 e EO-1 ALI($Eg = 0,798$; $\sigma = 0,009$).	128
Figura 5.32 – a) Mapa de detecção de mudanças entre os anos de 2009 e 2013 gerado por classificação direta a partir do classificador SVM para dados FQ06 associadas aos canais FD e EO-1 ALI b) incerteza da detecção de mudança ($Eg = 0,776$; $\sigma = 0,013$).....	129
Figura 5.33 – Matriz de confusão do mapa de mudanças gerado por classificação direta, a partir da classificação SVM dos dados FQ06 associados aos canais FD e EO-1 ALI.....	130
Figura 5.34 – a) Mapa de detecção de mudanças entre os anos de 2009 e 2013 por comparação pós-classificação com maior valor de exatidão global, obtido	

através do classificador SVM para os conjuntos de dados FQ13, canais HH, (HV+VH)/2, VV, e EO-1 ALI com 9 bandas e b) incerteza da detecção de mudança.....	134
Figura 5.35 – a) Mapa de detecção de mudanças entre os anos de 2009 e 2013 por classificação direta com maior valor de exatidão global, obtido através do classificador Maxver, para os conjuntos de dados FQ06, canal (HV+VH)/2 e EO-1 ALI, bandas 3,6,7,9 e b) incerteza da detecção de mudança.	135
Figura 5.36 – Matrizes de confusão dos mapas de mudanças entre os anos de 2009 e 2013 com maiores valores de exatidão gerados por a) comparação pós-classificação, a partir do classificador SVM, para os conjuntos de dados FQ13, canais HH,(HV+VH)/2, VV, e EO-1 ALI com 9 bandas e b) classificação direta, a partir do classificador Maxver, para os conjuntos de dados FQ06, canal (HV+VH)/2 e EO-1 ALI, bandas 3,6,7,9.....	136
Figura 5.37 – Mapas de cobertura da terra para os anos de a) 2009 ($Eg = 0,742$; $\sigma = 0,013$) e b) 2013 ($Eg = 0,824$; $\sigma = 0,007$), obtidos a partir da inferência de classes de cobertura com base no mapa de detecção de mudanças por classificação direta, pelo classificador Maxver, para os conjuntos de dados FQ06, canal (HV+VH)/2 e EO-1 ALI, bandas 3,6,7,9.	138
Figura 5.38 – Matrizes de confusão dos mapas de cobertura da terra para os anos de a) 2009 e b) 2013, obtidos a partir da inferência de classes de cobertura com base no mapa de detecção de mudanças por classificação direta, pelo classificador Maxver, para os conjuntos de dados FQ06, canal (HV+VH)/2 e EO-1 ALI, bandas 3,6,7,9.....	139

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1 – Matriz de confusão genérica.	23
Tabela 3.1 – Características dos dados Radarsat-2.	41
Tabela 3.2 – Faixas espectrais dos dados EO-1 ALI – data de aquisição 05/10/2013.	42
Tabela 3.3 – Dados Pluviométricos diários, em milímetros, para os meses de setembro de 2009 e outubro de 2013 a partir das estações pluviométricas 355001 - Mutum, 254011 - KM 1707/BR-163 e 254004 - Santarém.	48
Tabela 4.1 – Quantidade de <i>pixels</i> por amostra para treinamento e validação nos anos de 2009 e 2013.	58
Tabela 4.2 – Exemplo de cálculo da máxima mínima distância JM	60
Tabela 4.3 – Formação dos conjuntos de dados SAR/óptico para detecção de mudanças.	71
Tabela 4.4 – Transição de classes entre 2009 e 2013.	72
Tabela 4.5 – Quantidade de <i>pixels</i> para as amostras de mudança e não mudança entre os anos de 2009 e 2013.	76
Tabela 5.1 – Conjuntos de atributos ópticos selecionados para as classificações.	81
Tabela 5.2 – Teste de hipótese t pareado para a reciprocidade dos alvos nos canais HV e VH.	82
Tabela 5.3 – Conjuntos de atributos SAR selecionados para as classificações.	83
Tabela 5.4 – Atributos ou conjunto de atributos selecionados para detecção de mudanças.	88
Tabela 5.5 – Incerteza média das classes nas classificações da cobertura da terra.	106
Tabela 5.6 – Conjuntos de dados de entrada para detecção de mudança por comparação pós-classificação e por classificação direta.	108
Tabela 5.7 – Incerteza acumulada média das classes na detecção de mudanças por comparação pós-classificação.	120
Tabela 5.8 – Incerteza média das classes na detecção de mudanças por classificação direta.	131

LISTA DE SIGLAS E ABREVIATURAS

A	-	Anisotropia
AG	-	Agricultura
AG-SS1	-	Agricultura para Sucessão Secundária Inicial
ALOS/PALSAR	-	<i>Advanced Land Observing Satellite/ Phased Array type L-band Synthetic Aperture Radar</i>
AVHRR	-	<i>Advanced very-high-resolution radiometer</i>
B	-	Azul
BR-163	-	Rodovia federal 163 (Cuiabá – Santarém)
BS	-	Solo Exposto
BS-AG	-	Solo Exposto para Agricultura
CCD/CBERS	-	Câmera Imageadora de Alta Resolução/Satélite Sino Brasileiro de Recursos Terrestres
CD	-	Classificação Direta
CP	-	Pasto Limpo
CP-DP	-	Pasto Limpo para Pasto Sujo
CPP	-	Comparação Pós-classificação
CP-SS1	-	Pasto Limpo para Sucessão Secundária Inicial
CVA	-	Análise do vetor de mudanças (<i>Change Vector Analysis</i>)
DCP	-	Decomposição Polarimétrica de Cloude e Pottier
DEGRAD	-	Mapeamento da Degradação Florestal na Amazônia Brasileira
DETER	-	Sistema de Detecção de Desmatamento em Tempo Real
DP	-	Pasto Sujo
DPI	-	Divisão de processamento de Imagens
DPs	-	Decomposições Polarimétricas
DP-SS1	-	Pasto Sujo para Sucessão Secundária Inicial
EO-1 ALI	-	<i>Advanced Land Imager</i> do satélite <i>Earth Observing-1</i>
ETM+	-	<i>Enhanced Thematic Mapper Plus</i>
FD	-	Decomposição Polarimétrica de Freeman e Durden
FLONA Tapajós	-	Floresta Nacional do Tapajós
FQ06	-	Fine Quad Polarization 06
FQ13	-	Fine Quad Polarization 13
G	-	Verde
GFOI	-	<i>Global Forest Observations Initiative</i>
H	-	Entropia
HH	-	Transmissão Horizontal e Recepção Horizontal
HV	-	Transmissão Horizontal e Recepção Vertical
I	-	Mudanças Impossíveis
IBAMA	-	Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis
INPE	-	Instituto Nacional de Pesquisas Espaciais
IS	-	Superfícies Impermeáveis
JM	-	Jeffries-Matusita
LISS	-	<i>Linear Imaging Self-scanning Sensor</i>
MAXVER	-	Máxima Verossimilhança
MODIS	-	<i>Moderate-Resolution Imaging Spectroradiometer</i>
MS	-	Multispectral
MSS	-	<i>Multispectral Scanner</i>

N	-	Não Mudança
NC	-	Não Classificada
NO	-	Não Observada
P	-	Mudanças Possíveis
PCA	-	Análise de componentes principais (<i>Principal Component Analysis</i>)
PCs	-	Pontos de Controle
P _D	-	Espalhamento <i>Double Bounce</i>
MF	-	Floresta Madura
PIN	-	Projeto de Integração Nacional
PRODES	-	Projeto de Monitoramento do Desmatamento na Amazônia Legal por Satélite
P _s	-	Espalhamento Superficial
P _v	-	Espalhamento Volumétrico
R	-	Vermelho
REM	-	Radiação Eletromagnética
RMS	-	Erro Médio Quadrático (<i>Root Mean Squared</i>)
SAR	-	Radar de Abertura Sintética (<i>Synthetic Aperture Radar</i>)
SIG	-	Sistemas de Informações Geográficas
SLC	-	<i>Single Look Complex</i>
SPOT-HRG	-	<i>Satellite Pour l'observation de la Terre - High Resolution Geometrical</i>
SPOT-XS	-	<i>Satellite Pour l'observation de la Terre - Multispectral</i>
SR	-	Sensoriamento Remoto
SS1	-	Sucessão Secundária Inicial
SS1-SS2	-	Sucessão Secundária Inicial para Sucessão Secundária Intermediária
SS2	-	Sucessão Secundária Intermediária
SVM	-	Máquina de vetores de suporte
TM	-	<i>Thematic Mapper</i>
U	-	Mudanças Improváveis
UK-DMC2	-	<i>United Kingdom - Disaster Monitoring Constellation 2</i>
UTM	-	Universal Transverse Mercator
VH	-	Transmissão Vertical e Recepção Horizontal
VV	-	Transmissão Vertical e Recepção Vertical
WAT	-	Água
WFI/CBERS	-	Câmera de campo largo/Satélite Sino Brasileiro de Recursos Terrestres
WGS-84	-	World Geodetic System-1984
ZEE	-	Zoneamento Ecológico-Econômico
α	-	Ângulo Alfa (Decomposição Polarimétrica de Cloude e Pottier)

LISTA DE SÍMBOLOS

B_{kl}	-	Distância Bhattacharyya
E_g	-	Exatidão Global
H_0	-	Hipótese Nula
H_1	-	Hipótese Alternativa
L_p	-	Função de Lagrange
t_{calc}	-	Valor t calculado
t_{crit}	-	Valor t crítico
μ	-	Média da classe
α	-	Nível de significância
σ	-	Desvio Padrão
$DistJM$	-	Distância JM
IC	-	Incerteza
ICA	-	Incerteza Acumulada
b	-	Número de atributos
$\#k$	-	Número de classes
i	-	Elemento indexador de classe
j	-	Elemento indexador de classe
k	-	Classe
n	-	Número de <i>Pixels</i>
$g(x)$	-	Hiperplano de Separação
μ_k	-	Vetor de Médias das Amostras da classe k
$ \cdot $	-	Determinante da matriz
$(\cdot)^T$	-	Matriz Transposta
μ_l	-	Vetor de Médias das Amostras da Classe l
$\#classificações$	-	Número Total de Classificações
$\#Classe Maj$	-	Quantidade de classificações de acordo com a Classe Majoritária
N_A	-	Quantidade de Padrões de Treinamento
ω_0	-	Escalar real
L_p	-	Função de Lagrange
y_i	-	Rótulo da classe
α_i	-	Multiplicador de Lagrange

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO.....	1
1.1. Objetivos e contribuições	6
2 DETECÇÃO DE MUDANÇAS DA COBERTURA DA TERRA.....	9
2.1. Etapas da detecção de mudanças	10
2.1.1. Aquisição das imagens	10
2.1.2. Pré-processamento das imagens.....	17
2.1.3. Métodos de detecção de mudanças.....	19
2.1.4. Avaliação da exatidão	22
2.2. Detecção de mudanças multissensor.....	24
2.2.1. Comparação pós-classificação	31
2.2.2. Classificação direta	32
2.3. Detecção de mudanças aplicada a regiões de floresta tropical.....	34
3 MATERIAIS	39
3.1. Área de estudo	39
3.2. Dados utilizados	41
4 METODOLOGIA	49
4.1. Pré-processamento	52
4.2. Definição das classes de cobertura e das amostras de treinamento e validação	53
4.3. Seleção de atributos.....	58
4.4. Decomposição polarimétrica dos dados SAR.....	62
4.5. Classificação da cobertura da terra	64
4.6. Avaliação das classificações	68
4.7. Detecção de mudança.....	70
4.7.1. Detecção de mudança por comparação pós-classificação	71
4.7.2. Detecção de mudança por classificação direta	73
4.8. Avaliação da detecção de mudança.....	76
5 RESULTADOS E DISCUSSÕES.....	81
5.1. Seleção de atributos.....	81
5.2. Classificações.....	83
5.3. Detecção de mudanças	107

6	CONSIDERAÇÕES FINAIS.....	141
6.1.	Conclusões.....	141
6.2.	Trabalhos futuros	142
	REFERÊNCIAS BIBLIOGRÁFICAS	145

1 INTRODUÇÃO

Várias regiões do mundo passam por mudanças na cobertura da terra geradas por causas naturais, antrópicas ou por uma combinação desses fatores. Estas alterações possuem uma variedade de escalas espaciais e temporais (COPPIN et al., 2004). O acompanhamento destas mudanças durante um determinado tempo de interesse, baseado em um monitoramento da superfície da terra, é de grande importância para o conhecimento e compreensão das transformações ocorridas. Este processo de identificação de mudanças no estado de um objeto ou fenômeno, observado em épocas diferentes, é chamado de detecção de mudanças (SINGH, 1989). A detecção de mudanças auxilia a compreensão das relações e interações entre os fenômenos humanos e naturais, podendo promover uma melhor tomada de decisão em diversas situações (LU et al., 2004a).

Analisar e identificar estas mudanças depende da existência de informações multitemporais e o sensoriamento remoto (SR), definido por Lillesand e Kiefer (1994) como a arte de obter informação sobre um objeto, área ou fenômeno a partir de dados coletados sem que haja o contato direto com os mesmos, se mostra como uma importante ferramenta de aquisição de dados para estudos de detecção de mudanças da cobertura da terra. Dentre os dados de SR aplicados à detecção de mudanças, destacam-se os dados obtidos por sensoriamento remoto orbital, a partir dos quais informações atualizadas da cobertura da terra são obtidas de forma remota e recorrente (MYERS, 1988). Além disso e principalmente, com baixo custo quando comparado a outros métodos de SR como a fotogrametria (ROSENDO; ROSA, 2007). Outros atrativos associados ao uso de dados de SR são: a possibilidade de seleção de diferentes resoluções espaciais e espectrais, bem como o formato digital, adequado para processamentos computacionais (CHEN et al., 2012).

A premissa básica da utilização de dados de SR em estudos de detecção de mudanças é o fato de que alterações observadas em uma determinada área de

interesse são expressas em mudanças nas respostas obtidas por sensores, sejam eles passivos ou ativos (MAS, 1999). No entanto, é preciso destacar que estas mudanças devem ser separadas de alterações de resposta espectral causadas por outros fatores, tais como: condições atmosféricas, iluminação, ângulo de visada, teor de umidade e até mesmo problemas técnicos no momento da aquisição (SINGH, 1989).

As primeiras publicações relacionadas ao uso de dados de sensoriamento remoto aplicados à detecção de mudanças datam do início dos anos 60 com Rosenfeld (1961) e Shepard (1964), passando por Lillestrand (1972) e chegando a Singh (1989). Este último realizou uma importante revisão sobre o tema, na qual documentou as técnicas de detecção de mudanças existentes até então, tornando-o mais amplamente difundido. Com isso, métodos de detecção de mudanças passaram a ser aplicados nas mais diversas áreas do conhecimento, como monitoramento de florestas (COLLINS; WOODCOCK, 1996; DESCLEÉ et al., 2006; HUANG et al., 2010; REICHE et al., 2013), monitoramento de expansão urbana (LO; SHIPMAN, 1990; YEH; LI, 2001; BORGHYS et al., 2007; DU et al., 2012), acompanhamento de geleiras (ENGESET, et al., 2002), monitoramento de áreas alagadas (HOUHOULIS; MICHENER, 2000; BAKER et al., 2007) e até mesmo alterações de biomassa (COPIN et al., 2001).

Mesmo não sendo um conceito novo, a detecção de mudanças ainda é considerada um tópico ativo de pesquisas (REICHE et al., 2013; VOLPI, 2013; LU et al., 2014; ALVES, 2015; ANJOS et al., 2015). A disponibilidade de novos dados, produtos e ferramentas, bem como a necessidade de avaliar a aplicação dos mesmos à detecção de mudanças, fazem deste um tópico atual (LUI; COOMES, 2015). Lu et al. (2014) apresentam a situação atual do tópico e os desafios a serem superados. Dentre estes desafios, destaca-se o problema de disponibilidade de dados, seja por falta de verba para aquisição dos mesmos ou simplesmente pela inexistência de imagens de qualidade para as datas de interesse.

De fato, a impossibilidade de adquirir dados adequados ao problema estudado ainda é comum. Por essa razão, Hansen e Loveland (2012) afirmam que, dentre os fatores capazes de influenciar a detecção de mudanças, o aumento da disponibilidade de dados seria o de maior impacto no aumento da quantificação e tipificação das mudanças globais. Porém, historicamente, a maioria dos estudos e aplicações envolvendo o tema baseia-se apenas na utilização de dados ópticos, provenientes de um mesmo sensor (BRUZZONE; BOVOLO, 2008). Considerando este fato, o uso, o aprimoramento e até mesmo o desenvolvimento de metodologias que utilizem não só os dados ópticos, mas também dados obtidos por radares de abertura sintética (SAR, do inglês *Synthetic Aperture Radar*) ou até mesmo dados SAR e ópticos integrados, se mostra como uma alternativa para o problema da disponibilidade de dados.

Um crescente interesse na utilização de dados SAR em projetos de detecção de mudanças, por exemplo, tem sido observado nos últimos anos (REIS, 2014). Apesar das dificuldades inerentes ao dado SAR, devido ao ruído multiplicativo que este tipo de dado carrega consigo, a possibilidade de se obter informação em condições meteorológicas adversas tem se mostrado um grande atrativo, quando comparado a dados ópticos (PANDA et al., 2015). Esse atrativo é ainda mais vantajoso para áreas de floresta onde a cobertura de nuvens é frequente durante grande parte do ano (SERVELLO et al., 2010). Além do uso de dados SAR, a utilização de metodologias capazes de integrar dados de diferentes sensores (multissensor) também se mostra como outra possibilidade de lidar com o problema da disponibilidade de dados (ANJOS et al., 2015).

Conjuntos de dados multissensor podem ser formados por dados coletados a partir de diferentes sensores ópticos, diferentes sensores SAR ou até mesmo pela combinação de ambos (LU et al., 2014), aumentando assim, a gama de dados disponíveis para as áreas e datas de interesse. Apesar de não ser considerada a melhor opção para um estudo que envolva detecção de mudanças, pois apresenta o inconveniente de se trabalhar com diferentes

resoluções espaciais, espectrais, radiométricas ou até mesmo diferentes tipos de informação (PAOLO, 2012), a utilização de dados multissensor se torna, muitas vezes, necessária (LU et al., 2008). No entanto, para que bons resultados possam ser obtidos é necessário que as metodologias adotadas sejam capazes de lidar com dados de diferentes sensores e diferentes resoluções. Assim, a adaptação e aplicação de metodologias existentes à integração de diferentes tipos de dados, tratada neste estudo, ou até mesmo o desenvolvimento de novas metodologias que tratem essa integração são considerados desafios atuais para o tópico e se fazem necessários (LU et al., 2013a).

Pesquisas anteriores tratam principalmente da integração de dados advindos de diferentes sensores ópticos. Dentre elas, podem ser citadas a integração de dados Landsat *Multispectral Scanner* (MSS) e Landsat *Thematic Mapper* (TM) (SERRA et al., 2003), Landsat *Enhanced Thematic Mapper Plus* (ETM+) e *Satellite Pour l'observation de la Terre Multispectral* (SPOT XS) (DENG et al., 2008), Landsat TM, e *Satellite Pour l'observation de la Terre High Resolution Geometrical* (SPOT HRG) (LU et al., 2008).

A integração de dados ópticos e SAR em pesquisas de detecção de mudanças da cobertura da terra não tem recebido a mesma atenção. Porém, situações nas quais dados ópticos já têm sido utilizados, mas a obtenção de informação nova precisa ser imediata e não pode estar condicionada a boas condições atmosféricas comprovam a necessidade de uma maior atenção a esta integração de dados. Sistemas de alerta de desmatamento ou de desastres naturais, por exemplo, são importantes demandas da utilização de dados SAR e óptico dentro de uma mesma metodologia de detecção de mudanças. No entanto, apesar de serem necessárias, principalmente em regiões tropicais úmidas, metodologias que abordem o uso de dados SAR e ópticos, em datas distintas, para um mesmo estudo de mudanças ainda são raras (ANJOS et al., 2015). Dentre os poucos estudos encontrados, aparecem os estudos

desenvolvidos por Alberga (2009); Lu et al. (2013a), Reiche et al. (2013) e Reis (2014).

Nesse contexto, surgem questões que, se respondidas, podem alavancar a detecção de mudanças envolvendo dados multissensor SAR e óptico e por esta razão, orientam este trabalho. A primeira delas está relacionada ao potencial do uso de dados multissensor SAR e óptico em estudos de detecção de mudanças em áreas de floresta tropical. Isso porque, apesar do aumento recente do uso de dados SAR em detecção de mudanças ainda não é possível afirmar com clareza que este tipo de dado possa gerar resultados satisfatórios em abordagens que utilizem dados SAR e ópticos em datas distintas. A segunda refere-se especificamente ao potencial de dados SAR em banda C em detecção de mudanças multissensor para área de florestas, até o momento pouco abordada. A terceira refere-se à seleção de métodos de detecção de mudanças, dentre os já descritos na literatura, que sejam aplicáveis a dados multissensor e aos propósitos do estudo. Para tanto, é necessário considerar que abordagens baseadas em cálculos envolvendo medições de radiometria não são aplicáveis a dados multissensor SAR e óptico que sabidamente detectam diferentes tipos de informações para um mesmo tipo de alvo e que métodos baseados em limiar não são capazes de tipificar mudanças. E, finalmente, a quarta questão que se refere à como tratar a avaliação dos resultados de detecção de mudança e torná-los comparáveis para os diferentes métodos de detecção utilizados. Para tanto, uma abordagem, que trate o problema recorrente de diferentes métodos de detecção de mudanças apresentarem resultados contendo diferentes conjuntos de classes de mudança e não mudança, é apresentada. A proposta desta nova abordagem é criar uma forma de comprovar que as classes detectadas em campo, através de visitas a área de estudo, são as que de fato ocorreram na região de interesse para o intervalo temporal estudado. Assim, além das classes de mudança e não mudança impossíveis e improváveis, já tratadas em outros

estudos, as classes possíveis, mas que, no entanto, não ocorreram na região para o intervalo do estudo, também podem ser tratadas.

Considerando os aspectos abordados, esta tese apresenta um estudo de detecção de mudanças com dados multissensor, capaz de tratar dados SAR em banda C e dados ópticos obtidos em datas distintas, através das metodologias de detecção de mudanças por comparação pós-classificação e classificação direta, ambas baseadas em classificações *pixel a pixel*, na região da Floresta Nacional do Tapajós (FLONA Tapajós).

1.1. Objetivos e contribuições

O objetivo principal deste trabalho é avaliar o potencial da utilização de dados multissensor SAR em banda C (Radarsat-2) e dados ópticos (EO-1 ALI) na detecção de mudanças na cobertura da terra para uma região de floresta tropical a partir das abordagens já existentes na literatura, comparação pós-classificação (CPC) e classificação direta (CD). Para alcançar esse objetivo a exatidão global e a matriz de confusão associadas a cada mapa de mudança deverão ser calculadas de acordo com as características do método de detecção de mudança utilizado e índices de incerteza classe a classe obtidos através da repetição das classificações deverão ser gerados. Os seguintes objetivos específicos também são propostos:

- Comparar o uso dos dois diferentes métodos de detecção de mudanças baseados em classificações (Comparação pós-classificação e Classificação direta) e verificar, suas potencialidades de adequação à detecção de mudanças multissensor SAR e óptico.
- Verificar a influência dos diferentes ângulos de visada de aquisição das imagens SAR nos modos *Fine Quad Polarization 06* (FQ06) e *Fine Quad Polarization 13* (FQ13) na detecção de mudanças.

- Tratar o problema das classes de mudanças impossíveis, improváveis e possíveis que, mesmo não ocorrendo na região e no intervalo de um estudo, são encontradas de forma recorrente nos resultados de detecções de mudança baseadas em comparação pós-classificação.
- Explorar uma metodologia de validação das classes de mudança e não mudança detectadas em campo e consideradas no estudo, tornando os resultados dos diferentes métodos abordados comparáveis.

A partir dos objetivos descritos destacam-se algumas contribuições do trabalho. Do ponto de vista teórico, este trabalho apresenta uma proposta de validação das classes de mudança e não mudanças encontradas em campo como sendo as que de fato ocorreram na região no intervalo temporal estudado. Essa validação, baseada em mapas de cobertura da terra acurados para cada uma das datas em questão e obtidos a partir do resultado da detecção de mudança por classificação direta contribui de forma substancial para a comparação dos mapas de mudança finais, gerados pelos métodos comparação pós-classificação e classificação direta, não abordada até o momento. Do ponto de vista prático, uma metodologia consistente de detecção e tipificação de mudanças com uso de dados SAR e óptico em datas distintas, o que ainda não é uma aplicação consolidada do Sensoriamento Remoto, pode contribuir para a melhoria de sistemas de alertas que atualmente dependam exclusivamente de dados ópticos. Conseqüentemente, a melhora de políticas públicas associadas as informações geradas por esses sistemas de alerta também pode ser citada como uma contribuição prática deste trabalho. Buscando elucidar essas contribuições, os conceitos teóricos necessários ao entendimento e desenvolvimento do trabalho, a metodologia utilizada e por fim as análises e conclusões acerca dos resultados obtidos serão apresentados.

2 DETECÇÃO DE MUDANÇAS DA COBERTURA DA TERRA

Um processo de detecção de mudanças deve ser capaz, segundo Lu et al. (2004a), de identificar a ocorrência ou não de mudanças, em uma determinada área de interesse, em um determinado intervalo de tempo. Processos de detecção de mudanças podem ser aplicados às mais diversas áreas do conhecimento como reconhecimento facial, diagnósticos médicos, infraestrutura civil, monitoramento por vídeo, sistemas de auxílio a motoristas entre outros (RADKE et al., 2005; BITTENCOURT, 2011). No entanto, as aplicações mais comuns envolvem a detecção de mudanças de uso e cobertura da terra a partir de dados de sensoriamento remoto (LU et al., 2004a; ANJOS, 2015).

Neste contexto é importante definir os conceitos de uso e cobertura da terra bem como a distinção entre os termos. A cobertura da terra se refere ao estado biofísico da superfície da terra e a parte imediatamente abaixo da superfície, de forma a descrever o seu estado físico (LAMBIN; GEIST, 2006). Já o uso da terra envolve tanto os atributos biofísicos quanto as atividades exercidas e o intuito da manipulação, ou seja, o propósito para o qual a terra é utilizada por atividades de interesse humano (LAMBIN; GEIST, 2006; LU et al., 2004). Assim, o uso da terra é um conceito mais relacionado a fatores sociais, culturais, econômicos e políticos do que às propriedades de reflectância dos alvos, o que implica em uma relação limitada com o sensoriamento remoto (TREITZ; ROGAN, 2004). Por essa razão, a maioria dos estudos de detecção de mudanças trata apenas as mudanças da cobertura da terra.

A classificação dos tipos de mudanças, em conversão e modificação, é outro conceito de grande importância em detecção de mudanças. Enquanto a conversão é caracterizada pela completa substituição de uma cobertura por outra, a modificação é caracterizada por mudanças sutis, que, apesar de afetarem as características da cobertura, não modificam sua classe (LAMBIN; GEIST, 2006). Um estudo de detecção de mudanças baseado em dados de

sensoriamento é capaz de tratar essas mudanças desde que as alterações ocorridas na cobertura da terra alterem também a resposta que a área afetada envia ao sensor escolhido para o estudo.

Para tanto, um estudo de detecção de mudanças é baseado no encadeamento das etapas de definição da área de estudo e a descrição das mudanças ocorridas na área, aquisição de imagens, pré-processamento das imagens, definição dos algoritmos de detecção de mudanças a serem utilizados e, finalmente, avaliação da exatidão dos resultados obtidos (DOBSON et al., 1995; LU et al., 2004a, COPPIN et al., 2004, LU et al., 2014). Devido à grande importância para este estudo essas etapas são discutidas em uma seção específica, assim como a detecção de mudanças multissensor, os métodos de detecção de mudanças utilizados neste estudo e as aplicações da detecção de mudanças ao desmatamento na Amazônia.

2.1. Etapas da detecção de mudanças

Dentre as etapas de um processo de detecção de mudanças, a aquisição das imagens, o pré-processamento, a escolha de um método de detecção de mudanças e a avaliação da exatidão são discutidos de forma mais detalhada nesta seção. Detalhes referentes à definição da área de estudo e ao estudo dos tipos de mudanças que ocorrem na área de estudo são tratados na subseção aquisição das imagens.

2.1.1. Aquisição das imagens

Estudos de detecção de mudanças da cobertura da terra podem adotar uma metodologia bi-temporal ou uma metodologia de análise de trajetória temporal. Métodos bi-temporais baseiam nas informações de apenas duas imagens em datas distintas enquanto a análise de trajetória temporal utiliza três ou mais imagens da área de interesse também em datas distintas (COPPIN et al., 2004). Em ambas as metodologias, a seleção apropriada das datas de aquisição das imagens é de grande importância, porém, no método bi-temporal

uma boa escolha de datas de aquisição é crucial, pois como é único, esse intervalo define o tipo de mudança que pode ou não ser observado (KIEL, 2008).

A detecção da conversão de áreas de floresta em áreas de solo exposto ou pastagem, por exemplo, pode ser obtida através de um par de imagens com intervalo de poucos meses quando essa mudança ocorre por corte raso. Já o acompanhamento detalhado da trajetória de um desmatamento por degradação florestal necessita de inúmeras imagens durante todo o processo, que pode levar anos. Em um estudo de impactos de uma queimada, um intervalo de poucos meses é geralmente suficiente, enquanto para o estudo de um desastre natural, o intervalo entre as imagens pode ter exatamente o tempo de duração do fenômeno. Assim, a correta determinação do intervalo entre as imagens se baseia no conhecimento da área e do tipo de mudança que se deseja estudar. Por essa razão, não existe um espaçamento temporal padrão entre as imagens usadas na detecção de mudanças, mas sim um espaçamento temporal associado a cada situação ou processo (DOBSON et al., 1995; LU et al., 2004a, LU et al., 2014).

No entanto, a definição do intervalo temporal entre as imagens não é a única questão que merece atenção na etapa de aquisição dos dados. Além da resolução temporal, dados adquiridos por sensores remotos também podem apresentar diferentes resoluções radiométricas, espectrais e espaciais. Por essa razão, o conhecimento das características inerentes aos dados advindos de diferentes sensores é de extrema importância na seleção do conjunto de dados a ser utilizado (LEFSKY; COHEN, 2003).

Dentre todos os dados de sensoriamento remoto disponíveis, os dados ópticos de resolução espacial média são os mais comumente utilizados em processos de detecção de mudanças (HANSEN; LOVELAND, 2012). No entanto, dados de alta resolução espacial, adquiridos através de sensores como IKONOS, QuickBird e Worldview, vêm sendo utilizados em estudos de detecção de

mudanças em escala local (LU et al., 2010). A análise de mudanças em escala continental ou global tem sido feita a partir de dados de resolução espacial grosseira obtidos a partir de sensores como MODIS e AVHRR (LUNETTA et al., 2006; BONTEMPS et al., 2012). Já os dados SAR têm sido utilizados em estudos de detecção de mudanças em regiões de florestas tropicais (WHITTLE et al., 2012; BRISCO et al., 2013; NASCIMENTO et al., 2013; REIS, 2014; REIS; SANT'ANNA, 2015) para as quais imagens ópticas de qualidade são dificilmente encontradas em determinados períodos devido à constante cobertura de nuvens.

Idealmente, um estudo de detecção de mudanças deve ser conduzido através de imagens de um mesmo sensor (PAOLO, 2012; LU et al., 2014) devido as mesmas resoluções espaciais e radiométricas. Porém, dados de um mesmo sensor, com as resoluções desejadas, podem não estar disponíveis para as datas desejadas. Nesses casos, o uso de dados de diferentes sensores ópticos e/ou SAR pode ser necessário (REICHE et al., 2013). Nesse contexto, as características dos dados ópticos e SAR, principais fontes de dados para estudos de detecção de mudanças, são apresentadas de forma sucinta a seguir. A detecção de mudanças a partir de dados de diferentes sensores é tratada em seção específica, devido à importância do tema para esse estudo.

2.1.1.1. Dados Ópticos

Sensores ópticos são aqueles capazes de medir a energia solar refletida por alvos nas faixas do visível, infravermelho próximo e infravermelho médio do espectro eletromagnético. Esses sensores também registram a energia emitida pelos alvos, na região do infravermelho termal.

As informações contidas em dados ópticos apresentam relação com as características químicas, físicas e biológicas dos alvos. Estas informações resultam em imagens que podem ser interpretadas visualmente ou mais rigorosamente através da análise do comportamento espectral dos alvos na imagem quando existe informação espectral. Isso porque diferentes materiais

refletem e absorvem a energia solar de forma diferente em cada faixa do espectro. Outra característica desse tipo de imagem é a de que o sinal de retorno dos alvos pode ser descrito por meio de um modelo de ruído gaussiano aditivo (JENSEN, 2009).


Devido a essas características, dados ópticos se mostram como uma fonte viável de dados para estudos envolvendo detecção de mudanças (BRUZZONE; BOVOLO, 2008). No entanto, este tipo de dado possui algumas restrições. Por depender do sol como fonte de energia, a aquisição de dados durante a noite não é possível em todas as faixas espectrais, sendo possível coletar durante a noite apenas os contrastes térmicos entre os alvos, com o uso das bandas termais. Condições atmosféricas adversas também interferem na aquisição de informação, o que dificulta a obtenção de imagens ópticas de qualidade em regiões tropicais, que apresentam constantes períodos de cobertura de nuvens (PANDA et al., 2015).

2.1.1.2. Dados SAR

Radars de abertura sintética (SAR) são sensores capazes de obter imagens, operando na região de microondas do espectro. Uma imagem SAR é fruto da parcela do sinal, emitido pelo próprio radar, que retorna ao sensor após a interação da radiação eletromagnética (REM) com os alvos de uma superfície (LEWIS; HENDERSON, 1998; OLIVER; QUEGAN, 2004). Por serem ativos, ou seja, dependentes da energia eletromagnética emitida pelo próprio sensor, os radares podem obter informações tanto diurnas quanto noturnas. Esses sensores também são capazes de prover dados de forma quase que independente às condições da atmosfera, pois a dispersão atmosférica que afeta os pequenos comprimentos de onda da faixa óptica do espectro (0,38 μm - 0,78 μm) não afeta comprimentos de onda maiores como os da faixa de microondas (0,1cm - 100cm) (PANDA et al., 2015). Por essa razão, dados SAR podem ser obtidos para regiões cobertas por nuvem, neblina, poeira ou até durante chuvas. No entanto, vale ressaltar que a atenuação no sinal SAR pode

ocorrer em situações de chuvas pesadas e que essa atenuação é diretamente proporcional à frequência do sinal e à intensidade da chuva (RICHARDS, 2009), como é mostrado no gráfico da Figura 2.1.

Figura 2.1 – Atenuação atmosférica em dados micro-ondas devido à chuva.



Fonte: Adaptado de Richards (2009).

Outro fator capaz de interferir na resposta obtida por um sensor SAR é a rotação do plano de polarização do sinal emitido. Essa rotação ocorre quando uma onda eletromagnética se propaga na presença de um campo magnético. Assim, ao atravessar a ionosfera, que possui elétrons livres capazes de produzir um campo magnético, o sinal emitido pelos sensores SAR pode ter a sua polarização rotacionada. Essa rotação pode reduzir a intensidade do sinal recebido pelas antenas preparadas para captar ondas em determinadas polarizações. No caso de o meio ser um plasma, como a ionosfera, este efeito é conhecido como rotação de Faraday. A magnitude da rotação de Faraday depende do trajeto percorrido e da frequência da onda (SANT'ANNA et al., 2009), sendo menos expressiva para ondas de alta frequência como as de micro-ondas. Assim, apesar de existirem, as atenuações para os dados SAR


acontecem em uma escala significativamente menor do que para os dados ópticos, podendo ser, em muitas situações, desconsideradas.

No entanto, diferentemente das imagens ópticas, que contêm informações a respeito da reflectância e das propriedades físico-químicas dos alvos, os dados SAR carregam informações a respeito da estrutura e das propriedades dielétricas desses alvos (JENSEN, 2009). Por essa razão, a resposta do sinal SAR é fortemente afetada pela rugosidade dos alvos, ângulo de incidência, espalhamento volumétrico, reflexão de canto e umidade do terreno (JENSEN, 2009; LEWIS; HENDERSON, 1998). Dessa forma, diferentes tipos de terreno e diferentes condições de umidade podem fazer com que um mesmo tipo de cobertura não responda da mesma forma em uma mesma imagem SAR, o que dificulta o processo de classificação destas imagens (WANG et al., 1986).

A diferença entre o comprimento de onda dos sinais utilizados por sensores ópticos e SAR também merece destaque. Enquanto os comprimentos de ondas curtos, captados por sensores ópticos, carregam consigo informações sobre a superfície dos alvos, os comprimentos de ondas longos utilizados por sensores SAR são capazes de penetrar nos mesmos. Os sensores SAR utilizam diferentes comprimentos de onda, todos pertencentes à faixa de micro-ondas do espectro, que são divididos nas bandas P (30 - 100 cm), L (15 - 30 cm), S (7,5 - 15 cm), C (3,8 - 7,5 cm), X (2,4 - 3,8 cm), Ku (1,67 - 2,4 cm), K (1,18 - 1,67 cm) e Ka (0,75 - 1,18) (JENSEN, 2009). Para regiões de floresta as bandas com comprimentos de onda mais curtos se mostram sensíveis a pequenos galhos e folhas, enquanto as bandas de comprimento de onda mais longos são sensíveis à troncos e galhos. Portanto, imagens geradas por sensores SAR em bandas de comprimento de onda mais curtos carregam consigo informações ao nível do dossel superior, enquanto as imagens geradas por sensores SAR em bandas de comprimento de onda mais longos penetram no dossel superior e podem fornecer informações sobre a estrutura lenhosa e até mesmo sobre a superfície do terreno subjacente (LEFSKY; COHEN, 2003). Buscando ilustrar essa diferença, a interação esperada entre o sinal captado

por sensores ópticos e por sensores SAR nas bandas X, C e L com uma floresta hipotética é apresentada na Figura 2.2.

Figura 2.2 – Penetração dos diferentes tipos de sinal em uma floresta hipotética.



Fonte: Adaptado de Lefsky e Cohen (2003).

Apesar das muitas vantagens, os dados de sensoriamento remoto obtidos a partir de sensores SAR também apresentam desvantagens em relação aos dados ópticos. A principal delas está relacionada à natureza coerente do sinal emitido e recebido pelos sensores SAR, que corrompe a imagem gerada por um ruído de caráter multiplicativo chamado *speckle* (GOODMAN, 1976). Por ser multiplicativo, o ruído *speckle* é mais intenso onde o sinal de retorno é maior, o que resulta em uma aparência granular da imagem, dificultando sua interpretação visual, bem como sua segmentação e classificação automáticas. Também, devido ao ruído *speckle*, as formas e bordas dos alvos apresentam uma definição menos nítida se comparadas com imagens ópticas de resolução espacial comparável (ORSOMANDO et al., 2007). Assim, a análise de dados SAR exige um intensivo pré-processamento baseado na utilização de técnicas capazes de suavizar esse tipo de ruído (BRUZZONE; BOVOLO, 2008; JENSEN, 2009). Processamentos *multi-look* são frequentemente utilizados para esse propósito (TORRES et al., 2014). Outra forma de tratar este ruído é através da utilização de filtros redutores de *speckle*, que são de grande

importância prática na extração de informações contidas nos dados SAR, melhorando a discriminação das coberturas da terra (DONG et al., 2000).

Além das dificuldades já citadas, o ruído multiplicativo também implica no fato da maioria dos dados provenientes de sistemas SAR não aderirem a uma distribuição Gaussiana. Assim, diferentes distribuições são utilizadas para modelar o sinal de retorno (VIEIRA, 1996; FRERY, 1993). Segundo Vieira (1996) dados amplitude podem ser modelados pela distribuição raiz quadrada da gama para áreas homogêneas, como pastagem e solo exposto, pela distribuição K amplitude para áreas heterogêneas, como florestas primárias, e pela distribuição G-amplitude Zero para áreas extremamente heterogêneas como áreas urbanas. Já os dados em intensidade podem ser modelados pela distribuição gama para áreas homogêneas, K-intensidade para áreas heterogêneas e G-intensidade zero para áreas extremamente heterogêneas (VIEIRA, 1996; FREITAS et al., 2007). Lembrando que a imagem do terreno pode ser formada tanto em amplitude, através da detecção linear do sinal, quanto em intensidade, através da detecção quadrática do sinal de retorno.

2.1.2. Pré-processamento das imagens

Após a aquisição dos dados, um estudo de detecção de mudanças deve prosseguir com a etapa de pré-processamento dos mesmos. Para dados de sensoriamento remoto, o pré-processamento se baseia em correções radiométricas, geométricas e atmosféricas, e deve ser realizado quando necessário, tanto para dados ópticos quanto para dados SAR (ROGAN et al., 2002; ROGAN; CHEN 2004; COPPIN et al., 2004; PAOLO, 2012).

Em geral, em estudos de detecção de mudanças, as correções radiométricas são utilizadas para realizar a normalização radiométrica e a equalização dos histogramas de imagens com diferentes resoluções radiométricas. No entanto, também podem ser realizados processamentos de filtragem de ruídos, realce e até mesmo inferência de valores radiométricos para *pixels* que, por problemas de aquisição, transmissão ou processamento dos dados, tenham perdido

informação. Já as correções geométricas são utilizadas principalmente com o intuito de atribuir à imagem sua correta localização no espaço, o que é por georreferenciamento ou registro de imagens. Assim, correções geométricas são de extrema importância para estudos de detecção de mudança, pois se bem realizadas podem assegurar a correta associação de um mesmo *pixel* em dois conjuntos de dados, o que implica no registro de informações acerca de uma mesma localização geográfica, ao longo do tempo. Finalmente, as correções atmosféricas são aquelas que possuem o intuito de minimizar as influências da atmosfera no sinal coletado. Correções de interferências de aerossóis, gases e vapor de água presentes na atmosfera são mais utilizadas para dados ópticos, uma vez que dados SAR são menos sensíveis a essas condições adversas (PAOLO, 2012). Já a correção da rotação de Faraday, descrita na subseção 2.1.1.2, é uma correção atmosférica específica para dados SAR e pode ser utilizada sempre que necessário.

Deve-se notar, no entanto, que as técnicas de pré-processamento das imagens não criam informações novas, mas apenas tentam destacar as informações de interesse presentes nos dados originais. Um pré-processamento bem-sucedido garante que todas as alterações detectadas para um mesmo *pixel*, em imagens de datas distintas, estejam associadas às mudanças ocorridas na superfície (KENNEDY et al., 2009). Dessa forma, o pré-processamento dos dados é considerado uma etapa crucial no processo de detecção de mudanças, pois um pré-processamento realizado de maneira não adequada pode conduzir a resultados errôneos e não realistas. Vale ressaltar, que diferentes métodos de detecção de mudanças dependem de diferentes tipos de pré-processamento, o que pode fazer com que algumas dessas correções, mais comumente as atmosféricas e/ou as radiométricas, se tornem desnecessárias.

2.1.3. Métodos de detecção de mudanças

Dentre as etapas de um processo de detecção de mudanças, a escolha do método utilizado merece especial atenção. Desde as primeiras publicações relacionadas à detecção de mudanças até os dias atuais, muitos métodos para esse fim foram desenvolvidos. Buscando facilitar a escolha do método de detecção adequado a cada situação, com o passar dos anos, propostas de agrupamento dessas técnicas de detecção de mudança foram desenvolvidas baseando-se nas principais características de cada método. Lu et al. (2004a) dividem mais de 30 métodos de detecção de mudanças em sete categorias: Álgebra, Transformação, Classificação, Modelos Avançados, Abordagens através de Sistemas de Informações Geográficas (SIG), Análise Visual de Imagens e Outras Abordagens. Diversos autores fizeram uso deste agrupamento em seus estudos de detecção de mudança (PILLAY, 2009; BITTENCOURT, 2011; ALBA et al., 2012). No entanto, outros agrupamentos foram propostos mais recentemente. Bhagat (2012) agrupa 29 técnicas de detecção de mudanças em oito categorias: classificação espectral, mudança radiométrica multidata, análise de vetor de suporte, abordagens híbridas, rede neural artificial, fusão, comparação de objetos e modelo triangular. Hussain et al. (2013) as dividem em dois grupos descrevendo 15 técnicas baseadas em *pixels* e 3 técnicas baseadas em objetos. E na mais recente revisão sobre o tema, Lu et al. (2014) propõem um novo agrupamento das técnicas de detecção de mudanças, agora em seis categorias, a saber: limiar por *pixel*, *subpixel*, métodos orientados a objetos, abordagens híbridas, métodos indiretos e classificação por *pixel*, as quais são detalhadas a seguir.

A categoria limiar por *pixel* contém técnicas que se baseiam na escolha de um limiar de separação entre as classes de mudança e não mudança. A escolha desse limiar pode ser feita de diversas formas, mas é, em geral, subjetiva e depende do conhecimento de um especialista. Métodos como imagem diferença, diferença de índice de vegetação e análise de componentes

principais são exemplos de técnicas pertencentes à categoria limiar (LU et al., 2014).

Metodologias de detecção de mudanças pertencentes à categoria *subpixel* são aquelas que buscam obter informações de mudança em uma escala inferior ao tamanho do *pixel* da imagem utilizada. O problema da mistura espectral em um mesmo *pixel*, principalmente para imagens de resolução grosseira, tem sido tratado por essa abordagem (HAERTEL et al., 2004; ZANOTTA; HAERTEL, 2012). Por serem as imagens de resolução grosseira uma fonte de informação para grandes regiões, o desenvolvimento da categoria *subpixel* se mostra extremamente importante para estudos de mudanças em escala continental e global.

Por outro lado, a detecção de mudanças em escala local, a partir de dados de alta resolução, tem sido tratada por metodologias orientadas a objetos (DESCLEÉ et al., 2006; CHEN et al., 2012; HUSSAIN et al., 2013). Segundo Lu et al. (2014) a detecção de mudança por métodos pertencentes à categoria orientada a objetos pode ser realizada através da comparação de segmentos de duas imagens em datas distintas ou da comparação das classificações desses segmentos em datas distintas ou até mesmo através da classificação por região de um único vetor contendo informação das duas datas.

São considerados pertencentes à categoria métodos híbridos aqueles que combinam o uso de diferentes métodos de detecção de mudanças (LU et al., 2004a; LIU et al., 2008). Em geral, estudos usando métodos híbridos podem ser conduzidos através da utilização de diferentes métodos para gerar uma única informação de mudança ou através da combinação dos resultados obtidos por diferentes métodos de detecção de mudanças em um único resultado (LU et al., 2014).

Os métodos indiretos são aqueles que buscam detectar mudanças através da identificação de atributos biofísicos que reflitam essa mudança na cobertura da terra. Segundo Lu et al. (2014) esses atributos podem ser derivados de dados

de sensoriamento remoto por meio de modelagem, como já utilizado para detecção de superfícies impermeáveis em áreas urbanas (LU et al. 2011, 2013b).

Finalmente, serão tratados os métodos pertencentes à categoria classificação por *pixel*, que tem sido os mais comumente aplicados a estudos de detecção de mudanças (HUSSAIN et al., 2013). Essa grande utilização dos métodos da categoria classificação por *pixel* se deve à diversas razões. Primeiramente é possível citar o fato de que diferentemente dos métodos da categoria limiar por *pixel*, os métodos da categoria classificação por *pixel* apresentam a possibilidade de tipificar a mudança, gerando informação do tipo "de-para". Quando comparada aos métodos das categorias orientada a objetos ou *subpixel*, a categoria classificação por *pixel* apresenta a vantagem de poder trabalhar com o rótulo do *pixel*, obtido por classificação, em cada uma das datas, sem a necessidade de gerar segmentações ou realizar análises de mistura espectral dos *pixels*. No entanto, detecções de mudanças por métodos pertencentes à categoria classificação por *pixel* também apresentam desvantagens. Dentre estas desvantagens é possível destacar a completa dependência da precisão das classificações envolvidas no estudo no resultado obtido, a necessidade de um registro de alta qualidade, além da possibilidade de apresentar uma alta variação de classes dentro de uma mesma área, principalmente quando aplicados a dados de alta resolução espacial classificados sem influência da vizinhança (LU et al., 2014).

Com todas essas possibilidades, a escolha de um método de detecção de mudanças deve ser realizada em função de suas características e dos objetivos do estudo que se deseja realizar. Após a escolha, esse algoritmo deve ser aplicado até a obtenção de resultados que permitam a localização e quantificação das mudanças (KIEL, 2008). No entanto, devido à dificuldade de se escolher o melhor método de detecção de mudanças para um determinado objetivo, um analista pode testar diversos métodos em uma área de estudo e em seguida comparar e identificar, através da etapa de avaliação de exatidão,

os melhores resultados. Mas (1999), Hayes; Saider (2001), DiGirolamo (2006), entre outros, publicaram estudos comparativos entre diferentes técnicas de detecção de mudanças para aplicações específicas. Porém, estudos deste tipo não respondem à pergunta sobre qual o melhor método de detecção de mudança. E isso ocorre por não haver um método adequado a todos os casos. Assim, a escolha do método de detecção de mudanças utilizado deve estar sempre atrelada aos conhecimentos do analista sobre o problema em questão, a área de estudo, as técnicas existentes e também aos dados disponíveis.

2.1.4. Avaliação da exatidão

A necessidade de avaliação da exatidão dos resultados de mudanças surge como parte do desenvolvimento dos processos de detecção de mudanças e é uma importante forma de análise para os usuários dos produtos gerados por este tipo de estudo (CIHLAR, 2000). Nenhum projeto de detecção de mudanças é completo sem uma avaliação da exatidão dos resultados (DOBSON et al., 1995; LU et al., 2004a). Também a compreensão dos resultados obtidos quanto à empregabilidade desses resultados na tomada de decisões depende da etapa de avaliação da exatidão. Essa análise é baseada em mapas ou dados que contenham informações chamadas de verdade de campo. Cihlar (2000) destaca a forte dependência existente entre a exatidão dos resultados e os recursos disponíveis, pois, muitas vezes, essas verdades de campo são de difícil acesso. Dessa forma, um equilíbrio, entre o que é ótimo estatisticamente e o que é possível na prática, deve ser encontrado (CONGALTON, 2004).

A análise estatística engloba os elementos mais comumente utilizados na avaliação da exatidão dos resultados de detecção de mudanças. Essa análise se baseia em indicadores extraídos de uma matriz de confusão, gerada a partir dos resultados obtidos e dos dados de referência, desde que estes estejam disponíveis (BITTENCOURT, 2011). Estes indicadores, largamente utilizados para avaliação de classificações de dados de SR em data única, também são

valiosos na avaliação dos resultados de detecção de mudança (LU, et al., 2004).

Considere que $k = \{1, 2, \dots, c\}$ seja o conjunto das classes existentes em um mapa de mudanças; $\{x_{ii}, 1 \leq i \leq c\}$ sejam os *pixels* pertencentes ao conjunto de amostras de verdade de campo corretamente classificados, ou seja, atribuídos à mesma classe tanto nos dados de referência quanto na classificação e $\{x_{ij}, 1 \leq i \leq c, 1 \leq j \leq c, i \neq j\}$ sejam os *pixels* pertencentes ao conjunto de amostras de verdade de campo erroneamente classificados, ou seja, associados a classes diferentes nos dados de referência e na classificação. A partir dessas informações, é possível afirmar que o total de *pixels* pertencentes à classe i na classificação será dado por $x_{i+}, 1 \leq i \leq c$, enquanto o total de *pixels* pertencentes à classe j nos dados de referência será dado por $x_{+j}, 1 \leq j \leq c$. Assim, uma matriz de confusão genérica, como a apresentada na Figura 2.1, entre os dados de referência e os resultados da mudança pode ser obtida.

Tabela 2.1 – Matriz de confusão genérica.

		Referência				
		1	2	...	c	Total
Classificação	1	x_{11}	x_{12}	...	x_{1c}	x_{1+}
	2	x_{21}	x_{22}	...	x_{2c}	x_{2+}
	\vdots	\vdots	\vdots	\ddots	\vdots	\vdots
	c	x_{c1}	x_{c2}	...	x_{cc}	x_{c+}
	Total	x_{+1}	x_{+2}	...	x_{+c}	n

Sendo n o número total de *pixels* pertencentes à amostra de verdade de campo utilizada para validação dos resultados. Dentre os possíveis índices de avaliação de exatidão temos a exatidão global, utilizada neste trabalho, e definida como a proporção geral de *pixels* corretamente classificados como mostra a equação 2.1. (CONGALTON; GREEN, 1999).

$$E_g = \frac{\sum_1^c x_{kk}}{n} \quad (2.1)$$

No entanto, é preciso ressaltar que, além da exatidão global, outros índices, como a exatidão do produtor, a exatidão do consumidor e o índice Kappa, e outros tipos de informação também podem ser utilizados na avaliação de resultados. Neste estudo, além das matrizes de confusão e da exatidão global, informações a priori e dados de incerteza associados aos mapas de mudanças, descritos na seção metodologia, também são utilizados como formas de avaliação. Por tratar a exatidão global para mapas de mudança gerados por comparação pós classificação que apresentam uma matriz de confusão não quadrada uma proposta complementar para calcular a exatidão global também será apresentada.

2.2. Detecção de mudanças multissensor

Dentre as abordagens de detecção de mudanças presentes na literatura, as mais comuns são certamente as que fazem uso de duas ou mais imagens adquiridas por um mesmo sensor, sejam elas imagens ópticas de um mesmo sensor (COLLINS; WOODCOCK, 1996; MAS, 1999; YEH; LI, 2001; BAKER et al., 2007; HUANG et al., 2010; YANG; QIAN, 2012; ROKNI et al., 2014) ou imagens SAR de um mesmo sensor (ENGESET et al., 2002; WU et al., 2007; WHITTLE et al., 2012; BRISCO et al., 2013; MARIN et al., 2015). Além de mais comuns, as abordagens de detecção de mudanças baseadas em dados de um mesmo sensor são citadas por diversos autores como a melhor opção para estudos de detecção de mudanças, devido ao fato de as resoluções espacial, espectral e radiométrica dos dados serem as mesmas (SERRA et al., 2003; PAOLO, 2012; LU et al., 2014; ANJOS et al., 2015).

No entanto, mesmo não sendo o ideal, o trabalho com diferentes sensores muitas vezes se faz necessário (SERRA et al., 2003), principalmente devido à falta de disponibilidade de dados de um mesmo sensor, nas datas de interesse, para a área de estudo. Um exemplo didático do uso de dados advindos de

diferentes sensores em metodologias de detecção de mudança é apresentado por Alberga (2009) ao considerar um possível desastre natural, que geraria a necessidade de um rápido mapeamento de danos. Tendo o desastre ocorrido em uma área para a qual dados ópticos de um arquivo, anteriores ao evento, estivessem disponíveis, mas apenas dados SAR pudessem ser obtidos logo após o evento devido às condições atmosféricas adversas, o uso de dados de diferentes sensores se faria necessário.

Neste contexto, considera-se, como detecção de mudanças multissensor todo estudo capaz de detectar alterações, em um determinado intervalo temporal, a partir de diferentes tipos de dados, advindos de diferentes sensores, para as datas de interesse. Esses estudos normalmente envolvem diferentes resoluções espaciais, espectrais e até mesmo radiométricas e podem ser realizados a partir de dados adquiridos por diferentes sensores ópticos, diferentes sensores SAR ou até mesmo por sensores ópticos e SAR. Apesar de ser muitas vezes necessário, o uso de dados provenientes de diferentes sensores pode tornar a seleção de um método de detecção de mudanças mais difícil. Isso porque muitos dos métodos existentes são capazes de tratar apenas dados obtidos por um mesmo sensor (LU et al., 2008). Metodologias de detecção de mudanças baseadas em medições de radiometria, usadas para calcular diferenças ou razões, por exemplo, passam a não apresentar resultados apropriados quando os dados são adquiridos por diferentes instrumentos (ALBERGA, 2009).

Assim, a escolha da abordagem ideal para um projeto de detecção de mudanças multissensor deve envolver estudos baseados no conhecimento dos dados utilizados e das suas características, de modo a garantir a adequação desses dados ao método de detecção de mudanças escolhido. Isso porque, muitas vezes, uma metodologia aplicada a detecção de mudanças multissensor exigirá processamentos que não seriam necessários caso imagens provenientes de um mesmo sensor fossem utilizadas. A conversão de diferentes tipos de dados para um mesmo formato, a normalização da

radiometria de dados ópticos com diferentes resoluções radiométricas ou a reamostragem do tamanho de *pixel* para imagens com diferentes resoluções espaciais são exemplos de processamentos geralmente utilizados nesse tipo de situação. Outros processamentos como o registro dos dados, por exemplo, não sofrem alterações por se trabalhar com dados multissensores uma vez que a necessidade de precisão para dados multissensor é a mesma que a dos projetos de detecção de mudanças envolvendo dados de um mesmo sensor.

Abordagens multissensor envolvendo dados de diferentes sensores ópticos já são comuns na literatura (SERRA et al., 2003; DENG et al., 2008; LU et al., 2008, CORREA et al., 2014; MANDANICI; BITELLI, 2015). Deng et al. (2008), por exemplo, realizaram um estudo de detecção de mudanças multissensor baseado em análise de componentes principais (PCA, do inglês *Principal Component Analysis*), buscando mapear a expansão urbana na cidade de Hangzhou, China. Para tanto, dados ópticos Landsat-7 ETM+ e SPOT-5 XS foram utilizados e os resultados obtidos apresentaram uma exatidão global próxima a 90% em um conjunto de 11 classes de mudança e não mudança.

Lu et al. (2008a) propuseram uma metodologia de detecção de mudanças multissensor híbrida, baseada na utilização conjunta das técnicas de comparação pós-classificação e imagem diferença para detecção de alterações na vegetação. Para testar essa abordagem, imagens Landsat-5 TM e SPOT HRG do município de Machadinho d'Oeste no estado de Rondônia, Brasil, foram utilizadas no mapeamento de áreas de não mudança, áreas com perda de vegetação e áreas de incremento da vegetação de acordo com o objetivo proposto pelos autores.

Correa et al. (2014) utilizam uma metodologia multissensor de detecção de mudanças a partir de dados ópticos de alta resolução na qual imagens QuickBird e WorldView são utilizadas para detectar alterações na região de Trentino, Itália. O método de detecção de mudanças por análise do vetor de mudanças (CVA, do inglês *Change Vector Analysis*) é utilizado no estudo. Os

mapas de detecção de mudanças obtidos chegaram a alcançar uma exatidão global de 92% para uma região contendo diferentes tipos de agricultura, zonas urbanas, sub-urbanas e industriais.

Os métodos de detecção de mudanças multissensor envolvendo dados advindos de diferentes sensores SAR ou os envolvendo dados de sensores ópticos e SAR são mais raros na literatura e muitas vezes não se adequam ao definido neste estudo como detecção de mudanças multissensor. Para dados SAR de diferentes sensores é possível citar o trabalho de Chatelain (2008), que apesar de utilizar o termo multissensor em seu estudo, aplica sua metodologia, baseada na correlação e na razão entre os dados e no estudo de adequação de distribuições gama multivariadas a dois conjuntos de dados SAR distintos. Primeiramente, dados ERS são utilizados para detectar mudanças resultantes de uma inundação ocorrida ao redor de Gloucester, Inglaterra, e, em um segundo instante, dados Radarsat são utilizados para detectar alterações causadas pela erupção do vulcão Nyiragongo, na República do Congo. Cálculos de probabilidade de falsos alarmes são utilizados para validar os resultados. A diferença do número equivalente de *looks* das imagens utilizadas antes e depois dos eventos é citada como a característica que difere os dados.

Em relação à utilização de dados ópticos e SAR, os bons resultados obtidos por Lu et al. (2011) e por Pereira et al. (2013) na melhoria de classificações da cobertura da terra, a partir da integração de dados ópticos e SAR, geram uma perspectiva de bons resultados para esta integração também em estudos de detecção de mudanças. Uma vez que as diferentes características dos dados SAR e ópticos possam trazer novas possibilidades para a detecção de mudanças, é possível que uma maior capacidade de interpretação e resultados mais confiáveis sejam obtidos (HAACK; BECHDOL, 1999).

Neste contexto, estudos de detecção de mudanças baseados na integração de dados SAR e ópticos podem ser encontrados na literatura (REIS, 2014; MISHRA; SUSAKI, 2014). No entanto, estes estudos tratam os dados

multissensor de forma diferente da aqui adotada, uma vez que os mapas de mudança são obtidos a partir de dados com as mesmas características, para todas as datas em questão. Isso porque a integração dos diferentes tipos de dados ocorre anteriormente ou posteriormente à etapa de detecção de mudanças.

Por ser realizado na mesma região do trabalho proposto nesta tese e por comparar os resultados de mudanças obtidos a partir de dados ópticos, dados SAR e da fusão entre eles, o trabalho de Reis (2014) merece destaque. No estudo de Reis (2014), dados ALOS PALSAR (banda L) e Landsat TM deram origem a 6 conjuntos utilizados na detecção de mudanças. São eles: dados ópticos originais (bandas 2, 4 e 5), dados SAR originais (amplitude HH e HV), atributos extraídos das imagens ópticas (média da banda 2, média da banda 4 e variância da banda 5), imagens SAR filtradas, atributos de textura de segunda ordem extraídos das imagens SAR filtradas (média da amplitude HH, média da amplitude HV, entropia da banda HH e segundo momento da amplitude HH) e fusão dos dados ópticos originais (bandas 1-5 e 7) e SAR filtradas. Um classificador por regiões baseado em mínima distância Bhattacharyya dá origem às classificações individuais utilizadas na detecção de mudanças por comparação pós-classificação. Estas classificações são realizadas para 3 diferentes níveis de legenda contendo 12, 7 e 4 classes, respectivamente. Cada um dos seis conjuntos teve suas classificações comparadas nos 3 níveis de legenda gerando 18 mapas de mudança.

Reis (2014) afirma que, comparados aos resultados de mudança obtidos através do uso de dados ópticos, o uso de dados fusionados apresentou melhora apenas para algumas classes. Assim, a autora recomenda a utilização de dados ópticos sempre que possível. Na indisponibilidade de dados ópticos, Reis (2014) afirma que os dados de radar fornecem bons resultados. No entanto, limitações na separação de classes que envolvam floresta primária e vegetações secundárias são percebidas. Reis (2014) também afirma que, quanto menor o nível de detalhe da legenda, mais os resultados da detecção

de mudança a partir de dados SAR se aproximam dos resultados obtidos por dados ópticos. O problema da existência de classes impossíveis e improváveis nos mapas de mudança final, que ocorrem quando a comparação pós-classificação é utilizada como método de detecção de mudanças, também foi influenciado pelo nível de detalhe da legenda. Quanto maior a quantidade de classes mapeadas, maior foi a ocorrência de classes impossíveis e improváveis nos mapas de mudanças finais, o que diminuiu a acurácia dos mapas de mudança obtidos neste estudo.

Finalmente, são tratados os estudos de detecção de mudanças multissensor baseados em dados SAR e ópticos para datas distintas, como o estudo aqui realizado, presentes na literatura. Alberga (2009) usou medidas de similaridade entre diferentes tipos de imagens, resultando em mapas de mudança e não mudança para o intervalo temporal e as áreas de estudo adotadas. Imagens ópticas XS do sistema PELICAN coletadas em maio de 1998 e setembro de 2004 e imagens SAR em banda X coletadas através do instrumento aerotransportado RAMSES em julho de 2004, foram utilizadas para detectar mudanças da área urbana do município de Toulouse, França. A mesma metodologia foi aplicada a dados coletados por sensores ópticos aerotransportados em 1990 e 2004 e dados SAR em banda X coletados por sensores aerotransportados em 1993 da região de Oberpfaffenhofen, Alemanha, a fim de detectar mudanças causadas pelo homem. Como resultado, o estudo apresenta o número de falsos alarmes obtido por diferentes maneiras de selecionar o limiar de mudança e não mudança adotado. Reiche et al. (2012) utilizaram dados ALOS PALSAR em banda L, dos anos de 2007 e 2010, e imagens Landsat ETM+ e Landsat TM dos anos de 2006, 2007 e 2010, para detectar desmatamento e degradação no sul da Guayana. Uma abordagem híbrida baseada primeiramente na detecção de mudanças por imagem diferença para cada um dos conjuntos de dados (SAR e óptico) e uma posterior fusão dos mapas de mudança através de árvore de decisão foi adotada. Considerando apenas as classes desmatamento, degradação e não

mudança, uma exatidão global de 89% foi obtida para o mapa de mudanças final. Anjos et al. (2015) apresentam parte dos estudos iniciais desta tese, no qual as abordagens de detecção de mudanças por comparação pós-classificação e classificação direta são adotadas para detectar alterações na Floresta Nacional do Tapajós entre os anos de 2009 e 2013, através do classificador SVM. Para tanto, dados Radarsat -2 em modo FQ13 e EO-1 ALI foram utilizados em uma região contendo 9 classes de cobertura da terra e 16 classes de mudança e não mudança da terra e resultaram em uma exatidão global de 0,223 para o mapa de mudança gerado por comparação pós-classificação e em uma exatidão global de 0,878 para o mapa de mudança gerado por classificação direta.

A análise destes estudos de detecção de mudança multissensor envolvendo dados SAR e ópticos, fica clara a necessidade de uma metodologia de detecção de mudanças adequada aos dados utilizados ou até mesmo do desenvolvimento de metodologias específicas, capazes de tratar as diferentes características dos dois tipos de dados. Como o objetivo do presente estudo é explorar o potencial da utilização de dados SAR e ópticos na detecção de mudanças multissensor, em região de florestas tropicais, a partir de métodos já consagrados na literatura, a seleção dos métodos adequados aos dados utilizados se fez necessária.

Para esta seleção algumas questões foram consideradas. A impossibilidade de utilização de métodos baseados em cálculos envolvendo medições de radiometria para dados provenientes de sensores SAR e ópticos e a necessidade de tipificação das mudanças ocorridas serviram para excluir os métodos de detecção de mudanças baseados em limiar. Os métodos baseados em informação subpixel também foram descartados, uma vez que os dados utilizados possuem resolução espacial média suficiente para detectar mudanças para as classes estudadas. A dificuldade em se obter segmentações SAR e ópticas comparáveis devido à diferença expressiva na quantidade de segmentos encontrados para cada um destes dados, descartou a utilização de

metodologias orientadas a objeto. Por fim, os métodos de detecção de mudanças baseados em classificação por *pixel* não apresentaram restrições à utilização de dados SAR e ópticos. Isso porque tanto classificações individuais quanto classificações de vetores empilhados, contendo os dados SAR e ópticos em conjunto, são facilmente obtidas. Assim, os métodos de detecção de mudança por comparação pós-classificação e por classificação direta foram selecionados para o estudo e são descritos a seguir.

2.2.1. Comparação pós-classificação

A detecção de mudanças por comparação pós-classificação é considerada o mais óbvio dentre os métodos de detecção de mudanças (SINGH, 1989). Esse método consiste na comparação, *pixel a pixel*, de ao menos duas classificações independentes, baseadas em um mesmo conjunto de classes, de imagens em datas distintas e previamente registradas (BITTENCOURT, 2011). A fácil interpretação dos resultados obtidos, bem como a possibilidade de tipificar a mudança, são grandes vantagens do método. Outra vantagem deste método é o fato da utilização de classificações independentes tornarem a normalização da radiometria dos dados desnecessária (COPPIN et al., 2004). Isso porque na comparação pós-classificação, a integração dos dados de datas distintas, ocorre ao se comparar as classificações quando cada *pixel* carrega um valor referente a uma determinada classe e não mais a resposta obtida pelo sensor. Para a detecção de mudanças multissensor SAR e óptico essa vantagem é essencial, uma vez que dados SAR e óptico não possuem respostas radiométricas comparáveis e nem mesmo coletam informações a respeito das mesmas características dos alvos, não podendo, assim, serem comparados diretamente.

Como desvantagem, a detecção de mudanças por comparação pós-classificação apresenta uma total dependência de classificações iniciais acuradas. Além dos erros de classificação, erros de registro presentes nos dados originais também se agravam no resultado final do processo (MAS,

1999). Em geral, a exatidão global de um mapa de mudanças obtido por esse método fica próxima do resultado da multiplicação das exatidões globais das classificações individuais utilizadas no processo (SINGH, 1989; COPPIN, et al., 2004; BITTENCOURT, 2011). Isso porque para se obter uma classe de mudança correta, para um determinado *pixel*, através da comparação pós-classificação, é necessário que este *pixel* tenha sido corretamente classificado em todas as classificações individuais utilizadas. A probabilidade de que isso ocorra é dada pelo produto das probabilidades de acerto em cada uma das classificações utilizadas, ou seja, pelo produto das suas exatidões globais. Nesse contexto, a escolha acertada ou até mesmo o desenvolvimento/aprimoramento de técnicas de classificação que resultem em alta acurácia das classificações individuais é de extrema importância nesse tipo de processo.

2.2.2. Classificação direta

Diferentemente da comparação pós-classificação, a classificação direta busca detectar e tipificar alterações a partir da classificação dos dados de entrada em uma única etapa (ALMUTAIRI e WARNER, 2010). Para tanto, um conjunto de dados contendo informações de no mínimo duas imagens em datas distintas, para uma mesma região, deve ser gerado. Nesse novo conjunto, cada *pixel* passa a ser composto por um vetor obtido pelo empilhamento das informações contidas nas imagens originais (SINGH, 1989). A utilização de duas imagens contendo quatro bandas cada, por exemplo, dará origem a um conjunto de dados com oito bandas que, em seguida, deve ser classificado por meio de um algoritmo que pode ser supervisionado ou não.

Dessa forma, as alterações são detectadas devido aos fatos de cada tipo de transição ser considerado como uma classe distinta (BRUZZONE; SERPICO, 1997), e de que classes onde ocorrem mudanças apresentarem respostas diferentes daquelas onde mudanças não estão ocorrendo (MAS, 1999). Bruzzone et al. (2004) consideram o método de detecção de mudanças por

classificação direta uma alternativa ao problema de dependência da acurácia de classificações individuais existente no método por comparação de pós-classificação. Isso porque na detecção de mudança por classificação direta apenas uma classificação é realizada, o que pode aumentar a acurácia do mapa de mudança final obtido. Outra característica capaz de aumentar a acurácia do resultado final é a exploração da correlação temporal existente entre imagens multitemporais de uma mesma área (ALMUTAIRI e WARNER, 2010).

Como grave inconveniente, no entanto, se destaca o fato de que a quantidade de classes de mudança em potencial é dada pelo produto da quantidade de classes existentes em cada uma das imagens utilizadas. Assim, quanto maior a quantidade de classes em cada uma das imagens, maior será a quantidade de classes de mudanças em potencial, o que dificulta tanto a utilização de classificadores não supervisionados quanto de classificadores supervisionados. Para os classificadores não supervisionados a dificuldade está associada às classes de mudança/não mudança com pouca ocorrência que acabam não gerando agrupamentos distintos (ALMUTAIRI e WARNER, 2010). Para os classificadores supervisionados, a obtenção de dados de treinamento passa a ser um problema. Isso ocorre porque os dados de referência para a classificação direta devem consistir em observações de mudança baseadas na observação da cobertura da terra para todas as datas em questão e para os mesmos locais de amostragem, o que pode muitas vezes não ser possível (BRUZZONE et al., 2004). Outra razão apontada para a não seleção a classificação direta como método de detecção de mudanças, mesmo quando amostras existem, é considerar que as mesmas são observações insuficientes da ocorrência de mudança (GFOI, 2014). No entanto, as amostras não precisam compreender todas as mudanças possíveis, mas apenas as que de fato ocorreram na região e no intervalo estudado, e que em geral são em número muito inferior ao total de possibilidades.

Buscando tratar essa questão, o presente estudo, baseado em classificadores supervisionados, propõe uma forma de validar as classes de mudança e não mudança encontradas em campo e utilizadas na detecção de mudança por classificação direta, passando a adotá-las também para o resultado gerado pela detecção de mudanças por comparação pós-classificação.

2.3. Detecção de mudanças aplicada a regiões de floresta tropical

Por mapear tanto alterações naturais quanto alterações causadas pelo homem, os estudos de detecção de mudanças possuem as mais diversas aplicações. Como exemplo podemos citar o mapeamento de alagamentos, derretimento de geleiras, expansões urbanas, áreas agrícolas, áreas de desmatamento entre vários outros (LU et al., 2004a). Dentre essas aplicações, o mapeamento e monitoramento de áreas de desmatamento em florestas tropicais é tratado neste trabalho com especial atenção.

Regiões de floresta tropical desempenham um papel crucial tanto na regulação de padrões climáticos globais quanto no ciclo global do carbono, além de produzirem grandes suprimentos de oxigênio para a Terra, possuírem uma inigualável diversidade biológica. No entanto, é preciso destacar que além da importância ambiental essas regiões também são importante fonte de recursos econômicos para sua população (MYERS, 1988). Assim, o interesse pela utilização da madeira e da terra tem ocasionado a rápida degradação ou até mesmo a eliminação dessas regiões. Dessa forma, o grande desafio para as regiões de floresta tem sido determinar como essas regiões podem ser economicamente desenvolvidas e protegidas ao mesmo tempo.

Estudos estimam que 127.821 km² da Amazônia brasileira, que possui sozinha 30% das florestas tropicais da Terra, tenham sido desmatados entre os anos de 2004 e 2015 (INPE, 2015a). Tentando solucionar essa questão o governo brasileiro tem investido na criação de projetos de monitoramento e desenvolvimento sustentável da Amazônia brasileira, denominada, para fins governamentais, Amazônia Legal (ALVES, 2007). O Instituto Nacional de

Pesquisas Espaciais (INPE), por exemplo, vem desenvolvendo desde 1978 projetos de monitoramento de áreas de interesse e prevenção de novos desmatamentos, (DUARTE et al., 2007). Como resultado deste investimento, sistemas operacionais para o monitoramento da floresta amazônica como o Projeto de Monitoramento do Desmatamento na Amazônia Legal por Satélite (PRODES) (INPE, 2013), o Sistema de Detecção de Desmatamento em Tempo Real (DETER) (INPE, 2008a) e o Mapeamento da Degradação Florestal na Amazônia Brasileira (DEGRAD) (INPE, 2010) foram desenvolvidos. Estes sistemas são considerados um dos responsáveis pela diminuição na taxa de desmatamento da Amazônia que entre os anos de 2004 e 2014 foi de 82% (INPE, 2015b).

O projeto PRODES acompanha o desmatamento na Amazônia Legal desde 1988 produzindo e distribuindo estimativas anuais do desmatamento na região. A princípio, o programa tinha sua metodologia baseada apenas na interpretação visual das imagens, mas a partir de 2002 uma nova metodologia, baseada também na classificação digital de imagens de satélite, foi adotada. Essa nova metodologia passou a permitir a divulgação tanto das estimativas quanto dos polígonos de desmatamento, que representam o incremento da área desflorestada a cada ano (INPE, 2008b).

Para a obtenção dessas informações o PRODES utiliza imagens Landsat. No entanto, imagens similares como CCD/CBERS-2, CCD/CBERS-2B, LISS-3, do satélite indiano Resourcesat-1, e imagens do satélite inglês UK-DMC2 já foram utilizadas. Com uma resolução espacial da ordem de 30 metros, o PRODES consegue mapear desmatamentos cujas áreas sejam superiores a 6,25 ha (INPE, 2013). Porém, é preciso ressaltar que apenas as áreas que sofrem corte raso, ou seja, áreas em estágio final do processo de desmatamento no qual a cobertura florestal já foi completamente removida, são identificadas pelo PRODES. Também merece destaque o fato de as estimativas de área para o desmatamento por corte obtidas pelo PRODES serem consideradas confiáveis por cientistas nacionais e internacionais (KINTISH, 2007).

Devido à impossibilidade metodológica do PRODES em divulgar dados de desmatamento em prazos menores o DETER busca, desde 2004, obter informações mais frequentes do desmatamento na região amazônica. Outra lacuna do PRODES que o DETER tenta suprir é o mapeamento de estágios intermediários do processo de desmatamento, apresentando como resultado tanto áreas totalmente desmatadas quanto áreas em processo de desmatamento (SHIMABUKURO et al., 2007). Assim, o DETER se caracteriza como um sistema de alerta de evidências de alteração da cobertura florestal na Amazônia, dando suporte à fiscalização e o controle do desmatamento na região.

Para isso, o programa utiliza imagens ópticas MODIS/TERRA e WFI/CBERS-2B. Esses sensores possuem alta frequência temporal, de 2 e 5 dias, respectivamente, mas uma resolução espacial limitada de 250 metros. Devido a essa resolução espacial apenas desmatamentos cujas áreas são superiores a 25 ha são detectados pelo DETER, porém a alta frequência de observação reduz as limitações impostas pela cobertura de nuvens frequentes na região amazônica (INPE, 2008a).

A metodologia do DETER parte da construção de uma máscara das áreas desmatadas utilizando como referência o mapa das áreas desflorestadas do ano anterior, gerado através do PRODES. Esse procedimento é realizado com o objetivo de recortar das imagens, antes da análise, as regiões sem interesse, o que reduz significativamente a área total analisada. Esse processo também garante que áreas desflorestadas em anos anteriores não sejam incluídas nos resultados do DETER. Assim, todo desmatamento identificado pelo DETER é considerado como desmatamento novo, e é apontado como área de alerta, tornando-se passível de fiscalização (INPE, 2008a).

Já o DEGRAD é um sistema de monitoramento que trata, desde 2007, especificamente áreas em processo de desmatamento, onde a cobertura florestal ainda não tenha sido totalmente removida. Os resultados do DEGRAD,

assim como os do PRODES, são apresentados de forma anual. O DEGRAD utiliza imagens dos satélites Landsat e CBERS e mapeia, assim como o PRODES, uma área mínima de 6,25 ha. Técnicas de realce de contraste são utilizadas para destacar as evidências da degradação, aprimorando a detecção destas regiões (INPE, 2010).

Após a descrição sucinta das metodologias adotadas pelos programas PRODES, DETER e DEGRAD é possível afirmar que, a rigor, estes programas não podem ser considerados como projetos de detecção de mudança. Isso porque a utilização de máscaras contendo áreas de desmatamento já detectadas em anos anteriores com o intuito de diminuir a área analisada faz com que a informação de interesse venha apenas das imagens da época estudada, não havendo, assim, a comparação de forma direta, das informações de duas ou mais datas. Entretanto, mesmo não sendo considerados projetos de detecção de mudanças, estes programas comprovam a importância de se detectar alterações na região. Outro detalhe que merece destaque é o fato de as metodologias do PRODES, DETER e DEGRAD serem baseadas apenas na utilização de dados ópticos. Pois, sabidamente, abordagens tradicionais têm encontrado dificuldade para detectar alterações da vegetação em regiões de floresta, a partir de dados ópticos, devido às condições de nuvens frequentes destas regiões (LU et al., 2008). No entanto, essa dificuldade afeta mais gravemente aquelas metodologias que se propõem a servirem de sistema de alerta para novos desmatamentos, como o DETER. Isso porque essas metodologias precisam gerar resultados para um menor intervalo de tempo, estando assim mais suscetíveis a não obtenção de dados de qualidade no período estudado.

Neste contexto, a possibilidade do uso de dados SAR e ópticos na detecção de mudanças se mostra como uma alternativa para a falta de dados ópticos de qualidade em regiões de florestas tropicais, em algumas datas. Principalmente por poder cobrir as lacunas de dados, sem descartar o uso dos dados ópticos, quando esses estão disponíveis e possuem a qualidade necessária.

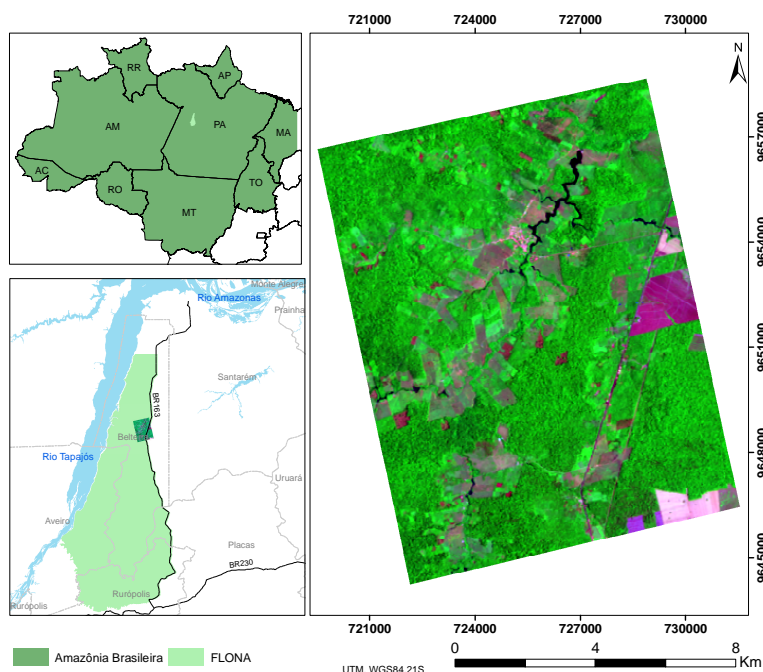
Assim, bons resultados para a detecção de mudanças multissensor baseada em dados SAR e ópticos em região de floresta podem contribuir de forma substancial ao aprimoramento dos sistemas de alertas de desmatamento, por exemplo, transformando-os em programas de monitoramento não mais totalmente dependentes de dados ópticos. Buscando esses bons resultados, a metodologia utilizada neste estudo para a detecção de mudanças multissensor, envolvendo dados SAR e ópticos, na região da Floresta Nacional do Tapajós (FLONA Tapajós) é apresentada a seguir.

3 MATERIAIS

3.1. Área de estudo

A área selecionada para o desenvolvimento deste trabalho está localizada no município de Belterra, Estado do Pará, e estende-se ao redor da rodovia BR-163, também conhecida como rodovia Cuiabá-Santarém (Figura 3.1). Esta região é parte da Floresta Nacional do Tapajós, criada pelo decreto no. 73.684 de 19/02/74, que possui em sua totalidade uma área estimada de 550.000 ha (IBAMA, 2004) e é caracterizada por um clima quente e úmido, com média térmica máxima anual variando entre 31°C a 33°C e média mínima entre 24°C a 25°C. O índice de precipitação pluviométrica anual varia entre 1800 a 2800 mm, com nítida divisão na distribuição das chuvas, que são abundantes no primeiro semestre, mas possuem baixa intensidade no restante do ano. A região possui predominância de floresta tropical úmida e é considerada geomorfologicamente como uma área plana com variações altimétricas entre 50 m e 200 m aproximadamente (ZEE BR-163, 2008).

Figura 3.1 – Localização da área de estudo (Imagem EO-1 ALI R-MS2, G-MS4', B-MS7).



O processo de ocupação da área teve início por volta de 1970 devido ao Projeto de Integração Nacional (PIN) (IBAMA, 2004). Com o intuito de ocupar a Amazônia Brasileira, o governo brasileiro financiou, através do PIN, obras de infraestrutura na região. Dentre as obras realizadas nesse período deu-se a construção da rodovia BR-163. A construção da rodovia e a consequente intensificação da ocupação da área vieram acompanhadas do desmatamento e das atividades associadas a este processo, como a extração de madeira, abertura de áreas agrícolas e de pastagens, o que intensificou a ocorrência de mudanças na região (PEREIRA, 2012). Por essa razão, o desmatamento na região concentra-se principalmente ao longo da rodovia e suas adjacências (NEGRI, 2009). Este mesmo cenário é encontrado em toda a Amazônia e pode ser explicado pela expedição do Decreto Federal nº 1164, de 1971. Este decreto criou faixas de 100 km de ambos os lados de toda estrada federal na Amazônia Legal, sobre as quais o governo passou a exercer o direito de posse e destinou a vários fins, entre os quais a colonização (BECKER, 1991).

Atualmente, a agricultura e a pecuária são as principais atividades econômicas da região (ESCADA et al., 2009), dando origem a uma variedade de classes de cobertura da terra que inclui pastagens, e áreas de cultivo de soja e outros grãos, como arroz, milho e sorgo. Considerando a importância da agricultura na região e a variação de coberturas da terra decorrentes dos processos de transformações, a observação do calendário agrícola se faz necessária. Normalmente, o plantio na região inicia-se em dezembro, com colheita no início de abril. Os agricultores que optam por duas safras anuais realizam o segundo plantio entre os meses de março e abril colhendo-as entre os meses de julho e agosto (ESCADA et al., 2009). Apesar da predominância da agricultura e da pecuária, uma grande diversidade de uso e ocupação da terra é observada na região, o que possibilita a observação de várias classes de cobertura da terra. Pereira (2012), por exemplo, detecta a existência de 13 classes de cobertura da terra em seu estudo para obtenção de classificações da área através da fusão de dados ópticos e SAR. A saber: Floresta Primária, Floresta Primária em

Exploração, Floresta Degradada, Regeneração Antiga, Regeneração Intermediária, Regeneração Inicial, Pasto Sujo, Pasto Limpo, Pasto Limpo com Babaçu e Inajá, Solo Preparado para Agricultura ou em pousio após a colheita, Agricultura em Pousio de 7 a 24 meses, Soja com 100 dias e Soja com 40 dias.

A existência de diversas classes de cobertura da terra e a possibilidade constante de ocorrência de mudanças como desmatamento, diferentes estágios de agricultura e de sucessão secundária, entre outras, foram fundamentais na escolha da região como área de estudo. O conhecimento acumulado sobre a área em trabalhos realizados pelo grupo de pesquisa em radar da Divisão de Processamento de Imagens (DPI) do INPE no local e um rico conjunto de dados também foram fatores predominantes para a escolha da região.

3.2. Dados utilizados

O estudo de detecção de mudanças multissensor na região da FLONA Tapajós, entre os anos de 2009 e 2013, baseou-se em informações obtidas a partir de sensores SAR e sensores ópticos, além de dados de campo. Imagens adquiridas pelo sensor SAR do satélite Radarsat-2, em banda C, em formato *Single Look Complex* (SLC), nos modos *fine quad polarization* 06 e 13 (FQ06 e FQ13), nos dias 09 e 26 de setembro de 2009 respectivamente, foram selecionadas para o estudo. Essa escolha se deu devido a disponibilidade destes dados no acervo do grupo de pesquisa e ao fato de as datas de aquisição serem próximas a trabalhos de campo já realizados na área. As principais características destes dados são apresentadas na Tabela 3.1.

Tabela 3.1 – Características dos dados Radarsat-2.

Modo	Polarizações	Incidência (°)		Resolução Espacial (m)		Data de aquisição	Resolução radiométrica
		<i>near</i>	<i>far</i>	<i>near</i>	<i>far</i>		
FQ06	HH, HV, VH e VV	24,6	26,4	12,5	11,7	09/09/2009	16 bits
FQ13		32,4	34,0	9,7	9,3	26/09/2009	

A seleção dos dados ópticos também se baseou na data de trabalhos de campo previamente realizados na área de estudo. Dados Landsat livres da cobertura de nuvens para as datas desejadas não foram encontrados. Assim, dados obtidos através da aquisição de imagens do sensor *Advanced Land Imager* (ALI) do satélite *Earth Observing-1* (EO-1 ALI) no dia 05 de outubro de 2013, disponibilizadas gratuitamente pelo *United States Geological Survey* (<http://www.usgs.gov/>) foram selecionadas. Os dados EO1-ALI são disponibilizados em 9 bandas multiespectrais, com resolução nominal de 30 m e resolução radiométrica de 16 bits. Uma comparação entre as faixas espectrais dos dados EO-1 ALI e dos dados Landsat ETM+, frequentemente utilizados para classificações da cobertura da terra e detecção de mudanças (ADAMS et al., 1995; ROBERTS et al., 1998; LU et al., 2004b), é apresentada na Tabela 3.2. A partir dessa comparação é possível perceber que os dados EO-1 ALI possuem 3 bandas espectrais não observadas nos dados Landsat ETM+ denominadas MS-1', MS-4' e MS-5' e das 6 bandas comparáveis às bandas dos dados Landsat 5 possuem intervalos espectrais idênticos (BICKNELL et al., 1999).

Tabela 3.2 – Faixas espectrais dos dados EO-1 ALI – data de aquisição 05/10/2013.

Banda	EO-1 ALI Faixa espectral (μm)	Landsat ETM+ Faixa espectral (μm)
MS-1'	0,433 - 0,453	-
MS-1	0,45 - 0,515	0,45 - 0,515
MS-2	0,525 - 0,605	0,525 - 0,605
MS-3	0,63 - 0,69	0,63 - 0,69
MS-4	0,775 - 0,805	0,75 - 0,9
MS-4'	0,845 - 0,89	-
MS-5'	1,2 - 1,3	-
MS-5	1,55 - 1,75	1,55 - 1,75
MS-7	2,08 - 2,35	2,08 - 2,35

Fonte: Adaptado de Bicknell et al. (1999).

De acordo com as escolhas de dados realizadas o trabalho de detecção multissensor aqui apresentado se baseia na utilização de dados SAR para a primeira data e dados ópticos para a segunda data de interesse. No entanto, é preciso ressaltar que o mesmo pode ser realizado, seguindo a mesma metodologia, para dados ópticos na primeira data e dados SAR na segunda data se assim exigirem os dados disponíveis.

As imagens SAR em modo FQ06 e FQ13 e a imagem EO-1 ALI, já recortadas para a área de interesse, são apresentadas na Figura 3.2. Composições coloridas RGB são utilizadas para destacar a diferença visual entre os tipos de dados utilizados neste estudo.

Além de imagens ópticas e SAR, dados de campo também foram utilizados no estudo. Estes dados, para os dois anos em questão, foram coletados através de trabalhos de campo realizados por equipes do Instituto Nacional de Pesquisas Espaciais (INPE) em setembro de 2009 e agosto de 2013 e são compostos por descrições das áreas visitadas, coordenadas geográficas e fotografias geolocalizadas. Pontos de controle (PCs) implantados no terreno durante o trabalho de campo de 2013, através do método estático relativo, foram utilizados para obtenção do registro dos dados SAR e ópticos já citados. Uma imagem do satélite QuickBird, de 19 agosto de 2012, gerada pela fusão das bandas multiespectral e pancromática, através da técnica de Gram-Schmidt, com resolução espacial de 0,60m também foi utilizada na etapa de registro das imagens. A localização das fotos obtidas nos trabalhos de campo de 2009 e 2013 e dos PCs utilizados para fins de registro podem ser vistas na Figura 3.3. Dentro da área de interesse são contabilizadas 667 fotos do ano de 2009 e 168 fotos do ano de 2013. A partir da localização dessas fotos é possível afirmar que as áreas visitadas em 2013 são em sua maioria áreas já visitadas no de 2009. No entanto, nem todas as áreas visitadas em 2009 foram revisitadas em 2013.

Figura 3.2 – a) Imagem Radarsat FQ06 (R-HH, G-HV e B-VV), b) Imagem Radarsat FQ06 (R-HH, G-HV e B-VV), c) Imagem EO-1 ALI (R-MS2, G-MS4', B-MS7).

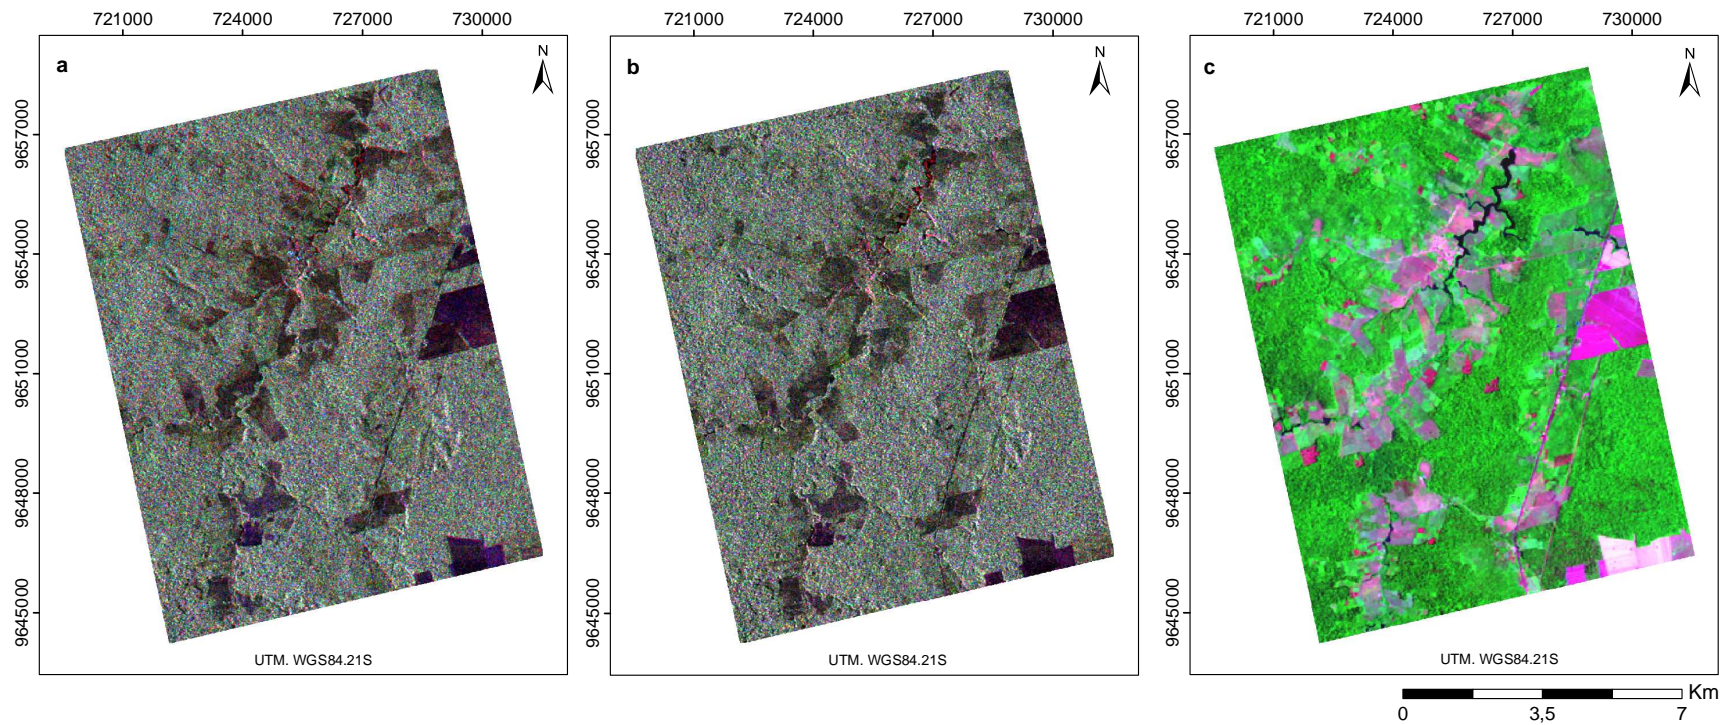
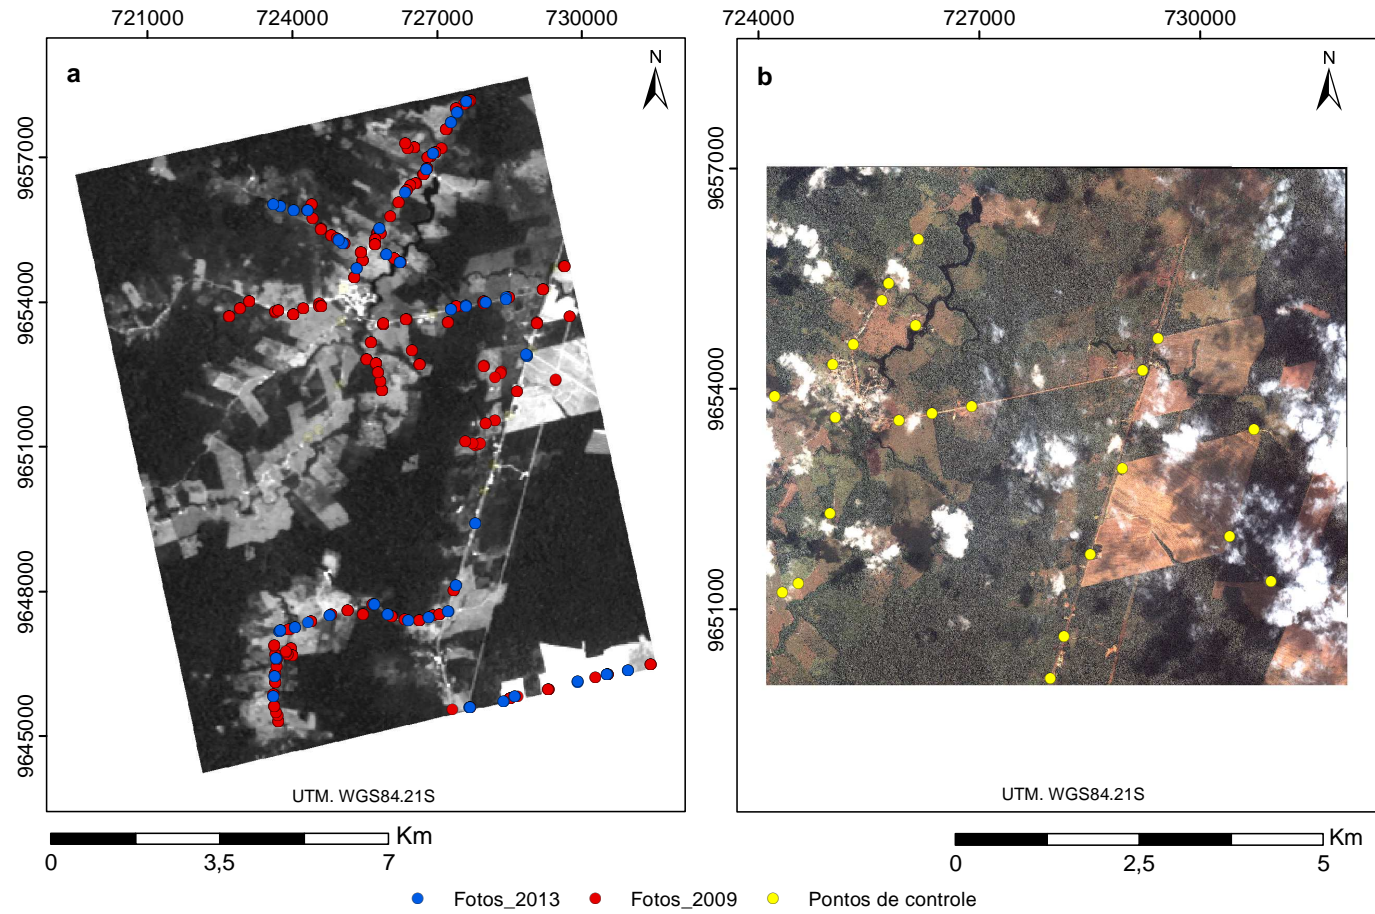
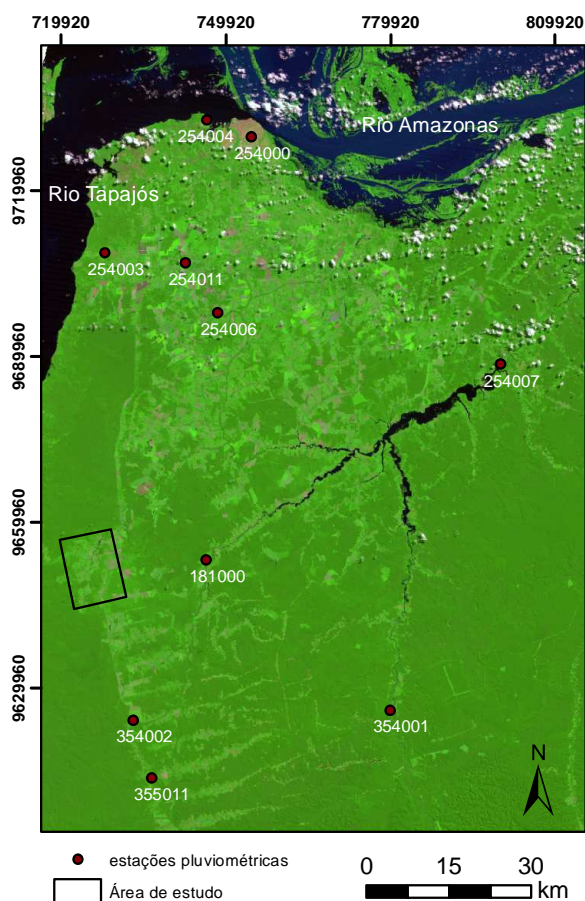


Figura 3.3 – a) Localização das fotos nos anos de 2009 e 2013 e b) localização dos pontos de controle de alta precisão utilizados para fins de registro.



Considerando a importância das condições meteorológicas na escolha dos dados ópticos e o fato de que o aumento da umidade causa alterações na constante dielétrica dos materiais, o que por sua vez pode alterar as respostas dos alvos nas imagens SAR (RANEY, 1998), as informações de precipitação para a área de estudo no período da aquisição das imagens também foram utilizadas no estudo. A localização das estações pluviométricas próximas a área de estudo, com dados disponibilizadas pelo Sistema de Informações Hidrológicas (HidroWeb) da Agência Nacional de Águas (ANA) (ANA, 2013), a partir das quais os dados puderam ser coletados, é apresentada na Figura 3.4.

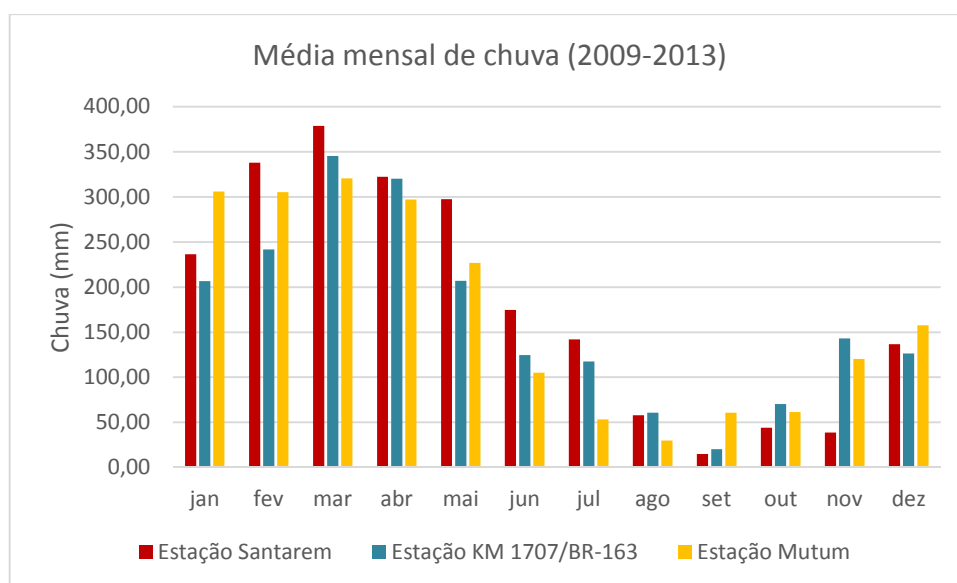
Figura 3.4 – Localização das estações pluviométricas próximas a área de estudo.



Dentre as estações apresentadas na Figura 3.4. apenas as estações 355001 - Mutum, 254011 - KM 1707/BR-163 e 254004 - Santarém possuem informações

referente as datas de interesse. Assim, as médias mensais de chuva, calculadas de acordo apenas com os dados de cada uma dessas estações, são apresentados na Figura 3.5. De forma a facilitar a visualização do padrão de precipitação na área durante o intervalo de estudo o gráfico foi gerado para o intervalo no qual as mudanças são estudadas, ou seja, entre os anos de 2009 e 2013.

Figura 3.5 – Média mensal de chuva, na área de estudo, entre os anos de 2009 e 2013.



Como forma de auxiliar a discussão do comportamento dos diferentes alvos em cada um dos dados utilizados no estudo os valores de precipitação medidos nos meses de setembro de 2009 e outubro de 2013, nos quais os dados SAR e ópticos foram adquiridos, também foram obtidos dia a dia, como apresentado na Tabela 3.3. Os dias em destaque referem-se a data exata de aquisição de um dos dados utilizados no estudo.

Tabela 3.3 – Dados Pluviométricos diários, em milímetros, para os meses de setembro de 2009 e outubro de 2013 a partir das estações pluviométricas 355001 - Mutum, 254011 - KM 1707/BR-163 e 254004 - Santarém.

Aquisição dados SAR				Aquisição dado Óptico			
Dia	Mutum	Santarém	Km 1707	Dia	Mutum	Santarém	Km 1707
01/09/2009	0	0	0	01/10/2013	1,3	6,3	0
02/09/2009	0	0	0	02/10/2013	8,4	0,3	0
03/09/2009	0	0	0	03/10/2013	0	0	0
04/09/2009	0	0	0	04/10/2013	0	0	0
05/09/2009	0	0	0	05/10/2013	0	0	0
06/09/2009	0	0	0	06/10/2013	0	0	0
07/09/2009	0	0	0	07/10/2013	0	2,2	0
08/09/2009	0	0	0	08/10/2013	8,3	0	0
09/09/2009	0	4,1	3,6	09/10/2013	0,6	0	0
10/09/2009	0	0	0	10/10/2013	26	1,2	0
11/09/2009	0	0	0	11/10/2013	0	0	0
12/09/2009	0	0	0	12/10/2013	0	0	0
13/09/2009	8,8	0	0	13/10/2013	0	0	0
14/09/2009	0	0	0	14/10/2013	0	0	0
15/09/2009	0	0	4,9	15/10/2013	0	0	0
16/09/2009	0	0	0	16/10/2013	0	0	0
17/09/2009	0	0	0	17/10/2013	0	0	0
18/09/2009	0	0	0	18/10/2013	0	0	0
19/09/2009	0	0	0	19/10/2013	0	0	0
20/09/2009	0	0	0	20/10/2013	0	0	0
21/09/2009	0	0	2,3	21/10/2013	0	0	0
22/09/2009	0	0	0	22/10/2013	0	0	0
23/09/2009	0	0	0	23/10/2013	0	0	0
24/09/2009	0	0	0	24/10/2013	0	0	0
25/09/2009	0	0	0	25/10/2013	0	0	0
26/09/2009	0	0	0	26/10/2013	4,5	0	0
27/09/2009	0	0	0	27/10/2013	0	0	0
28/09/2009	0	0	0	28/10/2013	0	0	0
29/09/2009	0	0	0	29/10/2013	0	16,2	0
30/09/2009	0	0	0	30/10/2013	0	60,1	14,6
-	-	-	-	31/10/2013	0	5	16,3

4 METODOLOGIA

A metodologia de detecção de mudanças multissensor utilizada neste estudo foi desenvolvida através do encadeamento de diversas etapas. Devido às diferentes características dos dados SAR e ópticos, essas etapas foram divididas em dois grandes grupos. O grupo I contém as etapas de pré-processamento dos dados e seleção de atributos, aplicadas separadamente a dados SAR e ópticos, como mostra o fluxograma da Figura 4.1. O grupo II contém as etapas de classificação das imagens através dos algoritmos Máquina de Vetor Suporte (SVM, do inglês *Support Vector Machine*) e Máxima Verossimilhança (Maxver), os métodos de detecção de mudanças por comparação pós-classificação e classificação direta e finalmente as validações dos resultados obtidos, igualmente aplicadas aos dois tipos de dados, como mostra o fluxograma da Figura 4.2. As etapas do grupo II são realizadas a partir dos resultados obtidos pelas etapas do grupo I.

A descrição detalhada das etapas realizadas se dará seguindo a divisão proposta. Primeiramente serão descritos os processos realizados no grupo I, subdivididos em três categorias: pré-processamento, definição das classes de cobertura e amostras de treinamento e validação e seleção de atributos. Posteriormente serão descritos os processos realizados no grupo II, subdivididos em quatro categorias: classificação da cobertura da terra, avaliação das classificações, detecção de mudanças e avaliação da detecção de mudança.

Figura 4.1 – Fluxograma das atividades do grupo I.

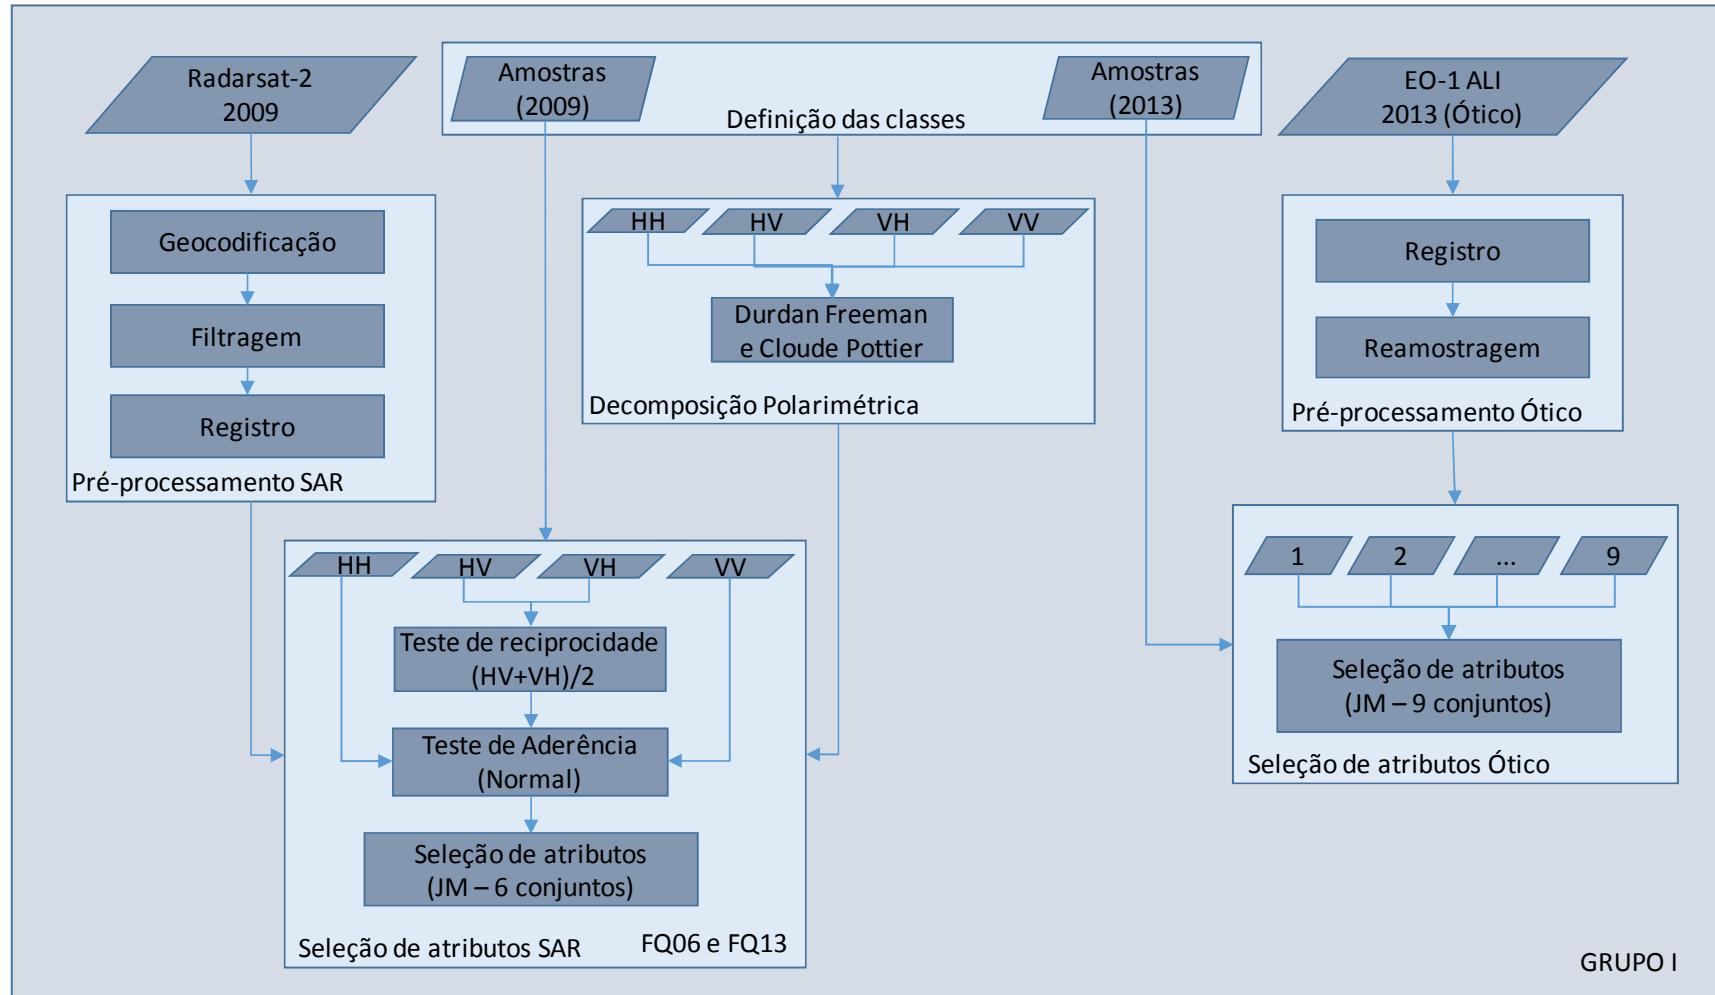
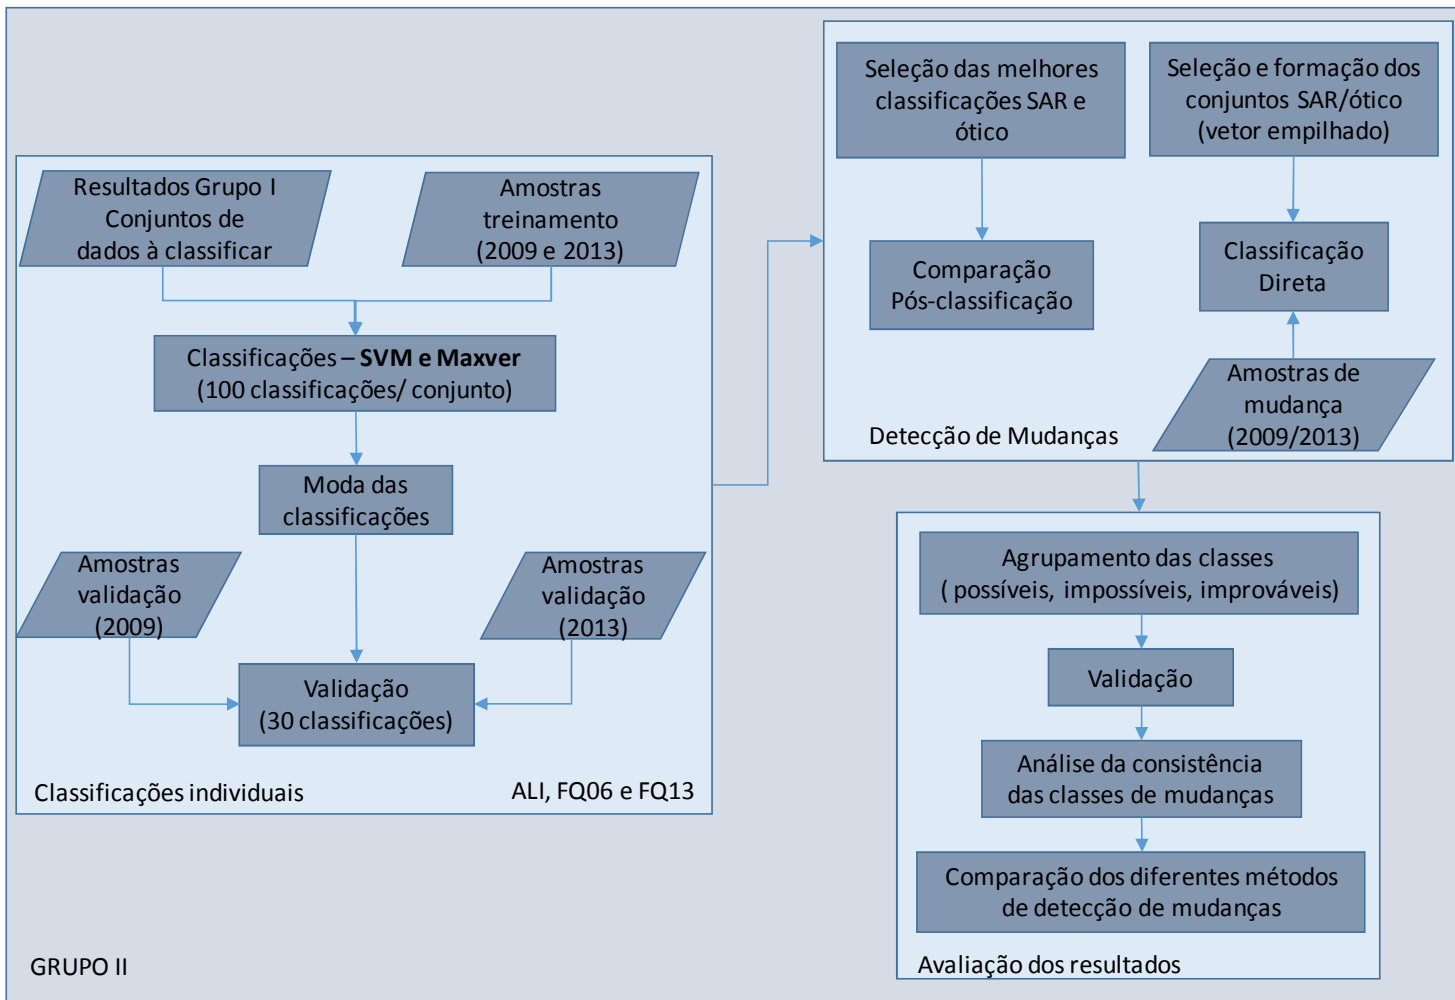


Figura 4.2 – Fluxograma das atividades do grupo II.



4.1. Pré-processamento

As etapas de pré-processamento foram baseadas em diferentes processos para os diferentes tipos de dados. Enquanto o pré-processamento das imagens ópticas baseou-se apenas na reamostragem e no registro dos dados, o pré-processamento das imagens SAR se dividiu em geocodificação, filtragem e registro. Primeiramente serão tratadas as etapas de pré-processamento aplicadas apenas aos dados SAR.

A geocodificação dos dados Radarsat-2 originais, tanto para o modo FQ06 quanto para o modo FQ13, foi gerada através do *software* ASF MapReady 3.1. Nesse processo as imagens, contendo as polarizações HH, HV, VH e VV, foram projetadas no sistema de coordenadas UTM (*Universal Transverse Mercator*), Zona 21S, datum WGS-84 (*World Geodetic System 1984*) e seus *pixels* reamostrados, através do método de reamostragem por vizinho mais próximo, para 10 m por 10 m. Também como resultado desse processo, as imagens, originalmente em valores complexos e em *slant range*, foram convertidas para dados de amplitude em *ground range*.

Com o intuito de reduzir o ruído *speckle*, o filtro *Gama* adaptativo, baseado em um modelo de ruído multiplicativo, com janela 3x3, foi aplicado aos dois modos dos dados Radarsat-2. A escolha do filtro *Gama* se deu devido à existência de trabalhos que mostram que áreas de vegetação são melhores modeladas quando se supõe, para o ruído *speckle*, a distribuição *Gama* (MANSOURPOUR et al., 2006). Após a geocodificação e a filtragem dos dados SAR, deu-se início ao registro dos dados. Esse processo pode ser aplicado igualmente aos dados ópticos e SAR. Como os dados EO-1 ALI utilizados no estudo já foram disponibilizados no sistema de projeção UTM, Zona 21S e datum WGS 84, apenas um processo de reamostragem se fez necessário antes do registro. Os *pixels* da imagem EO - 1 ALI foram reamostrados para 10 m por 10 m, usando o interpolador do vizinho mais próximo.

O processo de registro das imagens foi realizado com base em uma imagem QuickBird de 19 de agosto de 2012, previamente registrada, para que os dados e os resultados obtidos carregassem consigo uma geocalização precisa da área de interesse. A utilização desta imagem QuickBird como imagem auxiliar no processo de registro se deu devido ao fato de esta ser a imagem sobre a qual os pontos de controle de alta precisão coletados em campo foram selecionados. Assim, o registro da imagem Quick Bird foi realizado com base em 23 dos pontos de controle implantados durante o trabalho de campo de 2013, sendo 16 utilizados para a correção geométrica e 7 utilizados na avaliação do resultado. O registro, aplicando-se a transformação polinomial de 1.^a ordem e o interpolador do vizinho mais próximo resultou em um erro médio quadrático (RMS, do inglês *Root Mean Squared*) de 0,4 *pixel*. Detalhes desse processo de registro são apresentados em Oliveira et al. (2015).

O registro das imagens Radarsat-2 e dos dados EO-1 ALI, com base na imagem QuickBird já citada, foi realizado através do processo imagem para imagem, aplicando-se a transformação polinomial de 2.^a ordem e o interpolador do vizinho mais próximo. Os valores de RMS de 0,7; 1,0 e 0,4 *pixel* foram obtidos para as imagens Radarsat-2 FQ06, Radarsat-2 FQ13 e EO-1 ALI respectivamente. Após os processamentos aqui apresentados, os conjuntos de dados SAR e óptico encontravam-se aptos à classificação. No entanto, uma etapa intermediária de seleção de atributos foi realizada, buscando reduzir a quantidade de canais utilizados e selecionar as melhores combinações entre eles.

4.2. Definição das classes de cobertura e das amostras de treinamento e validação

Os dados de campo coletados nos anos de 2009 e 2013 foram utilizados tanto na definição das classes de cobertura da terra quanto na elaboração das amostras de treinamento e validação utilizados no trabalho. As amostras de treinamento foram utilizadas para classificar as imagens SAR e ópticas e as

amostras de validação utilizadas para validar os resultados obtidos. Considerando as informações contidas em fotografias com coordenadas geográficas e as anotações feitas durante as visitas *in loco*, um conjunto de 9 classes de cobertura da terra pôde ser definido. Agricultura (AG), Solo Exposto (BS, do inglês *Bare Soil*), Pasto Limpo (CP, do inglês *Clean Pasture*), Pasto Sujo (DP, do inglês *Dirty Pasture*), Superfícies Impermeáveis (IS, do inglês *Impervious Surface*), Floresta Madura (MF, do inglês *Mature Forest*), Sucessão Secundária Inicial (SS1), Sucessão Secundária Intermediária (SS2) e Água (WAT, do inglês *Water*). Uma breve descrição de cada classe de cobertura da terra é apresentada a seguir e fotografias de áreas pertencentes a cada uma dessas classes são apresentadas na Figura 4.3.

Agricultura (AG): áreas cultivadas em diferentes estágios de crescimento (Soja, Feijão, Milho);

Solo Exposto (BS): áreas de solo exposto, incluindo solo preparado para agricultura e após a colheita, e áreas de soja pronta para colheita e de vegetação muito esparsa que respondem como solo exposto;

Pasto Limpo (CP): áreas de pastagens com poucas espécies invasoras e arbustivas;

Pasto Sujo (DP): áreas utilizadas para pastagem com presença de espécies invasoras;

Superfícies Impermeáveis (IS): superfícies nas quais a água não pode penetrar, na região apenas telhados e a rodovia;

Floresta Madura (MF): composta por áreas de floresta primária em que a ação humana não provocou ações significativas em suas características originais de estrutura e por sucessão secundária avançada.

Sucessão Secundária Inicial (SS1): áreas de vegetação secundária com predominância de herbáceas e arbustos;

Sucessão Secundária Intermediária (SS2): áreas com presença de vegetação secundária com poucas espécies herbáceas e predominância de árvores de pequeno porte e arbustos;

Água (WAT): corpos hídricos em geral, principalmente igarapés.

Figura 4.3 – Exemplo das classes de cobertura da terra definidas para o estudo: a) Agricultura; b) Solo Exposto, c) Pasto Limpo, d) Pasto Sujo; e) Superfícies Impermeáveis; f) Floresta Madura; g) Sucessão Secundária Inicial; h) Sucessão Secundária Intermediária; e i) Água.



Após a definição das classes, os dados de campo possibilitaram a elaboração das amostras de treinamento e validação do ano de 2013. As amostras de treinamento e validação para o ano de 2009 já existiam, e foram obtidas a partir dos dados de campo de 2009 por outros integrantes do grupo de pesquisa em radar DPI - INPE. A localização destas amostras de treinamento e de validação para o ano de 2009 são apresentadas na Figura 4.4, enquanto a localização das amostras de treinamento e validação para o ano de 2013 são apresentadas na Figura 4.5.

Figura 4.4 – Localização das amostras para o ano de 2009: a) treinamento e b) validação, ambas sobre os dados Radarsat - 2 em modo FQ06 (composição RGB – HH/HV/VV).

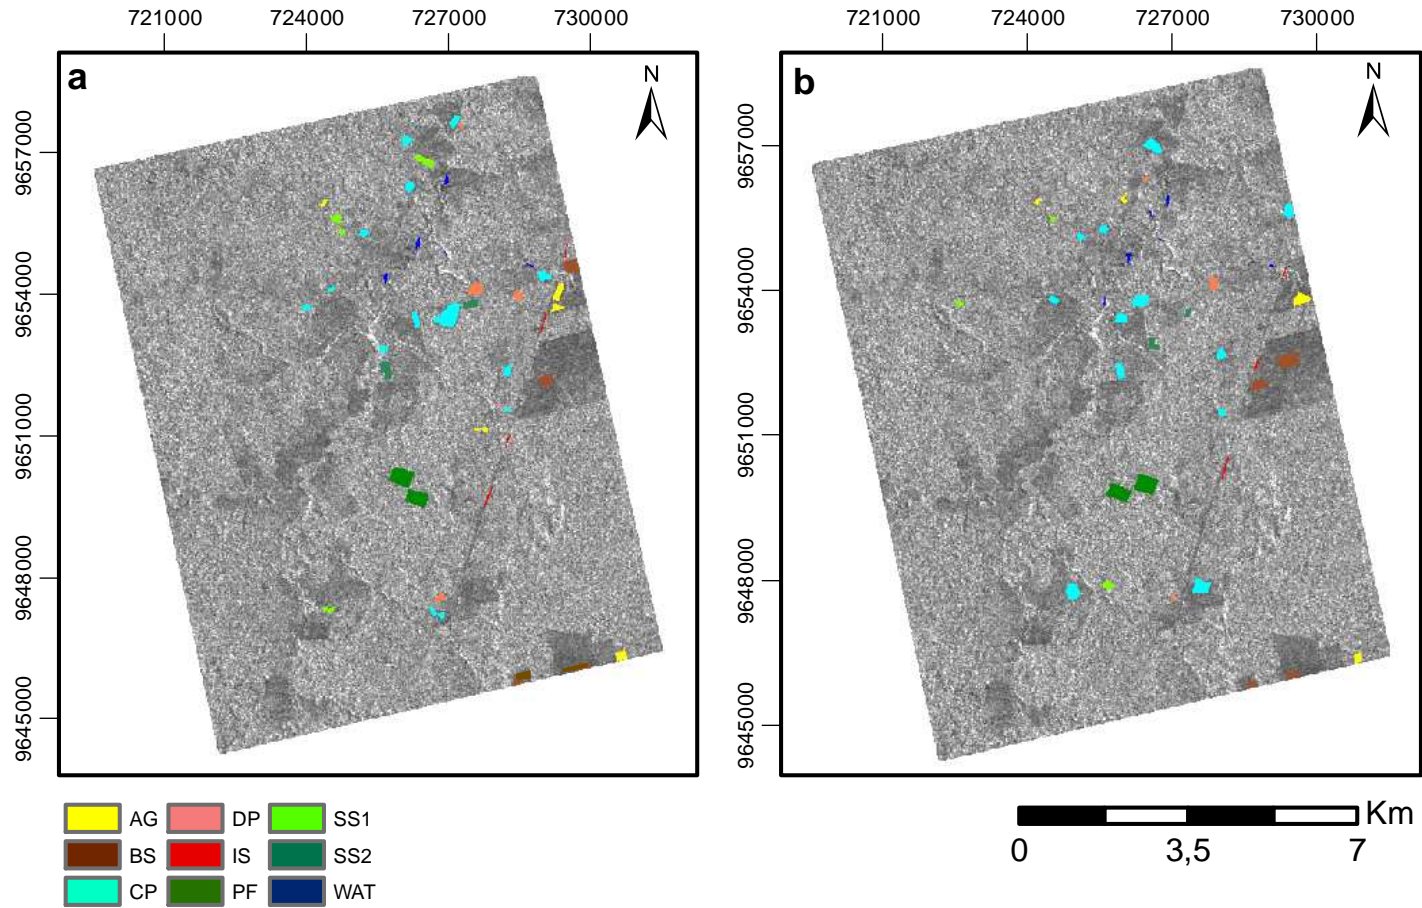
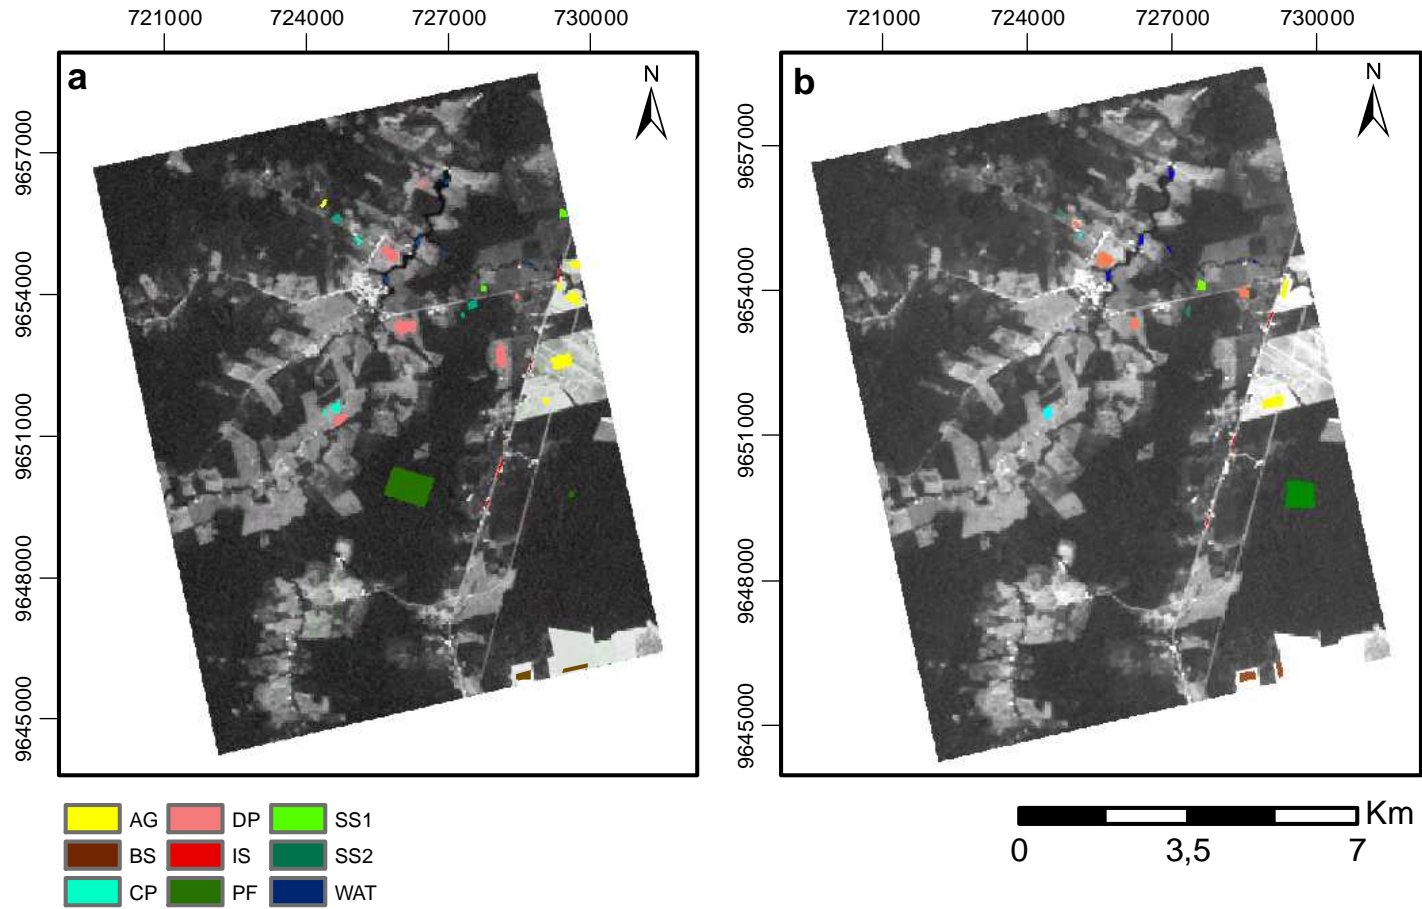


Figura 4.5 – a) Localização das amostras para o ano de 2013: a) treinamento e b) validação, ambas sobre os dados EO-1 ALI (banda MS-2).



A quantidade de *pixels* para as amostras de treinamento e validação obtidos para cada uma das classes em questão para os anos de 2009 e 2013 é apresentada na Tabela 4.1.

Tabela 4.1 – Quantidade de *pixels* por amostra para treinamento e validação nos anos de 2009 e 2013.

Classes	Amostras 2009		Amostras 2013	
	Treinamento	Validação	Treinamento	Validação
AG	1469	1119	2383	1283
BS	1991	2260	1223	963
CP	5084	5511	611	486
DP	1265	627	3648	1707
IS	402	320	412	230
MF	2826	2709	6035	3219
SS1	1235	613	443	325
SS2	1187	550	664	262
WAT	550	395	420	384

4.3. Seleção de atributos

Um processo de seleção de atributos é realizado com o intuito de diminuir a dimensionalidade do espaço de atributos. Este processo seleciona os conjuntos de atributos que apresentam uma maior separabilidade entre classes e uma variância pequena dentro de uma mesma classe (THEODORIDIS; KOUTROUMBAS, 2009), o que teoricamente retornaria melhores classificações.

Os dados envolvidos neste estudo de detecção de mudanças são compostos por diferentes números de atributos e conseqüentemente um diferente número de combinações entre eles. O dado EO-1 ALL, composto por 9 bandas, pode dar origem a 511 diferentes combinações de atributos. Os dados SAR, compostos pelos atributos HH, HV, VH e VV podem dar origem a 15 conjuntos distintos de atributos para cada um dos modos analisados. Para evitar a classificação de todos esses conjuntos, um processo de seleção de atributos foi adotado.

Dentre as medidas de separabilidade entre classes segundo um mesmo conjunto de atributos, podem-se citar as distâncias de Bhatthacharyya e de Jeffries-Matusita (JM). Como a distância de Bhatthacharyya cresce sem limites para classes altamente separáveis, a distância JM, dada pela Equação 4.1, é muitas vezes preferida, pois não apresenta esse inconveniente (SCHOWENGERDT, 2006).

$$DistJM = \sqrt{2(1 - e^{-B_{kl}})} \quad (4.1)$$

em que B_{kl} é a distância de Bhatthacharyya entre as classes k e l , definida para valores com distribuição gaussiana, pela Equação 4.2 (THEODORIDIS; KOUTROUMBAS, 2009):

$$B_{kl} = \frac{1}{8}(\mu_k - \mu_l)^T \left(\frac{\Sigma_k + \Sigma_l}{2} \right)^{-1} (\mu_k - \mu_l) + \frac{1}{2} \ln \left(\frac{\left| \frac{\Sigma_k + \Sigma_l}{2} \right|}{\sqrt{|\Sigma_k| \cdot |\Sigma_l|}} \right) \quad (4.2)$$

em que μ_k é o vetor de médias das amostras da classe k , μ_l é o vetor de médias das amostras da classe l , Σ_k é a matriz de covariâncias da classe k e Σ_l é a matriz de covariâncias da classe l , $(\cdot)^T$ é o transposto e $|\cdot|$ o determinante da matriz.

Mesmo dependendo dos valores da distância Bhatthacharyya, a distância JM apresenta resultados que variam apenas entre 0, quando não há separabilidade nenhuma entre as classes, e $\sqrt{2}$, quando as classes são totalmente separáveis. Isso porque o peso atribuído ao valor B_{kl} na distância JM decresce de forma exponencial, não alterando seu resultado a partir de determinados valores. Por essa razão, uma seleção de atributos baseada na escolha dos canais que apresentam a máxima mínima distância JM foi escolhida para esse estudo.

A seleção de atributos foi realizada a partir do aplicativo MultiSpec 3.3 e ocorreu sem problemas para os dados ópticos. A partir da imagem EO-1 ALI com 9 bandas e as amostras de cobertura da terra para o ano de 2013

(treinamento e validação) a distância Bhatthacharyya entre cada par de classes foi calculada, para todas as combinações de canais possíveis. Com os valores da distância Bhatthacharyya, a distância JM pôde ser calculada. Dentre todas as distâncias entre pares de classes, para uma determinada combinação de canais, o valor mínimo é selecionado, destacando o par de classes com menor separabilidade para aquela combinação de canais. Dentre todas as combinações possíveis para um número de canais, aquela que apresente a maior mínima distância JM é selecionada, garantindo uma separabilidade mínima entre as classes. Ao final do processo foram selecionados então, o canal a ser classificado isoladamente, a combinação de dois canais a ser classificada e assim por diante, até a combinação de 8 canais a ser classificada, de acordo com o critério estabelecido. Para um melhor entendimento do processo realizado um exemplo é apresentado.

Tabela 4.2 – Exemplo de cálculo da máxima mínima distância JM

Canais	Distância JM Mínima	Distância JM média	AB	AC	AD	BC	BD	CD
1 2 3	1,31	1,31	1,31	1,32	1,31	1,31	1,31	1,31
3 4 8	1,30	1,36	1,40	1,32	1,30	1,41	1,41	1,31
2 4 5	1,28	1,35	1,38	1,33	1,30	1,41	1,39	1,28
1 2 4	1,27	1,38	1,41	1,27	1,38	1,41	1,40	1,39
2 3 7	1,26	1,34	1,40	1,26	1,29	1,41	1,41	1,29

A Tabela 4.2 mostra um resultado fictício de seleção do melhor conjunto de 3 canais, em um total de 8 canais existentes. Considerando a existência de 8 canais, 56 combinações de 3 canais seriam possíveis, no entanto apenas as cinco melhores são apresentadas no exemplo. As colunas AB, AC, AD, BC, BD e CD apresentam as distâncias JM entre cada par de classes possível em um conjunto de 4 classes distintas A, B, C e D. A coluna distância JM mínima apresenta o menor valor dentre as distâncias JM calculadas enquanto a distância JM média apresenta a médias destas mesmas distâncias. Nesta situação hipotética o conjunto de canais 1, 2 e 3 seria escolhido por possuir o maior valor dentre as mínimas distâncias calculadas. No entanto é preciso destacar que a escolha do critério mínima distância prioriza conjuntos em que

todas as classes tenham um limite mínimo de separabilidade. Caso o critério escolhido para a seleção de canais na situação apresentada acima fosse a média da distância JM o conjunto de canais selecionados seria 1, 2 e 4, mesmo com uma distância mínima inferior ao conjunto 1, 2 e 3.

Com o resultado da seleção de atributos dos dados ópticos partiu-se para a seleção de atributos dos dados SAR. No entanto, a primeira forma de reduzir o espaço de atributos desses dados baseou-se na conhecida reciprocidade dos alvos nas polarizações cruzadas HV e VH. Buscando comprovar essa reciprocidade nos dados utilizados um teste t pareado, indicado para amostras dependentes, como é o caso, foi realizado. O teste considerou um conjunto de 900 *pixels*, abrangendo todas as 9 classes utilizadas no estudo (100 *pixels* por classe). A diferença entre os valores de cada um dos 900 *pixels* envolvidos no processo foi calculada para os canais HV e VH tanto no modo FQ06 quanto no modo FQ13. Os valores de média e desvio padrão dessa diferença, obtidos para os dois modos, comprovaram via teste t pareado, que não existem motivos para acreditar que os canais HV e VH sejam diferentes. A partir dessa comprovação os canais HV e VH foram descartados do estudo, e um novo canal gerado pela média dos mesmos $((HV + VH) / 2)$ passou a ser considerado.

A comprovação da reciprocidade dos alvos nos canais HV e VH reduziu as opções de combinações entre os canais a 7 possibilidades para cada modo. Porém, um processo de seleção de atributos buscando determinar os conjuntos com 1, 2 e 3 canais que apresentassem a maior separabilidade entre as classes do estudo ainda era desejado. No entanto, a utilização da seleção de atributos baseada em distância JM, para dados SAR, seguindo os parâmetros definidos para os dados ópticos, esbarra no inconveniente de o valor B_{kl} utilizado no cálculo da distância JM ser definido apenas para valores com distribuição gaussiana. Dados SAR sabidamente não seguem uma distribuição gaussiana (GOODMAN, 1976). Porém, os processamentos de transformação de *slant range* para *ground range*, a obtenção de dados em modo amplitude, a

reamostragem e a filtragem previamente realizados têm a característica de alterarem a distribuição dos dados. Nesse contexto, um teste de aderência dos dados processados a uma distribuição gaussiana foi conduzido através de uma implementação em ambiente R, considerando todas as amostras (treinamento e validação) de todas as 9 classes. O resultado obtido comprovou que a distribuição de cada uma das classes, em cada um dos três atributos testados (HH, (HV+VH)/2, VV), nos dois modos, se adequa a uma distribuição gaussiana, o que possibilitou o uso do método de seleção de atributos por máxima mínima distância JM como o conduzido para os dados ópticos. Ao final do processo foram selecionados o melhor canal a ser classificado isoladamente e a melhor combinação de dois canais a ser classificada.

Ao fim dos procedimentos de seleção de atributos, as 511 combinações possíveis dos canais do dado EO-1 ALI foram reduzidas a 9 conjuntos a ser classificados, sendo eles a melhor banda a ser classificada isoladamente, a melhor combinação de 2, 3, 4, 5, 6, 7 e 8 canais e o conjunto contendo todos os canais. O mesmo ocorreu para os dados SAR que foram reduzidos de 15 combinações possíveis a apenas 3 combinações para cada modo, sendo elas o melhor canal a ser classificado isoladamente, a melhor combinação de dois canais e o conjunto contendo os três canais disponíveis para os modos FQ06 e FQ13.

4.4. Decomposição polarimétrica dos dados SAR

Buscando fazer uso de toda a informação polarimétrica existente nos dados Radarsat-2, as decomposições polarimétricas (DPs) de Cloude e Pottier (DCP) e Freeman e Durden (FD) foram geradas. Estas decomposições foram extraídas das matrizes de covariância e coerência dos dados SAR polarimétricos originais, tanto para o modo FQ06 quanto para o modo FQ13. O software PolSARpro 5.0 foi utilizado tanto para gerar as matrizes de covariância e coerência, baseadas nos dados SAR originais, quanto para a extração das decomposições polarimétricas.

Decomposições polarimétricas buscam expressar o sinal coletado pelo sensor SAR como uma soma de elementos independentes, normalmente associados a um mecanismo físico (CLOUDE; POTTIER, 1996). Assim, a decomposição de Freeman e Durden decompõe a matriz de covariância dos dados SAR com base em três modelos diferentes de espalhamento. São eles: o modelo de espalhamento na copa ou volume dos alvos, o modelo de espalhamento na superfície dos alvos e o modelo de espalhamento *double bounce*, que ocorre em superfícies ortogonais com diferentes constantes dielétricas. Como resultado, a decomposição de Freeman e Durden dá origem aos atributos espalhamento volumétrico (P_V), espalhamento *double bounce* (P_D) e espalhamento superficial (P_S) (FREEMAN; DURDEN, 1998).

Já a decomposição de Cloude e Pottier decompõe a matriz de coerência dos dados SAR polarimétricos na soma de três novas matrizes de coerência, cada uma delas ponderada por seus correspondentes autovalores (LEE; POTTIER, 2009). Nessa decomposição cada matriz de espalhamento unitária representa uma contribuição do espalhamento total na qual os autovetores contêm informação sobre o tipo de espalhamento e os autovalores informam o quanto o espalhamento descrito pelo autovetor correspondente contribui para o processo de espalhamento como um todo. Ao fim do processo três parâmetros secundários são definidos em função dos autovetores e autovalores encontrados, dando origem a três atributos. São eles: a entropia (H), que mede o grau de desordem do processo de espalhamento; a anisotropia (A), que indica a importância dos tipos de espalhamentos secundários, sendo assim um parâmetro complementar à entropia; e o ângulo alfa (α) que determina o tipo de espalhamento dominante (superficial, volumétrico ou do tipo *double bounce*) (CLOUDE; POTTIER, 1997).

Assim, através da decomposição polarimétrica, 6 novos atributos (P_V , P_D , P_S , H , A e α) tornaram-se disponíveis para utilização tanto para o modo FQ06 quanto para o modo FQ13. E como produtos gerados por decomposição de alvos podem ser combinados com técnicas que consideram as propriedades

estatísticas dos dados polarimétricos (RIBEIRO et al., 2013), esses novos atributos puderam ser associados aos dados SAR originais e posteriormente classificados.

4.5. Classificação da cobertura da terra

O processo de detecção de mudança por comparação pós-classificação gerou a necessidade de se obter as classificações da cobertura da terra para todas as datas de interesse do estudo. A existência de informação de campo, coletada em datas próximas às datas de aquisição das imagens, possibilitou a classificação supervisionada dos conjuntos de atributos previamente selecionados. Os classificadores supervisionados SVM e Maxver foram selecionados para o estudo.

O classificador Maxver é o método de classificação supervisionado mais comum aplicado aos dados de sensoriamento remoto. É um classificador *pixel* a *pixel*, de baixo custo computacional, que se baseia na caracterização estatística do conjunto de dados analisados e no teorema de Bayes. Nesse tipo de classificador, o conjunto de treinamento define um diagrama de dispersão das classes e suas distribuições de probabilidade, considerando uma distribuição pré-estabelecida para cada uma destas classes. Assim, cada *pixel* passa a ser associado à classe à qual apresenta a maior probabilidade de pertencer. Normalmente o método da Máxima Verossimilhança se baseia em funções densidade de probabilidade gaussianas, como o adotado neste estudo. No entanto, algumas implementações apresentam a possibilidade de utilizar outras distribuições para a modelagem das classes (FRERY et al., 2007).

Já o classificador SVM baseia-se na obtenção de um hiperplano ideal de separação entre pares de classes, a partir de um conjunto de amostras contendo informação a respeito de todas as classes. Esse hiperplano ideal é aquele que possui a maior distância para os elementos mais próximos de duas classes distintas (VAPNIK et al., 1996). Para classes linearmente separáveis a

superfície de melhor separação é definida pelo hiperplano $g(x) = w^T x + \omega_0$, com w^T sendo o transposto do vetor ortogonal ao hiperplano de separação e ω_0 um escalar real. Estes parâmetros são encontrados de modo a maximizar a função de Lagrange (L_p) apresentada na Equação 4.3.

$$L_p = \frac{1}{2} w^T w - \sum_{i=1}^{N_A} \alpha_i (y_i (w^T x_i + \omega_0) - 1) \quad (4.3)$$

Com N_A sendo a quantidade de padrões de treinamento, y_i sendo o rótulo da classe (-1 ou 1) e $\alpha_i = 1, \dots, N_A$ o multiplicador de Lagrange.

No entanto, essa formulação original de um classificador SVM permite apenas a separação de duas classes linearmente separáveis, o que não ocorre quando se deseja gerar mapas de cobertura da terra, por exemplo. Assim, a separação de classes não linearmente separáveis e a separação de um número superior a duas classes precisam ser tratadas.

O problema das classes não linearmente separáveis pode ser tratado através da utilização de funções Kernel, que são capazes de mapear o espaço de atributos original em um outro espaço, denominado espaço característico, onde as classes passam a ser linearmente separáveis (THEODORIDIS; KOUTROUMBAS, 2009). No entanto, nessas situações, parâmetros de penalidade para os erros de classificação são utilizados e altos valores deste parâmetro, que implicam em menores índices de erro durante o treinamento, podem ocasionar perda de generalidade do modelo (PEREIRA et al., 2011).

A separação de mais de duas classes através do classificador SVM segue os princípios apresentados para casos envolvendo apenas duas classes, no entanto, uma estratégia multiclasse baseada em um número maior de hiperplanos de separação é adotada. Uma estratégia multiclasse pode reformular o método, o que exige um maior custo computacional, ou ainda

decompor o problema original em subproblemas binários do tipo “Um-Contra-Todos” ou “Um-Contra-UM” (NEGRI, 2013).

Antes da realização das classificações a partir dos classificadores selecionados, a diferença no tamanho das amostras obtidas para o treinamento, tanto em 2009 quanto em 2013, precisou ser considerada. O uso da totalidade desses *pixels* poderia privilegiar classes com uma maior quantidade de informação em detrimento das restantes. Assim, o sorteio de um mesmo número de *pixels* de treinamento para cada uma das classes foi adotado, como realizado em Negri (2013) e Reis (2014).

Porém, o sorteio de um único conjunto de amostras poderia superestimar ou subestimar a qualidade da classificação. Por esse motivo, adotou-se a repetição da classificação de um mesmo conjunto de atributos, um número elevado de vezes, baseada em diferentes sorteios de amostras de treinamento. O resultado desse processo é uma classificação final gerada pela moda de todas as classificações realizadas, ou seja, uma classificação na qual cada *pixel* recebe o rótulo mais frequentemente a ele atribuído nas classificações realizadas. Situações de empate foram solucionadas de forma aleatória. Além de gerar uma classificação final não tendenciosa em relação às amostras, a repetição de classificações também gera um novo tipo de informação: a incerteza da classificação final, utilizada como um dos meios de validação dos resultados.

Tratadas essas questões, os classificadores SVM e Maxver, já implementados em ambiente R, foram associados a uma metodologia baseada no método de Monte Carlo. Assim, cada conjunto de atributos selecionado pode ser classificado 100 vezes, por cada um dos classificadores utilizados, baseados em 200 *pixels* de treinamento para cada classe, sorteados aleatoriamente e sem repetição a cada nova classificação. Essa quantidade de *pixels* foi escolhida por ser aproximadamente a metade da quantidade de *pixels* do

menor dentre os conjuntos de amostras de treinamento, o que maximiza o número de diferentes combinações possíveis.

Vale ressaltar que os conjuntos de amostras de treinamento para os anos de 2009 e 2013 utilizados na obtenção dessas classificações são distintos e que uma abordagem “Um-Contra-Um” foi adotada para trabalhar a separabilidade do número de classes sempre superior a duas. Também é importante salientar que o kernel *Radial Basis Function* (RBF), que possibilita a resolução de problemas não linearmente separáveis através do mapeamento para um espaço de maior dimensão, foi adotado. A utilização de uma função kernel exige a determinação de parâmetros custo e gama, associados respectivamente a penalidade do erro de classificação e ao kernel escolhido, que neste estudo foram definidos com base nos valores de *default* estabelecidos pelo *software* ENVI 4.7. Assim, esses parâmetros assumiram, para todas as classificações SVM realizadas, os valores 100 e $1/b$ respectivamente, onde b é o número de atributos envolvidos em cada classificação. Como resultado final, o processo de classificação gerou 9 modas de classificações de dados ópticos, 3 modas de classificações dos dados SAR em modo FQ06 e 3 modas de classificações dos dados SAR em modo FQ13 para cada um dos classificadores, o que totaliza 30 classificações finais acompanhadas de sua respectiva imagem de incerteza.

No entanto, após a avaliação das classificações obtidas nesta etapa do processo, 4 novos conjuntos a serem classificados foram gerados. Isso porque os conjuntos de dados SAR chamados de soluções sub-ótimas, para cada um dos modos FQ06 e FQ13, foram associados aos atributos gerados pelas decomposições polarimétricas de Freeman e Durden e Cloude e Pottier. Estas soluções sub-ótimas são aqui definidas como o conjunto que, mesmo com um menor número de canais, apresente valores de exatidão global não estatisticamente diferentes do maior valor obtido, aqui chamado de solução ótima. A seleção de conjuntos sub-ótimos se deu a partir de testes de hipótese z , a um nível de significância de 5%. Por fim, os 4 novos conjuntos de dados,

SAR em modo FQ06 associados aos atributos da decomposição polarimétrica de Cloude e Pottier, SAR em modo FQ13 associados aos atributos da decomposição polarimétrica de Cloude e Pottier, SAR em modo FQ06 associados aos atributos da decomposição polarimétrica de Freeman e Durden e SAR em modo FQ13 associados aos atributos da decomposição polarimétrica de Freeman e Durden, foram classificados através do classificador SVM. O mesmo não foi realizado através do classificador Maxver uma vez que os novos canais gerados pelas decomposições polarimétricas não seguem distribuição normal.

4.6. Avaliação das classificações

O processo de avaliação das classificações obtidas foi baseado nas amostras de validação para cada uma das 9 classes em questão, obtidas para os anos de 2009 e 2013. Por motivos já descritos na etapa de classificação (ver subseção 4.5), as amostras de validação também foram sorteadas. Buscando a independência da validação em relação aos *pixels* sorteados, o processo de validação também foi repetido 100 vezes para cada uma das classificações finais. Essa repetição resultou em índices de validações médios. Assim, a implementação em ambiente R, utilizada para avaliar as classificações obtidas, apresenta como resultados a matriz de confusão média e a exatidão global média.

Para a obtenção de cada um desses índices, 100 *pixels* foram sorteados sem repetição, para cada classe, a cada nova validação. Esse valor foi escolhido considerando a maximização das diferentes combinações possíveis, como descrito para a etapa de classificação e dessa forma a cada 2 *pixels* utilizados para o treinamento, 1 foi utilizado para validação.

Após o processo de validação, considera-se como melhor classificação aquela que possui a menor quantidade de *pixels* classificados incorretamente e consequentemente a maior exatidão global. Por essa razão, a exatidão global foi utilizada para selecionar os conjuntos a formar os dados de entrada da

próxima etapa: a detecção de mudanças. No entanto, a solução sub-ótima não apresenta diferença significativa em relação à solução ótima e a sua utilização pode ser vantajosa em relação ao custo computacional de processos que envolvam novas classificações. Assim, testes de hipótese z, unilaterais, ao nível de significância 5%, baseados nos valores de exatidão global médio de cada classificação final e no desvio padrão dessa exatidão obtido a partir das 100 repetições para a validação, foram realizados. Esses testes buscam analisar a significância da melhoria da exatidão entre cada par de classificações e é sempre composta pela melhor classificação e uma dentre as restantes.

Além dos índices já citados, também foram utilizadas, como forma de avaliar os resultados obtidos, as imagens de incerteza associada a cada uma das classificações finais. As informações de incerteza das classificações (IC) foram obtidas através da porcentagem de classificações, dentre as 100 realizadas para cada conjunto de dados, nas quais cada *pixel* recebeu o rótulo a ele atribuído na imagem moda. Assim, na imagem de incerteza, cada *pixel* recebe um valor dado por:

$$IC = 1 - \frac{\#Classe\ Maj}{\#classificações} \quad (4.4)$$

sendo *IC* o valor de incerteza associado a cada *pixel* da imagem incerteza, *#Classe Maj* a quantidade de vezes que este *pixel* foi classificado como a classe majoritária, ou seja, a classe à qual o mesmo pertence na imagem moda e *#classificações* a quantidade de classificações realizadas. Dessa forma, o valor da incerteza pertence ao intervalo $\left[0, 1 - \frac{1}{\#k}\right]$, onde *#k* é o número de classes existentes na classificação e valores nulos de incerteza indicam que o *pixel* em questão foi classificado como pertencente a mesma classe em todas as classificações enquanto valores máximos para incerteza indicam a maior confusão possível na classificação de um *pixel*, ou seja, que este *pixel* foi classificado como pertencente a cada uma das classes existentes um mesmo

número de vezes. Através da informação de incerteza busca-se retratar a sensibilidade da classificação à variação do conjunto de treinamento, a incerteza da classificação também possibilita a avaliação do quão robusto é o processo de classificação dos dados, para as classes em questão, na área de interesse e na data considerada. No entanto, é preciso ressaltar que a incerteza adotada neste estudo é uma incerteza de repetição e não uma incerteza advinda dos classificadores utilizados no estudo.

4.7. Detecção de mudança

Os valores de exatidão global das classificações individuais de cada conjunto de atributos, obtidos a partir dos dois classificadores utilizados no estudo, deram origem aos conjuntos de dados de entrada para os processos de detecção de mudanças. No entanto, os conjuntos de dados de entrada utilizados no processo de detecção de mudanças por comparação pós-classificação e por classificação direta possuem diferentes características e por essa razão são selecionados de maneiras diferentes. Classificações baseadas em dados SAR do ano de 2009 e classificações baseadas em dados ópticos do ano de 2013 são utilizadas como dados de entrada para a detecção de mudanças por comparação pós-classificação. Já na detecção de mudanças por classificação direta são utilizados como dados de entrada atributos SAR do ano de 2009 e atributos ópticos do ano de 2013. Vale ressaltar que neste estudo as informações referentes ao de 2009, podem ser referentes apenas aos dados SAR em amplitude ou ainda aos dados SAR em amplitude associados aos canais gerados pelas decomposições polarimétricas. No total 6 conjuntos foram gerados, sendo 3 para cada método de detecção de mudanças utilizado, como mostra a Tabela 4.3.

Tabela 4.3 – Formação dos conjuntos de dados SAR/óptico para detecção de mudanças.

Método	Conjuntos	Tipo de dado
Comparação pós-classificação	FQ06/ALI	Melhores Classificações iniciais
	FQ13/ALI	
	SAR+DPs/ALI	
Classificação direta	FQ06/ALI	Empilhamento dos canais SAR e óptico
	FQ13/ALI	
	SAR+DPs/ALI	

Enquanto a detecção de mudanças por comparação pós-classificação depende das classificações iniciais já obtidas, a detecção de mudanças por classificação direta depende de uma nova classificação baseada em um único vetor contendo informações das duas datas. Por serem processos distintos, os mesmos serão apresentados em duas seções específicas.

4.7.1. Detecção de mudança por comparação pós-classificação

O método baseado na comparação, *pixel a pixel*, de duas classificações existentes foi aplicado a cada conjunto de dados previamente selecionado. Para cada conjunto de dados, uma nova imagem classificada, contendo o valor dos rótulos referentes as duas classificações utilizadas, é gerada. Considerando as 9 classes de cobertura possíveis nas classificações individuais, os resultados de detecção de mudança com base nesse método podem conter um total de 81 classes de mudança/não mudança em potencial. Das quais, 9 são potenciais classes de não mudanças e 72 são potenciais classes de mudança.

No entanto, nem todas as classes de mudança e não mudança resultantes do processo de detecção de mudança por comparação pós-classificação tem ocorrência possível. Classes de mudanças resultantes em Floresta Madura (MF), por exemplo, não são, na maioria das vezes, possíveis, uma vez que áreas agrícolas, áreas de solo exposto ou áreas de pasto, por exemplo, não se regeneram a ponto de voltar a ser considerada Floresta Madura em um

intervalo de anos. Assim, uma separação entre mudanças possíveis (P), impossíveis (I), improváveis (U) e não mudança (N) se faz necessária.

Neste contexto, a qualificação da transição das classes de cobertura entre os anos de 2009 e 2013 é apresentada na Tabela 4.4. Vale ressaltar que a tabela apresentada se baseia na possibilidade de existência ou não das classes para o intervalo de 4 anos analisado neste estudo e para as classes previamente selecionadas e descritas na seção 4.2. Assim, novos estudos, envolvendo diferentes classes e diferentes intervalos de tempo devem obrigatoriamente se basear em diferentes qualificações de mudanças.

Tabela 4.4 – Transição de classes entre 2009 e 2013.

		2013								
		AG	BS	CP	DP	IS	MF	SS1	SS2	WAT
2009	AG	N	P	P	P	P	I	P	I	P
	BS	P	N	P	P	P	I	P	I	P
	CP	P	P	N	P	P	I	P	I	P
	DP	P	P	P	N	P	I	P	I	P
	IS	U	U	U	U	N	I	U	I	P
	MF	P	P	P	P	P	N	P	U	U
	SS1	P	P	P	P	P	I	N	P	U
	SS2	P	P	P	P	P	P	P	N	U
	WAT	U	U	U	U	U	I	U	U	N

Nota: AG - Agricultura; BS - Solo Exposto; CP - Pasto Limpo; DP - Pasto Sujo; IS - Superfícies Impermeáveis; MF - Floresta Madura; SS1 - Sucessão Secundária Inicial; SS2 - Sucessão Secundária Intermediária; WAT - Água; N - Não mudança; P - Mudança Possível; I - Mudança Impossível; U - Mudança Improvável.

A diferença entre a quantidade de classes de mudança em potencial e as encontradas em campo durante o período estudado geram um problema no momento de comparar os resultados obtidos pelos dois métodos de detecção de mudança utilizados. Enquanto o resultado da classificação direta possui apenas as classes obtidas em campo, o método de comparação pós-classificação terá como classes de mudanças resultantes, as diferentes combinações entre o rótulo de cada *pixel* em 2009 e 2013.

Buscando resolver esse problema, o resultado da detecção de mudanças por comparação pós-classificação é apresentado e avaliado com base no agrupamento das classes que não existem ou que não tenham sido encontradas em campo. Dessa forma, todas as transições rotuladas como impossível (I) ou improvável (U), que apareçam nos resultados da detecção de mudanças por comparação pós-classificação, são agrupadas em uma classe chamada não classificadas. Já as mudanças possíveis, mas não encontradas *in situ*, são agrupadas em uma nova classe chamada não encontradas.

4.7.2. Detecção de mudança por classificação direta

A detecção de mudanças por classificação direta depende de uma nova classificação, baseada em um único arquivo contendo todos os canais advindos de conjuntos previamente selecionados. Considerando que os classificadores utilizados nesse estudo são supervisionados, a nova classificação também depende de amostras de treinamento. Para tanto, conjuntos de amostras de mudanças e não mudanças entre os anos de 2009 e 2013 se fizeram necessários. Essas amostras foram obtidas a partir do rico conjunto de dados de treinamento e validação para os tipos de cobertura da terra mapeadas nos anos de 2009 e 2013.

Dentre as classes de não mudança, apenas a classe Sucessão Secundária Inicial para Sucessão Secundária Inicial (SS1–SS1) não foi detectada em campo. Isso é explicado pela dificuldade de áreas de sucessão secundária inicial se manterem estáveis por mais de 3 anos (Anjos et al., 2015). Nas classes de mudança, foram detectadas apenas as classes agricultura para sucessão secundária inicial (AG–SS1), solo exposto para agricultura (BS–AG), pasto limpo para pasto sujo (CP–DP), pasto limpo para sucessão secundária inicial (CP–SS1), pasto sujo para sucessão secundária inicial (DP–SS1) e sucessão secundária inicial para sucessão secundária intermediária (SS1–SS2). A Figura 4.6 apresenta a localização das amostras de treinamento e validação para mudança e não mudança entre os anos de 2009 e 2013. A

quantidade de *pixels* das amostras de treinamento e validação para as classes de mudança e não mudança é apresentada na Tabela 4.5.

Figura 4.6 – a) Localização das amostras de treinamento para mudança e não mudança entre 2009 e 2013 e b) localização das amostras de validação para mudança entre 2009 e 2013, ambas sobre a banda 3 dos dados EO-1 ALI.

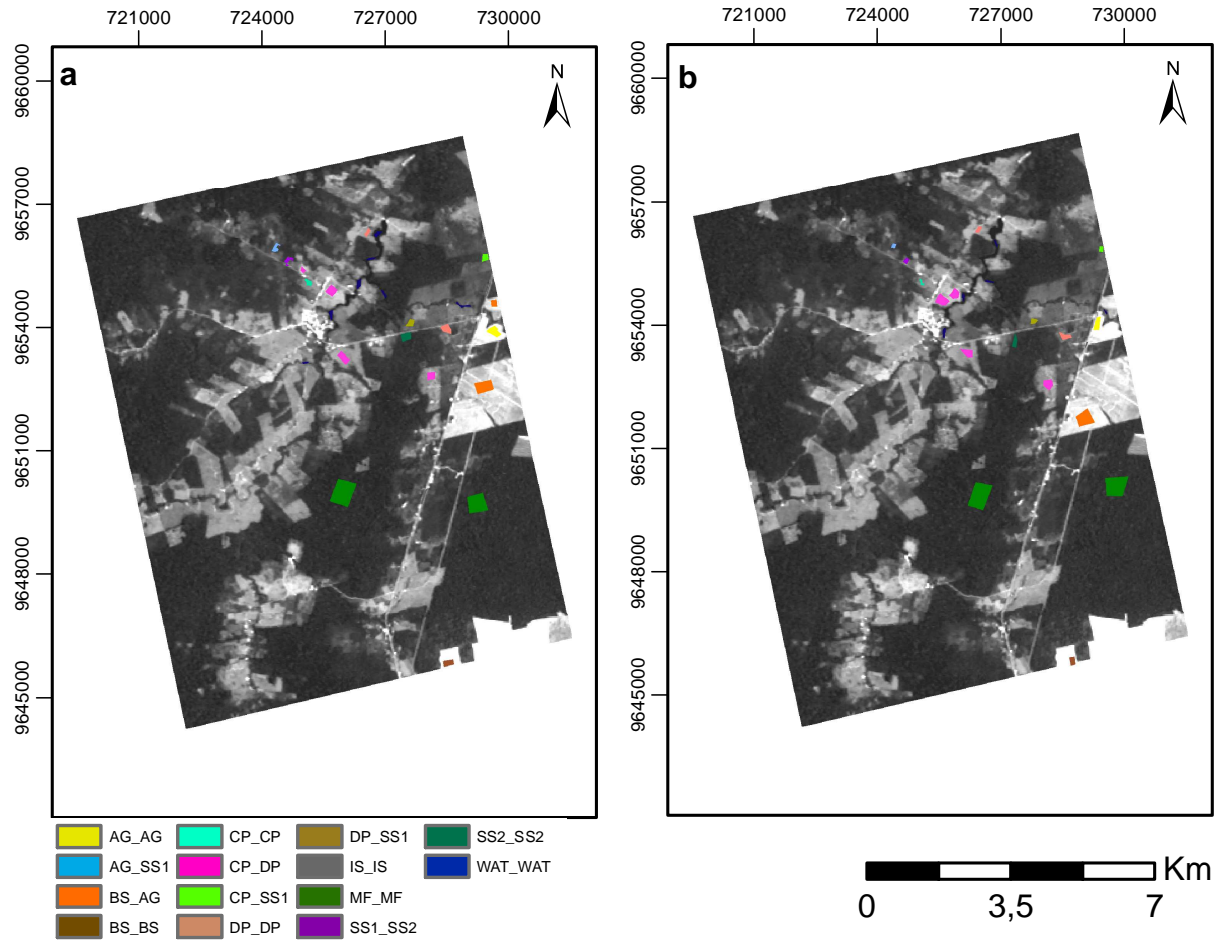


Tabela 4.5 – Quantidade de *pixels* para as amostras de mudança e não mudança entre os anos de 2009 e 2013.

Tipo	Classes	Treinamento	Validação	Tipo	Classes	Treinamento	Validação
Não mudança	AG_AG	531	379	Mudança			
	BS_BS	332	235		AG_SS1	208	99
	CP_CP	192	97		BS_AG	1290	1160
	DP_DP	558	449		CP_DP	1371	1825
	IS_IS	260	168		CP_SS1	238	117
	MF_MF	4416	4504		DP_SS1	251	164
	SS2_SS2	426	251		SS1_SS2	203	124
	WAT_WAT	893	388				

A partir da seleção dos conjuntos de dados de entrada e da elaboração dos dados de treinamento, a detecção de mudanças por classificação direta se deu com base nos métodos utilizados para as classificações individuais. Cada conjunto, contendo informações referentes aos dois anos, foi classificado 100 vezes por cada um dos classificadores adotado e para cada classificação foram realizados sorteios das amostras resultando em uma classificação final baseada na moda dessas classificações. Informações de incerteza também foram geradas para essas novas classificações. Por conter uma quantidade inferior de amostras para cada classe de mudança, a quantidade de *pixels* sorteados para cada classificação direta também foi inferior ao adotado nas classificações individuais. Novamente o critério de maximização do número de combinações distintas possíveis foi adotado, resultando em 100 *pixels* sorteados para o treinamento de cada classe de mudança ou não mudança detectadas *in situ*. Após a obtenção dos resultados de detecção de mudanças, tanto por comparação pós-classificação quanto por classificação direta, a etapa de validação destes resultados foi conduzida.

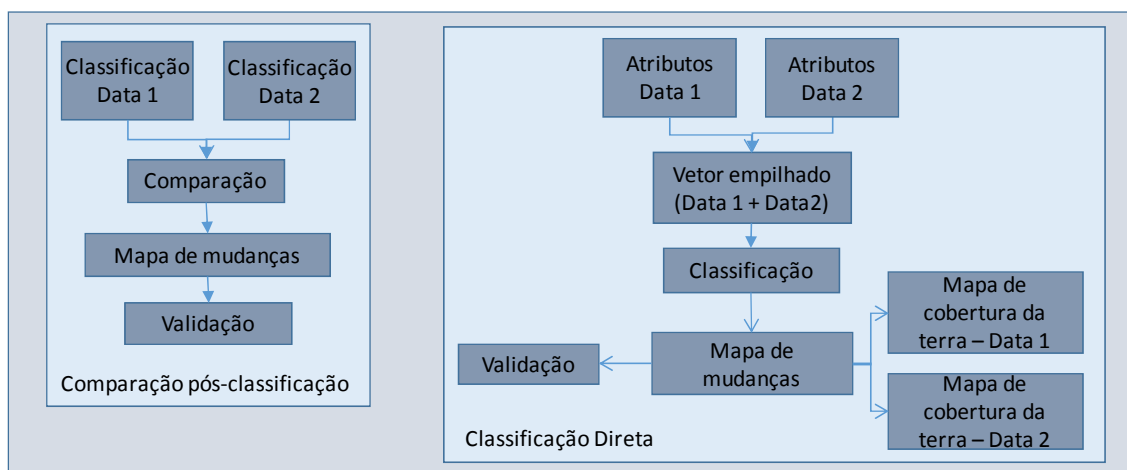
4.8. Avaliação da detecção de mudança

Após o agrupamento das classes não classificada e não observada, os resultados gerados por ambos os métodos passam a ser comparáveis e podem então ser avaliados. Esta avaliação se dá a partir da implementação em ambiente R já descrita na subseção 4.6 e utilizada para a validação das

classificações individuais. O processo de validação é realizado 100 vezes para cada mapa de mudança obtido. O sorteio de 50 *pixels* por classe, para cada uma das 100 validações, é realizado de acordo com critérios já estabelecidos, e implica na obtenção de uma matriz de confusão média e da exatidão global média.

No entanto, durante o processo de validação dos mapas de mudança, as classes de mudança detectadas em campo são consideradas como as únicas que de fato ocorreram no intervalo de interesse, o que pode não ser verdade. Falhas durante a coleta de dados e a impossibilidade de visitar toda a área de estudo podem gerar erros de omissão. Por essa razão, uma análise da consistência das classes de mudanças utilizadas no processo também é realizada. Para tanto, informações a respeito da cobertura da terra para os anos de 2009 e 2013 são extraídas do mapa de mudanças com maior exatidão global. As informações do tipo “de” “para” associadas às 14 classes de mudanças ou não mudanças contidas no mapa de mudança mais acurado dão origem a dois mapas de cobertura da terra. No mapa de cobertura da terra para o ano de 2009 cada *pixel* recebe como rótulo a classe de partida, ou seja, a classe “de”, enquanto no mapa de cobertura da terra para o ano de 2013 cada *pixel* recebe como rótulo a classe de chegada, a classe “para”. Por exemplo: um *pixel* classificado com SS1-SS2 no mapa de mudanças final será associado a classe SS1 no mapa de cobertura da terra do ano de 2009 e associado a classe SS2 no mapa de cobertura da terra do ano de 2013. Buscando facilitar o entendimento do procedimento adotado o encadeamento das etapas de classificação e validação para os métodos de detecção de mudanças por comparação pós-classificação e por classificação direta são apresentados na Figura 4.7.

Figura 4.7 – a) Encadeamento das etapas realizadas para classificação e avaliação dos mapas de mudança obtidos pelos métodos comparação pós-classificação e classificação direta.



A partir da elaboração dos dois mapas de cobertura da terra, uma avaliação dos resultados baseada nas amostras de validação disponíveis tanto para 2009 quanto para 2013 é realizada. Bons resultados de valores de exatidão global, acompanhados de análises classe a classe da matriz de confusão podem comprovar a qualidade desses mapas de cobertura. A avaliação também comprova que as classes utilizadas no processo de detecção de mudanças são representativas, validando assim o resultado do mapa de mudança.

Após a validação dos resultados obtidos, os índices de validação dos mapas de mudança são então utilizados para selecionar qual dentre os conjuntos de atributos apresenta o melhor resultado para a detecção de mudanças para cada um dos métodos adotados. Finalmente, os mapas de mudanças mais acurados são apresentados, destacando apenas as classes de mudança, objetivo do estudo, o que possibilita a comparação entre os resultados obtidos pelos dois métodos de detecção de mudanças adotados.

Além dos índices de validação, a incerteza da classificação (*IC*), já apresentada como forma auxiliar de avaliação das classificações individuais, também é associada a cada um dos mapas de mudanças obtidos. Para os mapas de

mudança obtidos por classificação direta a incerteza da classificação (IC) é obtida como já descrito para as classificações individuais (ver subseção 4.6). No entanto, vale ressaltar que os mapas de mudança obtidos por comparação pós-classificação não necessitam de novas classificações. Por essa razão, a informação de incerteza para esses mapas de mudança é, na verdade, uma incerteza estimada com base na metodologia de análise de acumulação de erros (Richards e Jia, 2006). Assim, ao supor que os erros são independentes, e sabidamente não mutuamente exclusivos, a incerteza do cruzamento de duas classificações, aqui chamada de Incerteza Acumulada (ICA), para cada *pixel* é dada por:

$$ICA = 1 - [(1 - IC_1) * (1 - IC_2)] = IC_1 + IC_2 - (IC_1 * IC_2) \quad (4.5)$$

sendo IC_1 o valor de incerteza do *pixel* na classificação de 2009 e IC_2 o valor de incerteza do *pixel* na classificação de 2013.

5 RESULTADOS E DISCUSSÕES

Os resultados obtidos pela metodologia proposta são apresentados em seções distintas relacionadas a cada uma das etapas do processo. Primeiramente são apresentados os resultados referentes à seleção dos atributos, posteriormente são apresentados os resultados das classificações e suas validações e, finalmente, os resultados da detecção de mudanças e suas validações.

5.1. Seleção de atributos

Após as etapas de pré-processamento, realizadas separadamente para os dados ópticos e SAR, os mesmos foram submetidos à seleção de atributos. Como resultado desse processo, dois grupos, SAR e óptico, contendo os conjuntos de dados a serem classificados foram gerados.

Para os dados ópticos, contendo as 9 bandas da imagem EO-1 ALI, a seleção de atributos por máxima mínima distância JM resultou em 9 diferentes conjuntos de atributos, compostos por uma banda, duas bandas, e assim por diante até a utilização de todas as bandas disponíveis. A composição de cada um desses conjuntos, a mínima distância JM obtida para os pares de classes e a média da distância JM entre todos os pares de classes em cada conjunto é apresentada na Tabela 5.1.

Tabela 5.1 – Conjuntos de atributos ópticos selecionados para as classificações.

Quantidade de bandas	Canais	Mínima distância JM	Distância JM media
1	MS3	0,494	1,168
2	MS3, MS5	1,074	1,331
3	MS2, MS3, MS5	1,235	1,381
4	MS2, MS4', MS5', MS7	1,299	1,404
5	MS2, MS3, MS4', MS5, MS7	1,325	1,407
6	MS1, MS2, MS3, MS4', MS5, MS7	1,334	1,410
7	MS1, MS2, MS3, MS4', MS5', MS5, MS7	1,340	1,411
8	MS1', MS1, MS2, MS3, MS4, MS5', MS5, MS7	1,345	1,412
9	MS1', MS1, MS2, MS3, MS4, MS4', MS5', MS5, MS7	1,349	1,412

Para os dados SAR, contendo os canais HH, HV, VH e VV em cada um dos modos utilizados, o processo de seleção de atributos dependeu de um número maior de etapas. Primeiramente um teste de reciprocidade dos alvos nos canais HV e VH foi realizado tanto para o modo FQ06 quanto para o modo FQ13. Um sorteio aleatório de 100 *pixels* dentre os conjuntos de amostras das 9 classes existentes, totalizando 900 *pixels* para cada um dos modos foi conduzido. Os valores de média e desvio padrão da diferença entre os canais HV e VH nesses 900 *pixels* foram utilizados em um teste de hipótese t pareado a nível de significância 5% (nível de confiança de 95%). Os resultados do teste comprovaram não existir motivos para acreditar que os canais sejam estatisticamente diferentes em ambos os modos. Um resumo do teste de hipótese t pareado para os canais HV e VH nos modos FQ06 e FQ13, contendo hipótese nula (H_0), hipótese alternativa (H_1), média da diferença absoluta (μ), desvio padrão da média (σ), nível de significância (α), valor t calculado (t_{calc}), valor t crítico (t_{crit}) e resultado do teste é apresentado na Tabela 5.2.

Tabela 5.2 – Teste de hipótese t pareado para a reciprocidade dos alvos nos canais HV e VH.

Modo	H_0	H_1	μ	σ	t_{calc}	$t_{critico}$	Resultado
FQ06	HV=VH	HV≠VH	0,011	0,011	0,030	[-1,96;1,96]	Aceito H_0
FQ13	HV=VH	HV≠VH	0,005	0,005	0,012	[-1,96;1,96]	Aceito H_0

A partir da comprovação da reciprocidade dos alvos nos canais HV e VH, a média $(HV+VH)/2$, passou a ser utilizada, juntamente com os canais HH e VV. Para esse novo conjunto, um teste de aderência a uma distribuição normal foi realizado. Isso porque o processo de filtragem aplicado aos dados amplitude, normalmente modelados pela distribuição raiz da gama em regiões homogêneas, tende a alterar a distribuição desses dados. Essa alteração causada aos dados originais pelos processamentos realizados pode ser percebida pela diferença entre o número de *look* dos dados, que originalmente era de um *look* e que nessa etapa foi estimado em aproximadamente 5 *looks*. O teste de aderência Shapiro Wilk foi realizado em ambiente R. Os p-valores

encontrados para cada classe, em cada canal, nos dois modos, implicam a aceitação da aderência dos dados processados a uma distribuição normal.

A partir da aderência dos dados a uma distribuição normal, a seleção de atributos por máxima mínima distância JM, definida como a utilizada para os dados ópticos já descrita na equação 4.1, foi utilizada. Os resultados deste processo são apresentados na Tabela 5.3.

Tabela 5.3 – Conjuntos de atributos SAR selecionados para as classificações.

Modo	Quantidade de canais	Canais	Distância JM mínima	Distância JM média
FQ06	1	(HV+VH)/2	0,141	0,595
	2	(HV+VH)/2, VV	0,141	0,673
	3	HH, (HV+VH)/2, VV	0,141	0,716
FQ13	1	(HV+VH)/2	0,000	0,556
	2	(HV+VH)/2, VV	0,141	0,645
	3	HH, (HV+VH)/2, VV	0,141	0,679

Vale ressaltar que em situações de empate entre dois conjuntos ou de ocorrência de distância nula entre duas classes para todos os conjuntos testados a média das distâncias foi adotada como critério de seleção. Isso ocorreu em todos os conjuntos de dados SAR devido à impossibilidade destes dados de separar as 9 classes envolvidas no estudo, mesmo com a inserção de novos canais nos dois modos. Essa impossibilidade de separar as classes envolvidas no estudo pode ser percebida tanto através dos baixos valores de distância JM mínima quanto dos valores de distância JM média que não passam de 0,716 em um intervalo que pode variar de 0 a 1,414. A partir desses resultados, os conjuntos selecionados foram classificados.

5.2. Classificações

A aplicação dos classificadores SVM e Maxver aos dados selecionados resultou em 34 classificações finais, sendo 18 para os dados ópticos, e 16 para os dados SAR. Das 18 classificações finais para os dados ópticos, 9 foram obtidas a partir do classificador Maxver e 9 a partir do classificador SVM. Já as

16 classificações finais para dados SAR referem-se tanto às classificações do modo FQ06 quanto FQ13, e são compostas por 3 classificações Maxver para dados SAR em amplitude, 3 classificações SVM para dados SAR em amplitude e 2 classificações SVM para dados SAR em amplitude associados aos dados das decomposições polarimétricas (Freeman e Durden e Cloude e Pottier) para cada um dos modos.

Cada classificação final é gerada pela moda de 100 classificações distintas, o que agrega informação de incerteza a esses resultados. O processo de validação de cada uma dessas classificações finais, também realizado 100 vezes, resulta em índices de Exatidão Global e em matrizes de confusão médias para cada uma das classificações. Por possuírem sempre o mesmo número de classes (9 classes de cobertura e 14 classes de mudança e não mudança), os resultados comparados neste estudo puderam ser apresentados e discutidos com base na exatidão global e nas matrizes de confusão de cada classificação, que são de fácil entendimento e interpretação.

Primeiramente, uma comparação entre os valores de exatidão global de cada uma das classificações finais foi utilizada na seleção dos melhores conjuntos de atributos classificados. Como a validação das classificações foi realizada repetidas vezes, os valores de exatidão global obtidos referem-se a uma exatidão global média e são acompanhados de um intervalo de credibilidade de 95%. Este intervalo corresponde ao valor mínimo e máximo observado para o índice após um descarte dos 2,5% maiores e menores valores. A exatidão global das classificações dos dados SAR em amplitude, dos dados SAR em amplitude associados aos dados das decomposições polarimétricas e dos dados ópticos são apresentadas nas Figuras 5.1, 5.2 e 5.3 respectivamente.

Figura 5.1 – Valores de exatidão global mínima, média e máxima das classificações de cobertura da terra a partir de dados SAR para o ano de 2009.




Figura 5.2 – Valores de exatidão global mínima, média e máxima das classificações de cobertura da terra a partir de dados SAR associados a decomposições polarimétricas para o ano de 2009.


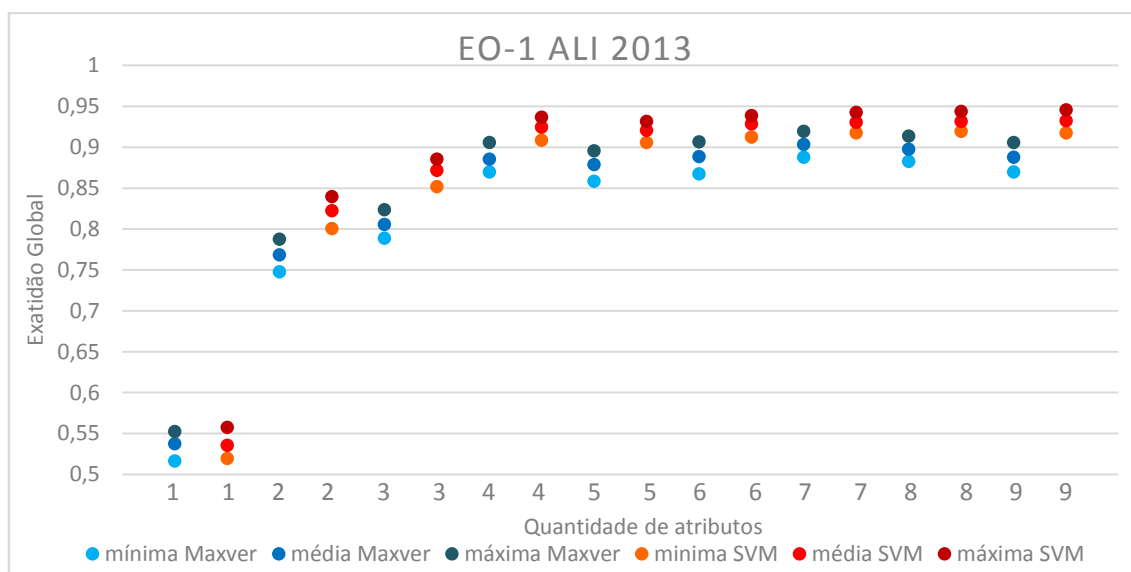


Figura 5.3 – Valores de exatidão global mínima, média e máxima das classificações de cobertura da terra a partir de dados ópticos para o ano de 2013.



Algumas questões relacionadas aos valores de exatidão global apresentados merecem destaque. A primeira delas é a classificação SVM dos dados SAR em modo FQ13 com apenas um atributo, que resulta em um valor de exatidão global visivelmente abaixo dos valores obtidos para o modo FQ06 ou até mesmo para o modo FQ13 com um maior número de atributos. Acredita-se que essa discrepância tenha ocorrido devido ao mal ajuste dos parâmetros custo e gama, necessários para o classificador SVM com função *kernel* RBF, a esse conjunto de dados, uma vez que os mesmos foram definidos da mesma forma para todas as classificações realizadas neste estudo. A pequena melhora obtida pela classificação SVM dos dados SAR em modo FQ06 associados aos atributos da decomposição polarimétrica de Freeman e Durden em comparação à classificação dos dados SAR em mesmo modo, porém classificados sem os atributos da decomposição polarimétrica também merece destaque. Por fim é preciso salientar que para os dados ópticos o classificador SVM se mostrou superior ao classificador Maxver para todos os conjuntos de atributos classificados.

Após as análises pontuais, esses valores de exatidão global para cada classificação individual foram utilizados no processo de seleção dos dados de entrada para os processos de detecção de mudança. No entanto, as diferenças entre as características dos métodos de detecção de mudanças por comparação pós-classificação e por classificação direta implicam na seleção de diferentes conjuntos de atributos. Como na comparação pós-classificação comparam-se classificações já obtidas, não havendo necessidade de mais processamentos, os dados selecionados para esse processo foram aqueles que obtiveram a maior exatidão global, o que chamamos de solução ótima. Já para a classificação direta, que depende de uma nova classificação, as soluções sub-ótimas foram adotadas. De acordo com os valores de exatidão global média já apresentados e com as definições acima descritas os conjuntos selecionados para cada método de detecção de mudanças, para cada tipo de dado e cada classificador são apresentados na Tabela 5.4. Vale ressaltar que para os dados SAR associados a decomposições polarimétricas uma solução sub-ótima não foi obtida, ou seja, nenhum conjunto contendo um número inferior de canais apresentou exatidão global estatisticamente igual ao maior valor de exatidão global obtido. Assim, o mesmo conjunto de atributos SAR associado a decomposição polarimétrica foi utilizado tanto na comparação pós-classificação (CPC) quanto na classificação direta (CD).

Tabela 5.4 – Atributos ou conjunto de atributos selecionados para detecção de mudanças.

Método	Imagem	Classificador	Canais	Nº de canais	Exatidão Global	Desvio Padrão
CPC	FQ06	Maxver	HH, (HV+VH)/2, VV	3	0,296	0,012
CPC	FQ06	SVM	HH, (HV+VH)/2, VV	3	0,293	0,012
CPC	FQ13	Maxver	HH, (HV+VH)/2, VV	3	0,272	0,011
CPC	FQ13	SVM	HH, (HV+VH)/2, VV	3	0,29	0,012
CPC	FQ06/FD	SVM	(HV+VH)/2, VV, P _V , P _D e P _S	5	0,325	0,013
CPC	EO-1 ALI	Maxver	MS1, MS2, MS3, MS4', MS5', MS5, MS7	7	0,904	0,008
CPC	EO-1 ALI	SVM	MS1', MS1, MS2, MS3, MS4, MS4', MS5', MS5, MS7	9	0,933	0,007
CD	FQ06	Maxver	(HV+VH)/2	1	0,282	0,012
CD	FQ06	SVM	(HV+VH)/2, VV	2	0,277	0,012
CD	FQ13	Maxver	(HV+VH)/2	1	0,266	0,012
CD	FQ13	SVM	(HV+VH)/2, VV	2	0,278	0,012
CD	FQ06/FD	SVM	(HV+VH)/2, VV, P _V , P _D e P _S	5	0,325	0,013
CD	EO-1 ALI	Maxver	MS2, MS4', MS5', MS7	4	0,886	0,009
CD	EO-1 ALI	SVM	MS2, MS4', MS5', MS7	4	0,925	0,007

Apesar de não serem o foco do estudo, os mapas de cobertura da terra para os anos de 2009 e 2013 que apresentaram a maior exatidão global para cada tipo de dado e para cada classificador são apresentados. Isso porque a forte dependência das classificações iniciais nos resultados da detecção de mudança por comparação pós-classificação obriga uma análise mais detalhada dessas classificações. Com esse intuito, os mapas de incerteza e as matrizes de confusão associadas a cada classificação da cobertura da terra utilizada na detecção de mudanças por pós-classificação também são apresentados. Esses resultados buscam fornecer informação a respeito dos erros associados a cada mapa de cobertura da terra, das confusões entre classes, e da incerteza na classificação de cada *pixel*. Essa análise ajudará a explicar os resultados obtidos pela utilização destes conjuntos na detecção de mudanças por comparação pós-classificação.

Como forma de facilitar a interpretação dos resultados obtidos, as matrizes de confusão deste estudo são apresentadas através de figuras nas quais um círculo de área diretamente proporcional ao valor da exatidão ou da confusão, dado em porcentagem, é gerada para cada célula. Buscando não poluir o resultado apresentado com informação pouco significativa essas circunferências foram geradas apenas para valores de exatidão superior a 5,0%. Ainda como forma de auxiliar a interpretação, a mesma legenda (cor/classe) associada aos mapas de cobertura ou mudança da terra são associadas aos dados de referência das matrizes de confusão.

A melhor classificação SAR em modo FQ06, gerada pelo classificador Maxver, juntamente com a incerteza associada a essa classificação é apresentada na Figura 5.4. A matriz de confusão referente a esta classificação é apresentada na Figura 5.5. A melhor classificação SAR em modo FQ06, gerada pelo classificador SVM, juntamente com a incerteza associada a essa classificação é apresentada na Figura 5.6, enquanto sua matriz de confusão é apresentada na Figura 5.7. As melhores classificações dos dados SAR em modo FQ13, a partir dos classificadores Maxver e SVM, com as incertezas associadas a cada uma dessas classificações e suas respectivas matrizes de confusão são apresentadas nas Figuras 5.8, 5.9, 5.10 e 5.11. Na Figura 5.12 são apresentadas a melhor classificação baseada em dados SAR associados à decomposição polarimétrica e suas incertezas. Esse resultado foi obtido pela classificação SVM dos atributos SAR em amplitude, média e VV, em modo FQ06 associados aos canais P_V , P_D e P_S gerados pela decomposição polarimétrica de Freeman e Durden. A matriz de confusão associada a esta classificação é apresentada na Figura 5.13. As melhores classificações dos dados EO-1 ALI geradas pelos classificadores Maxver e SVM e suas incertezas são apresentadas nas Figuras 5.14 e 5.16 e suas matrizes de confusão são apresentadas nas Figuras 5.15 e 5.17. Os valores de exatidão global (Eg) e desvio padrão (σ) obtidos para cada uma das melhores classificações são apresentados junto as mesmas. Os mapas de incerteza associados a todos os

mapas de cobertura da terra são apresentados de acordo com a mesma legenda. Nestes mapas de incerteza a cor verde representa a inexistência de incerteza ($IC = 0$), a cor vermelha representa a maior incerteza possível para o conjunto de classes do estudo ($IC = 0,88$) e os valores intermediários são representados pela escala de cor entre verde e vermelho como mostram as figuras. As classificações da cobertura da terra dos conjuntos utilizados na detecção de mudança por classificação direta, não são apresentadas.

Figura 5.4 – a) Melhor classificação SAR em modo FQ06 a partir do classificador Maxver e b) mapa de incerteza da classificação ($E_g = 0,296$; $\sigma = 0,012$).

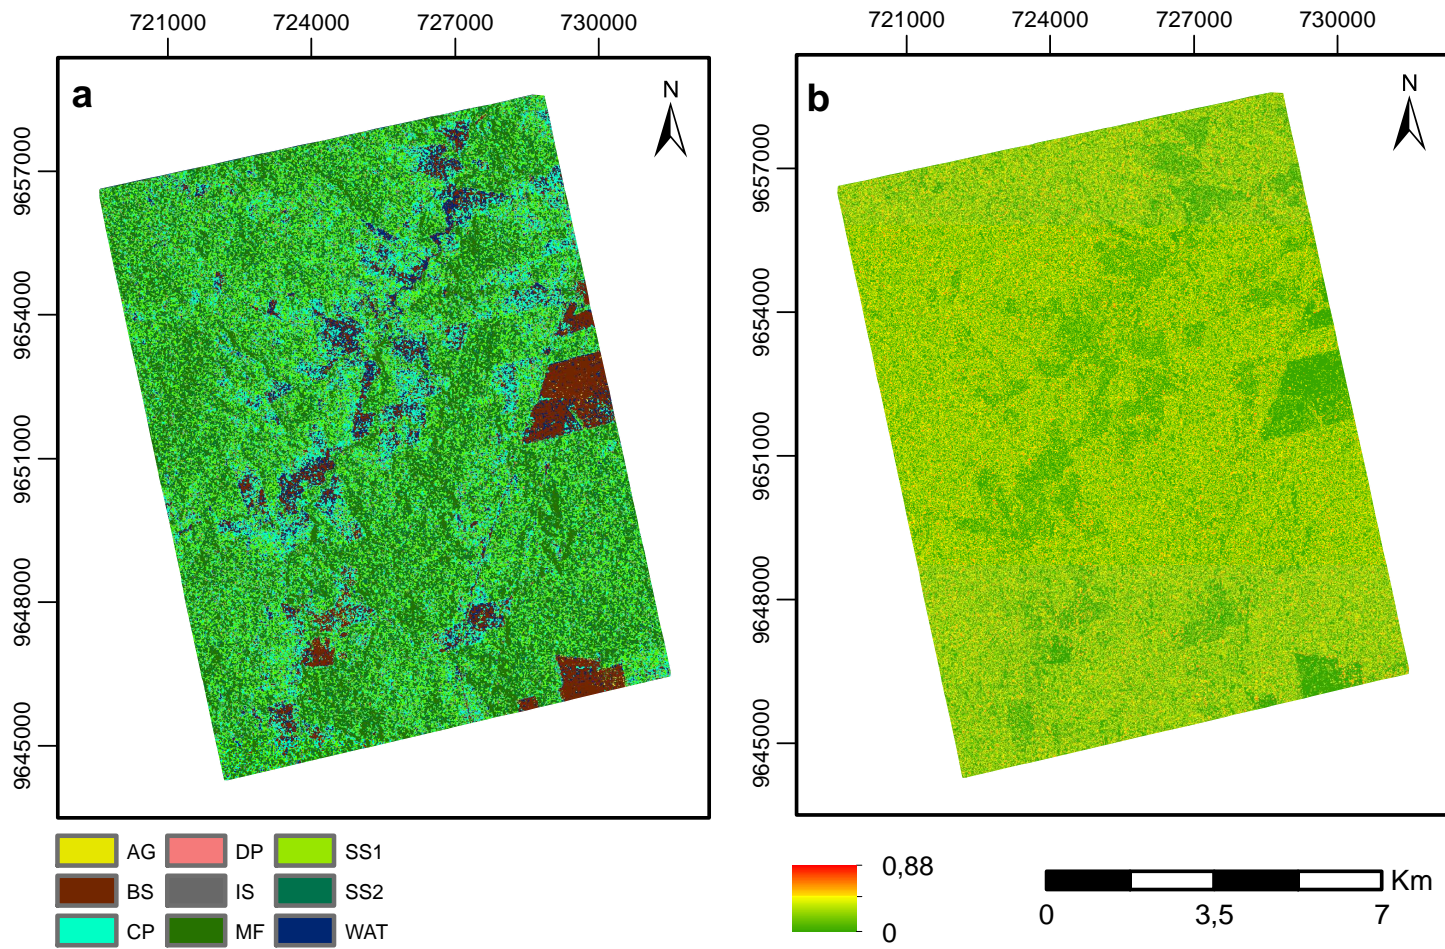


Figura 5.5 – Matriz de confusão da melhor classificação SAR em modo FQ06 a partir do classificador Maxver ($E_g = 0,296$; $\sigma = 0,012$).

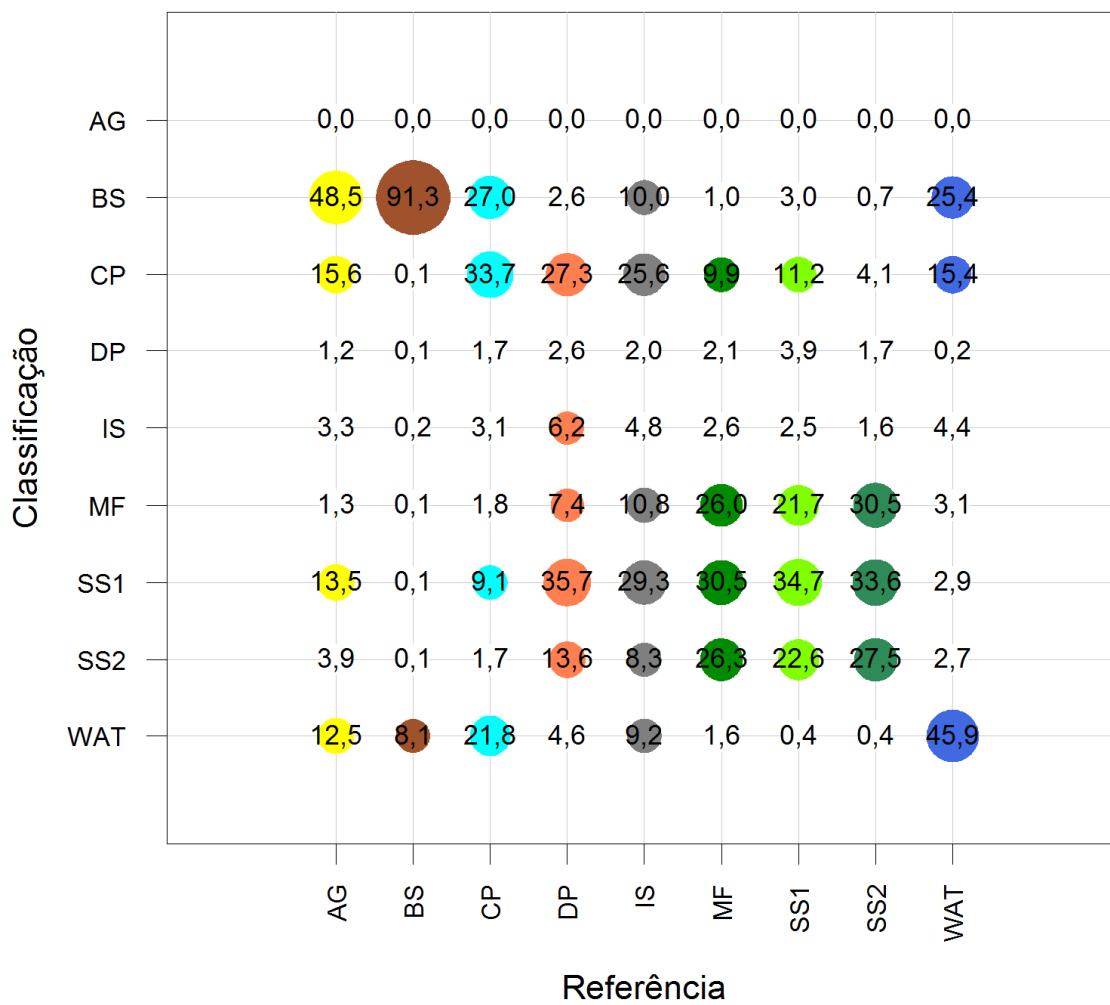


Figura 5.6 – a) Melhor classificação SAR em modo FQ06 a partir do classificador SVM e b) mapa de incerteza da classificação ($E_g = 0,293$; $\sigma = 0,012$).

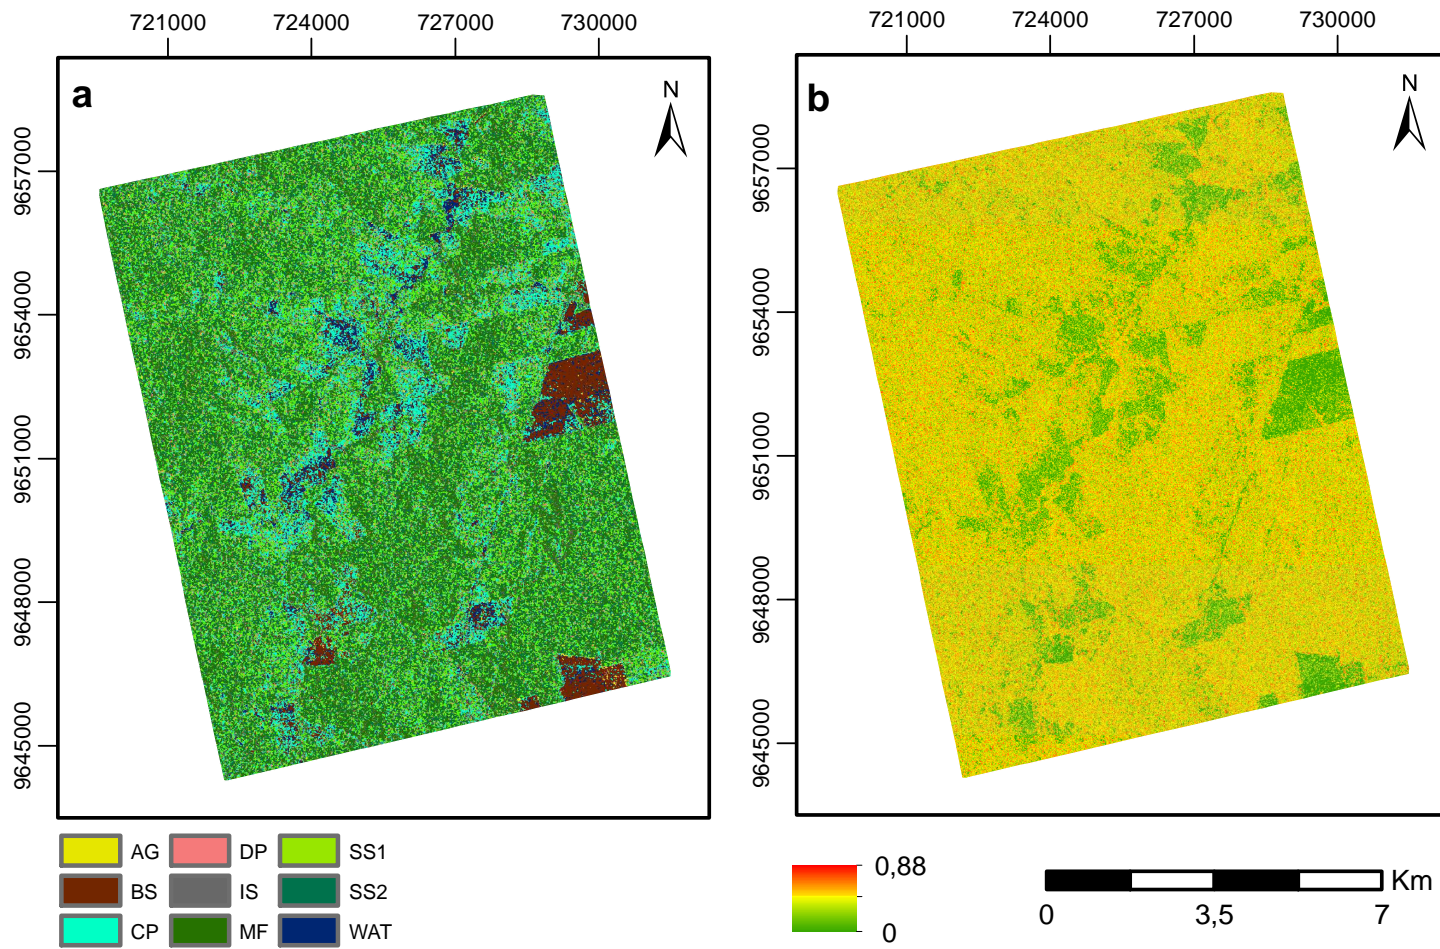



Figura 5.7 – Matriz de confusão da melhor classificação SAR em modo FQ06 obtida pelo classificador SVM ($E_g = 0,293$; $\sigma = 0,012$).



Os resultados apresentados mostram que independente do classificador utilizado, as classificações *pixel a pixel* dos dados SAR são extremamente pobres para o modo FQ06. Os melhores valores de exatidão global para a classificação desses dados foram de 0,296 para o classificador Maxver e 0,293 para o classificador SVM. Os resultados obtidos para as classificações SAR em modo FQ13, apresentados a seguir, não diferem quanto à exatidão global dos resultados obtidos para os dados em modo FQ06. Os melhores valores de acurácia para a classificação dos dados em modo FQ13 foram de 0,272 para o classificador Maxver e 0,290 para o classificador SVM.

Figura 5.8 – a) Melhor classificação SAR em modo FQ13 a partir do classificador Maxver e b) mapa de incerteza da classificação ($E_g = 0,272$; $\sigma = 0,011$).

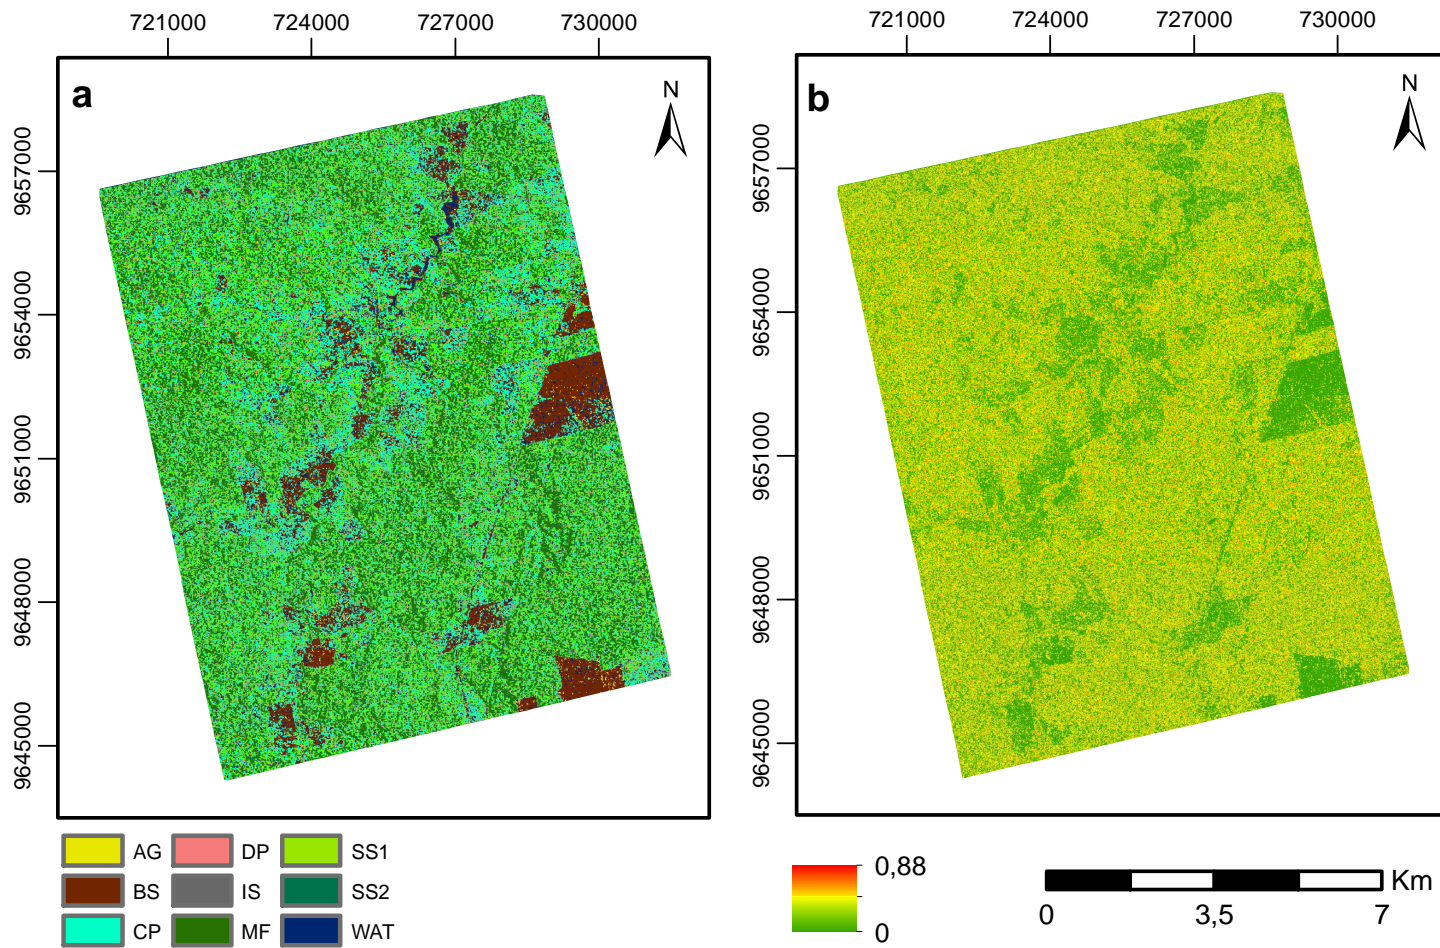


Figura 5.9 – Matriz de confusão da melhor classificação SAR em modo FQ13 a partir do classificador Maxver ($E_g = 0,272$; $\sigma = 0,011$).

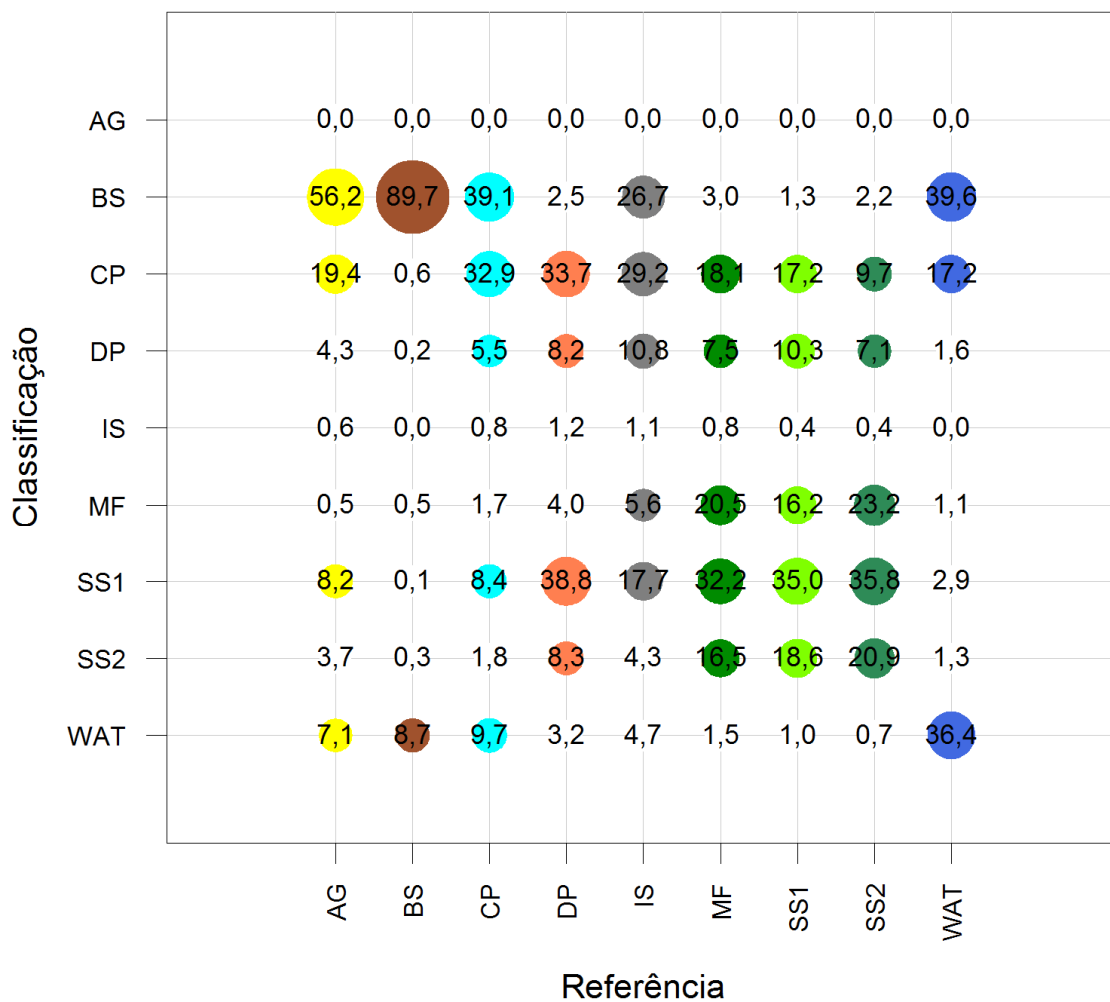


Figura 5.10 – a) Melhor classificação SAR em modo FQ13 a partir do classificador SVM e b) mapa de incerteza da classificação ($E_g = 0,290$; $\sigma = 0,012$).

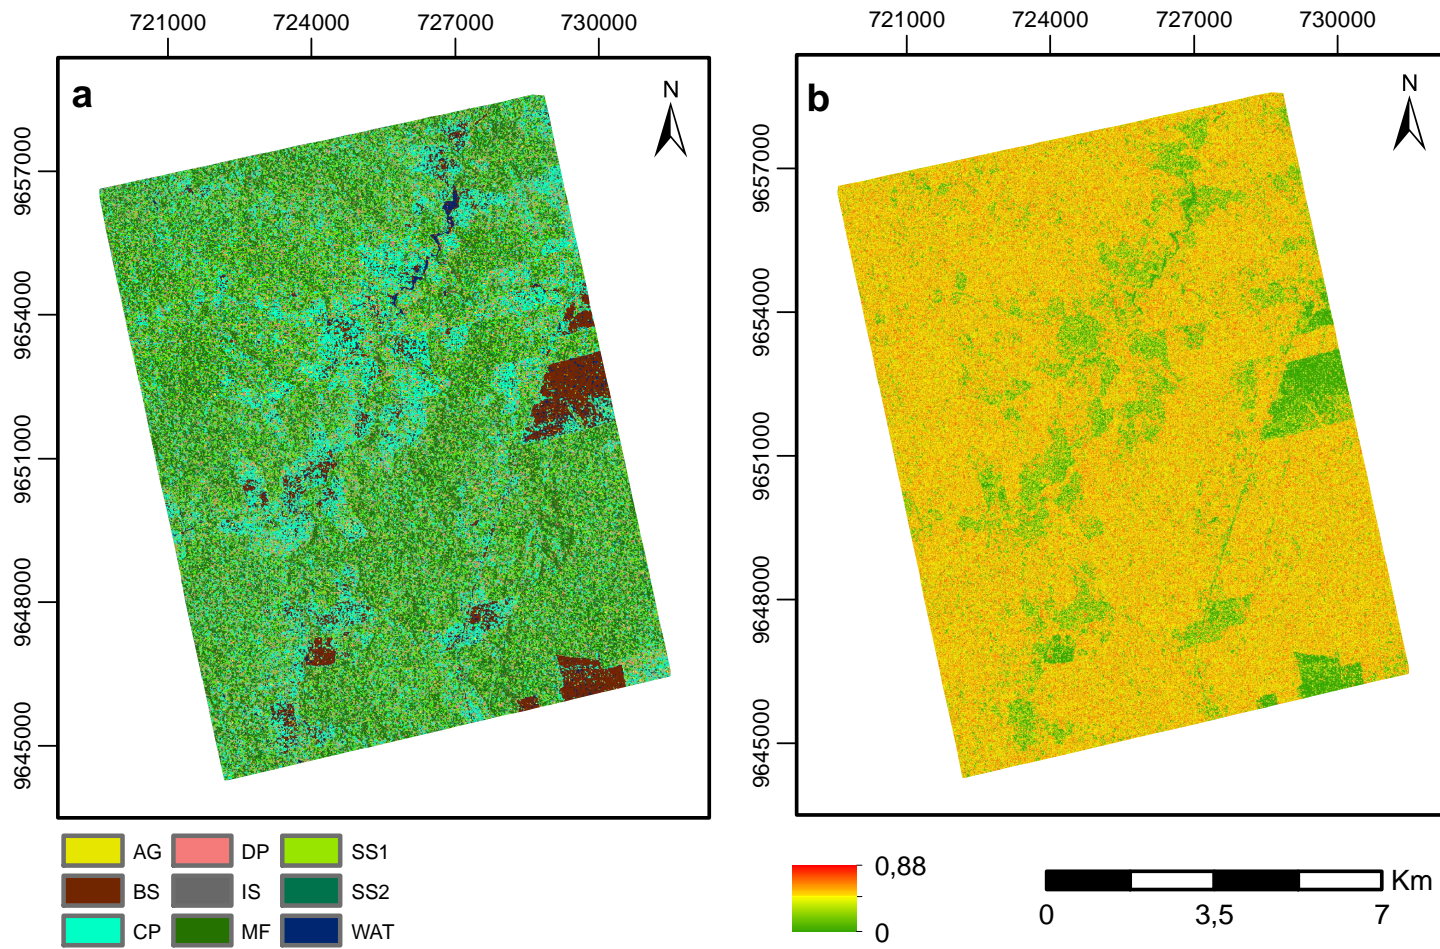



Figura 5.11 – Matriz de confusão da melhor classificação SAR em modo FQ13 a partir do classificador SVM ($E_g = 0,290$; $\sigma = 0,012$).



A partir dos resultados apresentados é possível perceber que a utilização de dados Radarsat-2 nos modos FQ06 e FQ13 isoladamente não se mostrou capaz de separar as 9 classes envolvidas no estudo independentemente do classificador utilizado. Uma análise classe a classe, no entanto, mostra a capacidade destes dados em separar quase que totalmente a classe Solo Exposto (BS). A exatidão para essa classe chega a alcançar 91,3% na classificação Maxver em modo FQ06. Para esse mesmo modo e mesmo classificador a classe Água (WAT) chega a alcançar 46% de acerto. Outra classe que merece destaque é a classe Pasto Limpo (CP) que alcança 49% de acerto para a classificação SVM dos dados SAR em modo FQ13.

Sob o ponto de vista dos diferentes ângulos de visada dos modos FQ06 e FQ13 é possível afirmar que os dados em modo FQ13 geraram classificações inferiores aos dados em modo FQ06, sendo essa inferioridade mais significativa nas classificações Maxver. No entanto, essa diferença não expressou diferenças significativas na separabilidade das classes envolvidas no estudo.

Em relação aos classificadores utilizados, os valores de exatidão global e os mapas de cobertura da terra obtidos mostram a mesma dificuldade em separar as classes envolvidas no estudo tanto para o SVM quanto para o Maxver. Porém, é preciso destacar a existência de um comportamento distinto dos classificadores Maxver e SVM em relação à incerteza de suas classificações. Devido a relação espacial existente entre os mapas de cobertura da terra e os mapas de incerteza associados a cada mapa de cobertura é possível perceber que áreas classificadas com maior exatidão como Solo Exposto, Pasto Limpo e Água aparecem mais verdes nos mapas de incerteza, ou seja, apresentam uma baixa incerteza nos mapas gerados por ambos os classificadores. No entanto as regiões de maior confusão, que ocorrem para as classes Floresta Madura, Sucessão Secundária Inicial e Sucessão Secundária Intermediária, uma vez que as classes Agricultura, Pasto Sujo e Superfícies Impermeáveis praticamente não são detectadas, se comportam de forma diferente, em relação à incerteza, nos diferentes classificadores. Para os mapas de cobertura da terra gerados pelo classificador Maxver é possível perceber que essas regiões de menor exatidão apresentam uma incerteza mais baixa do que as das áreas com maior exatidão mais ainda assim apresentam uma incerteza intermediária, aparecendo com cores entre verde claro e amarelo no mapa de incerteza. O mesmo não ocorre para os mapas gerados pelo classificador SVM, para os quais as incertezas dessas regiões são maiores, aparecendo com cores entre amarelo e vermelho, o que indica o aumento da incerteza e possivelmente a diminuição da exatidão das mudanças obtidas por comparação pós-classificação para essas regiões ao serem utilizadas classificações SVM de dados SAR para o ano de 2009.

Figura 5.12 – a) Mapa contendo a melhor classificação SAR com decomposição polarimétrica obtida (classificador SVM, modo FQ06, canais (HV+VH)/2, VV, P_V, P_D e P_s) e b) mapa de incerteza da classificação ($E_g = 0,325$; $\sigma = 0,013$).

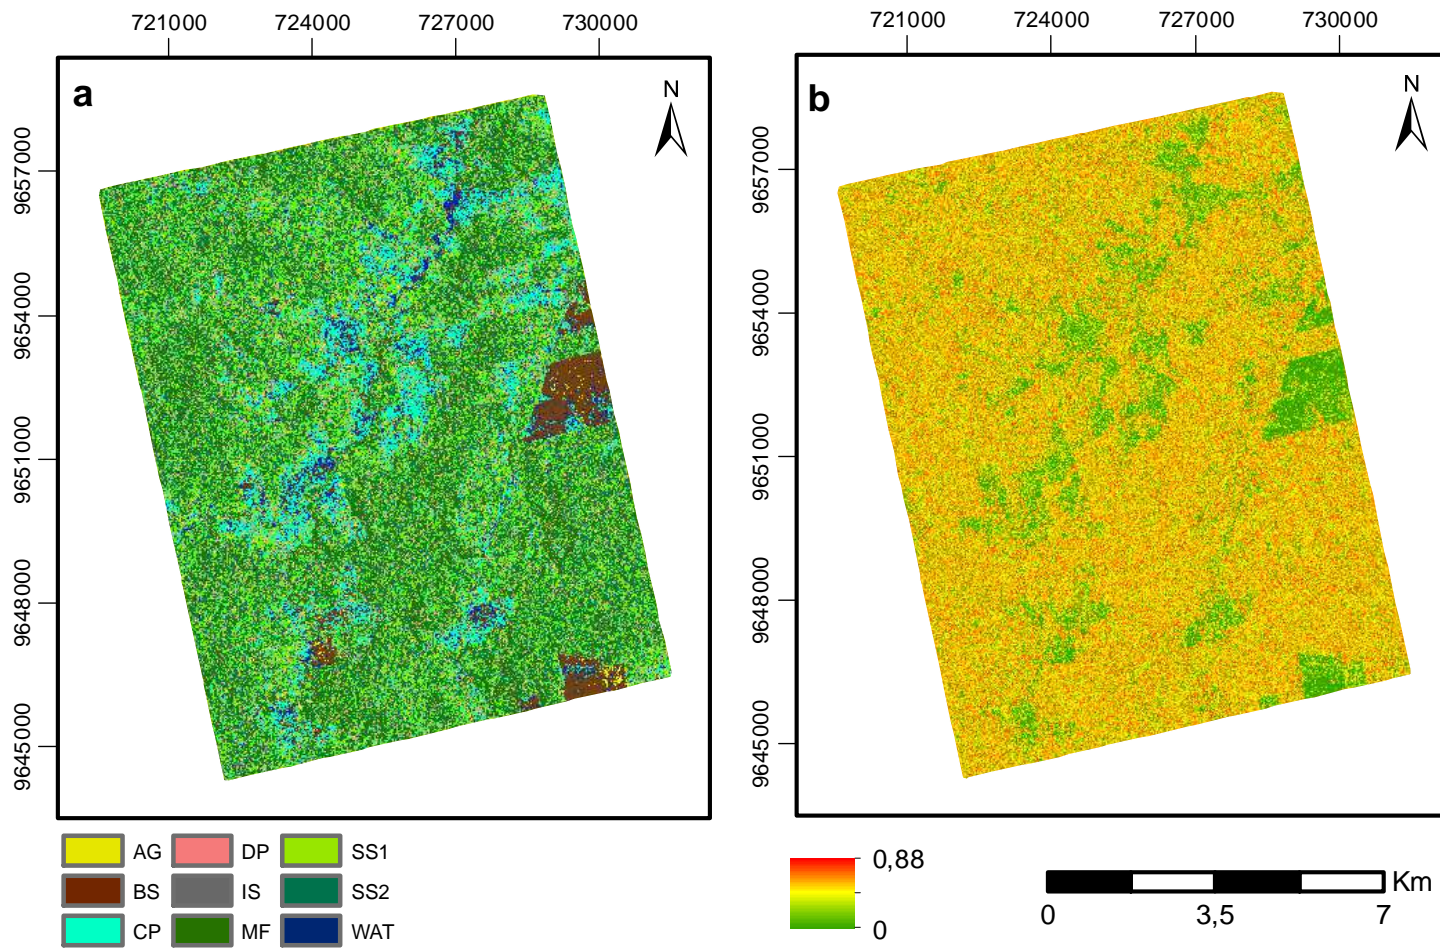
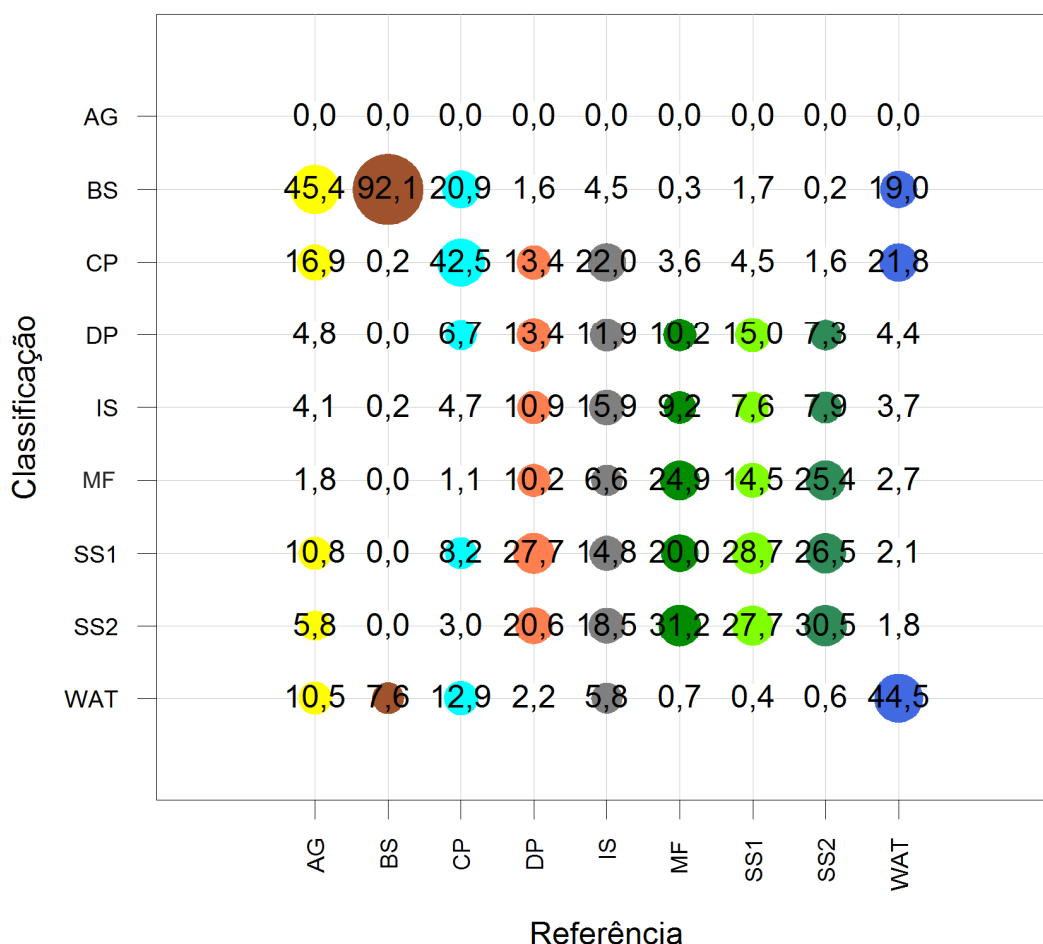


Figura 5.13 – Matriz de confusão da melhor classificação SAR com decomposição polarimétrica obtida (classificador SVM, modo FQ06, canais (HV+VH)/2, VV, P_V, P_D e P_S) ($Eg = 0,325$; $\sigma = 0,013$).



Apesar de superior aos resultados obtidos pelas classificações contendo apenas os dados SAR em amplitude, a utilização da decomposição polarimétrica também não se mostrou capaz de separar as 9 classes envolvidas no estudo. Análises classe a classe e de incerteza também mostram um comportamento muito próximo das classificações SVM de dados SAR sem atributos de decomposição polarimétrica. As classes Solo Exposto (BS) com 91% de exatidão, Água (WAT) com 44,5% de acerto e Pasto Limpo (CP) que alcança 42,5% de acerto também são as que mais se destacam na classificação SVM dos dados SAR em modo FQ06 associados aos atributos da decomposição polarimétrica de Freeman e Durden.

Figura 5.14 – a) Melhor classificação EO-1 ALI a partir do classificador Maxver e b) mapa de incerteza da classificação ($E_g = 0,904$; $\sigma = 0,008$).

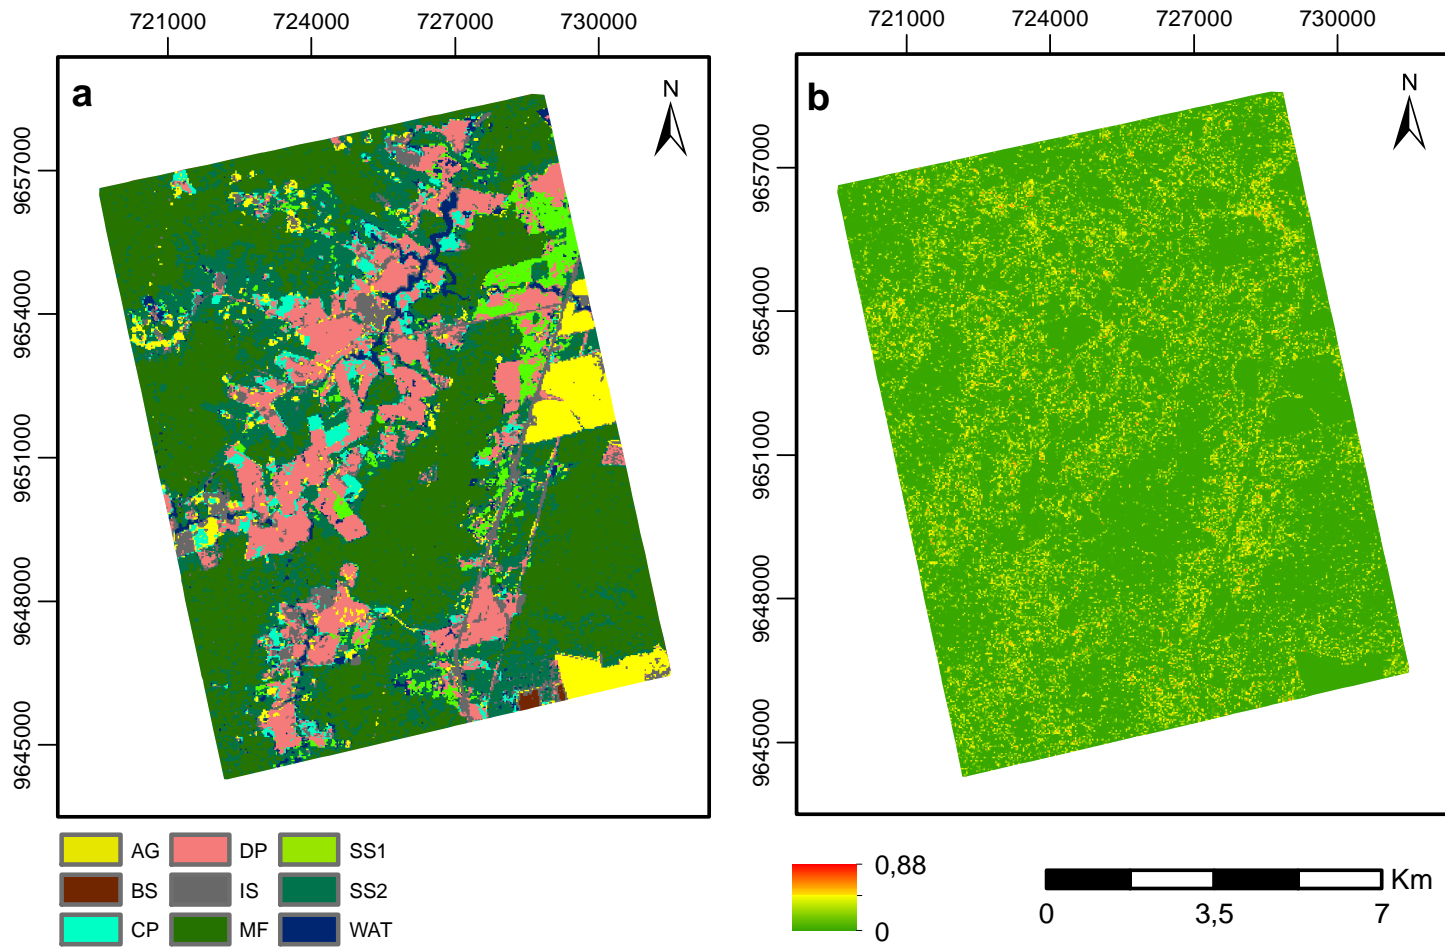


Figura 5.15 – Matriz de confusão da melhor classificação EO-1 ALI a partir do classificador Maxver ($E_g = 0,904$; $\sigma = 0,008$).




Figura 5.16 – a) Melhor classificação EO-1 ALI a partir do classificador SVM e b) mapa de incerteza da classificação ($E_g = 0,933$; $\sigma = 0,007$).

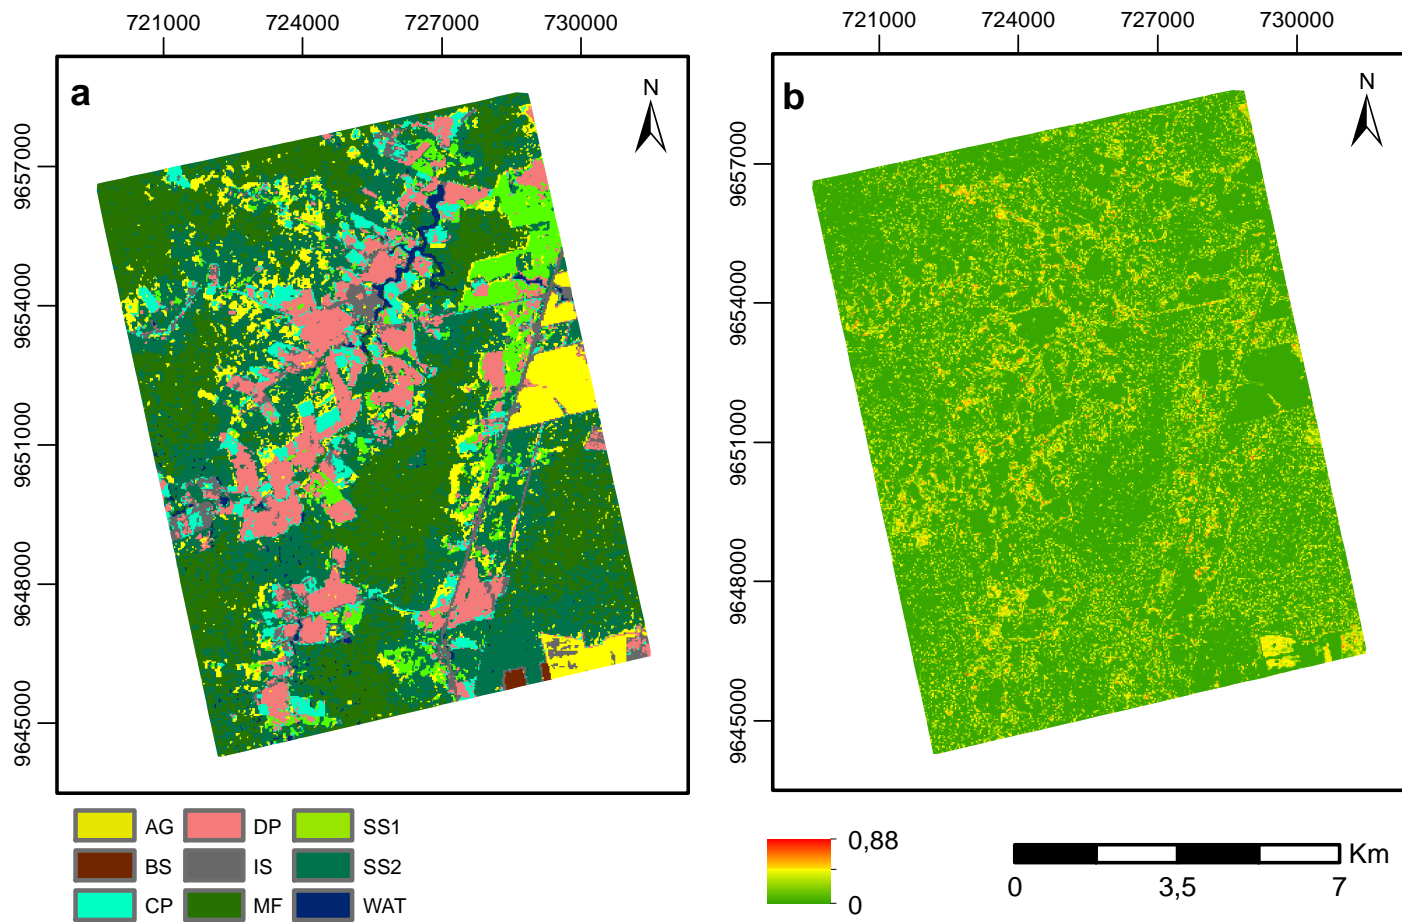



Figura 5.17 – Matriz de confusão da melhor classificação EO-1 ALI a partir do classificador SVM ($E_g = 0,933$; $\sigma = 0,007$).



Diferentemente das classificações de cobertura da terra baseadas em dados SAR, as classificações baseadas em dados ópticos se mostraram capazes de separar quase que totalmente as 9 classes envolvidas no estudo. A exatidão global obtida pelas classificações desses dados chegou a 0,904 e 0,933 para os classificadores Maxver e SVM, respectivamente. No entanto, uma análise classe a classe mostra que apesar dos excelentes resultados de exatidão global, as confusões entre as classes Sucessão Secundária Inicial (SS1) e Pasto Sujo (DP) e entre as classes Sucessão Secundária Intermediária (SS2) e Floresta Madura (MF) acontecem para os dois classificadores. A confusão

entre Superfícies Impermeáveis (IS) e Solo Exposto (BS) que ocorre no classificador Maxver no entanto, não é cometida pelo classificador SVM.

Apesar da exatidão global obtida pela classificação SVM ser superior a obtida pela classificação Maxver, o mapa de incerteza associado a classificação SVM é visivelmente mais amarelado do que o mapa de incerteza associado a classificação Maxver, o que indica uma incerteza mais elevada no mapa de cobertura da terra, ou ao menos em alguns pontos do mapa de cobertura da terra gerado através da classificação SVM. Para entender melhor a informação de incerteza, que é dada por um índice obtido de forma pontual, e não agrega informação relevante ao ser apresentada como um índice médio para a classificação como um todo optou-se por apresentar a incerteza média por classe. Isso porque baixos índices de incerteza para classes de alta ocorrência poderiam dar origem a uma incerteza média baixa mesmo que outras classes com menor ocorrência apresentassem altos índices de incerteza e vice-versa. As incertezas médias por classes, para cada uma das classificações individuais realizadas por cada classificador, são apresentadas na Tabela 5.5.

Tabela 5.5 – Incerteza média das classes nas classificações da cobertura da terra.

Classe	Maxver			SVM			
	FQ06	FQ13	EO-1 ALI	FQ06	FQ13	FQ06/FD	EO-1 ALI
AG	0,50	0,47	0,07	0,56	0,52	0,59	0,31
BS	0,08	0,07	0,00	0,20	0,18	0,18	0,01
CP	0,13	0,15	0,09	0,22	0,28	0,24	0,12
DP	0,46	0,42	0,06	0,54	0,54	0,56	0,09
IS	0,30	0,44	0,09	0,43	0,52	0,47	0,16
MF	0,22	0,24	0,04	0,57	0,45	0,52	0,55
SS1	0,24	0,28	0,07	0,40	0,53	0,39	0,09
SS2	0,25	0,44	0,08	0,40	0,54	0,46	0,08
WAT	0,15	0,03	0,15	0,60	0,34	0,28	0,13

Os resultados de incerteza média obtidos para cada classe comprovam a informação visual obtida nas Figuras 5.4, 5.6, 5.8 e 5.10 e já discutida, que mostra o classificador SVM apresentando uma maior incerteza principalmente para as classes de maior confusão. Os resultados de incerteza média obtidos

para cada classe, assim como as matrizes de confusão já apresentadas, também mostram uma maior certeza de classificação e uma maior separabilidade da classe Solo Exposto para os dados SAR em modo FQ06 e FQ13 principalmente para o classificador Maxver. A classe Pasto Limpo (CP) que apresentou uma separabilidade média de acordo com as matrizes de confusão também apresentam índices de incerteza menores que os demais para os dados SAR em ambos os modos e ambos os classificadores. Já a classe Água (WAT) destaca-se com uma incerteza baixa para os dados SAR em ambos os modos quando classificada através do classificador Maxver.

A melhor classificação envolvendo decomposição polarimétrica, obtida para dados FQ06 associados aos canais P_V , P_D e P_S gerados pela decomposição polarimétrica de Freeman e Durden, não apresenta valores de incerteza significativamente melhores que os das classificações para dados SAR apenas. Para os dados ópticos, a incerteza média das classes, assim como a exatidão global e as matrizes de confusão, também se mostra extremamente superior as obtidas nas classificações de dados SAR.

De forma geral, através da informação de incerteza média das classes é possível ressaltar que tanto para os dados SAR em ambos os modos quanto para os dados EO-1 ALI todas as classes apresentaram valor de incerteza médio menor ao serem classificados pelo Maxver. No entanto, as classificações dos dados SAR em modo FQ13 e dos dados ópticos através do classificador SVM foram as que apresentaram maior exatidão global, sendo superiores, sob esse critério, às classificações dos mesmos dados obtidas através do classificador Maxver.

5.3. Detecção de mudanças

A detecção de mudanças foi aplicada a 10 conjuntos de imagens contendo informações referentes a 2009 e 2013. Destes, 5 conjuntos foram utilizadas na comparação pós-classificação e 5 conjuntos foram utilizados na classificação

direta. Os conjuntos utilizados em cada método de detecção de mudanças e os respectivos valores de exatidão global obtidos são apresentados na Tabela 5.6.

Tabela 5.6 – Conjuntos de dados de entrada para detecção de mudança por comparação pós-classificação e por classificação direta.

Método	Classificador	Imagens	Atributos	Exatidão Global
CPC	Maxver	FQ06	HH, (HV+VH)/2, VV	0,251
		EO-1 ALI	MS1, MS2, MS3, MS4', MS5', MS5, MS7	
CPC	Maxver	FQ13	HH, (HV+VH)/2, VV	0,264
		EO-1 ALI	MS1, MS2, MS3, MS4', MS5', MS5, MS7	
CPC	SVM	FQ06	HH, (HV+VH)/2, VV	0,222
		EO-1 ALI	MS1', MS1, MS2, MS3, MS4, MS4', MS5', MS5, MS7	
CPC	SVM	FQ13	HH, (HV+VH)/2, VV	0,268
		EO-1 ALI	MS1', MS1, MS2, MS3, MS4, MS4', MS5', MS5, MS7	
CPC	SVM	FQ06/FD	(HV+VH)/2, VV, P _V , P _D e P _S	0,233
		EO-1 ALI	MS1', MS1, MS2, MS3, MS4, MS4', MS5', MS5, MS7	
CD	Maxver	FQ06	(HV+VH)/2	0,836
		EO-1 ALI	MS2, MS4', MS5', MS7	
CD	Maxver	FQ06	(HV+VH)/2	0,821
		EO-1 ALI	MS2, MS4', MS5', MS7	
CD	SVM	FQ13	(HV+VH)/2, VV	0,820
		EO-1 ALI	MS2, MS4', MS5', MS7	
CD	SVM	FQ13	(HV+VH)/2, VV	0,798
		EO-1 ALI	MS2, MS4', MS5', MS7	
CD	SVM	FQ06/FD	(HV+VH)/2, VV, P _V , P _D e P _S	0,776
		EO-1 ALI	MS2, MS4', MS5', MS7	

É preciso destacar que em todos os mapas de mudança gerados por comparação pós-classificação as classes consideradas impossíveis ou improváveis para o intervalo do estudo e aquelas consideradas possíveis, mas não encontradas em campo, foram agrupadas. As classes impossíveis ou improváveis são apresentadas como a classe não classificada enquanto as que apesar de possíveis não foram encontradas em campo são apresentadas como a classe não observada. Por essa razão uma linha contendo informação a respeito da porcentagem de *pixels* erroneamente classificados como pertencentes às classes não classificada ou não observada (NC_NO) é adicionada às matrizes de confusão referentes aos mapas de mudança por comparação pós-classificação. Essa abordagem as transforma em um tipo

especial de matrizes de confusão não quadrada, a partir da qual os índices de exatidão global são recalculados, não contendo assim informação de desvio padrão. Para chegar a esse novo valor de exatidão global a partir dessas matrizes não quadradas é necessário apenas que os pixels de validação classificados como as classes não encontrada ou não observada sejam retirados do cálculo, considerando para tanto apenas os pixels classificados como uma das classes existentes. Os mapas de incerteza associados a todos os mapas de mudança obtidos por comparação pós-classificação são apresentados de acordo com a incerteza acumulada (*ICA*) definida pela equação 4.5. Nestes mapas de incerteza a cor verde representa a inexistência de incerteza ($ICA = 0$), a cor vermelha representa a maior incerteza acumulada possível, calculada a partir das incertezas das classificações iniciais para o conjunto de classes do estudo ($ICA = 0,9856$). A escala de cores entre verde e vermelho é associada aos pixels com incerteza acumulada verde de maneira proporcional como mostram as figuras.

Os resultados da detecção de mudanças por comparação pós-classificação para o conjunto baseado nos dados SAR em modo FQ06 associados aos dados ópticos e nos dados SAR em modo FQ13 associados aos dados ópticos obtidos a partir do classificador Maxver são apresentados nas Figuras 5.18-a e 5.19-a. As matrizes de confusão não quadradas referentes a cada um destes mapas de mudança são apresentadas na Figuras 5.20. A exatidão global obtida, através destas matrizes, para cada um dos mapas de mudança é de 0,251 e de 0,264, respectivamente. Os mapas de incerteza associados a cada um destes mapas de mudança são apresentados nas Figuras 5.18-b e 5.19-b.

O mesmo procedimento foi adotado para os conjuntos formados pelas melhores classificações obtidas a partir do classificador SVM. Os mapas de mudança e os mapas de incerteza para cada um dos conjuntos de dados utilizados são apresentados nas Figuras 5.21 e 5.22. A exatidão global obtida para esses mapas de mudança são de 0,222 para o conjunto baseado nos dados SAR em modo FQ06 associados aos dados ópticos e de 0,268 para o

conjunto baseado nos dados SAR em modo FQ13 associados aos dados ópticos. As matrizes de confusão não quadradas, referentes a cada um destes mapas de mudança são apresentadas na Figura 5.23.

Finalmente o resultado da comparação pós-classificação envolvendo dados SAR em modo FQ06 associados aos canais P_V , P_D e P_S e dados EO-1 ALI é apresentado na Figura 5.24. A matriz de confusão associada a este mapa de mudança com exatidão global de 0,233 é apresentado na Figura 5.25.

Figura 5.18 – a) Mapa de mudanças entre os anos de 2009 e 2013 gerado por comparação pós-classificação das classificações Maxver FQ06 e EO-1 ALI mais acuradas e b) incerteza da detecção de mudança ($E_g = 0,251$).

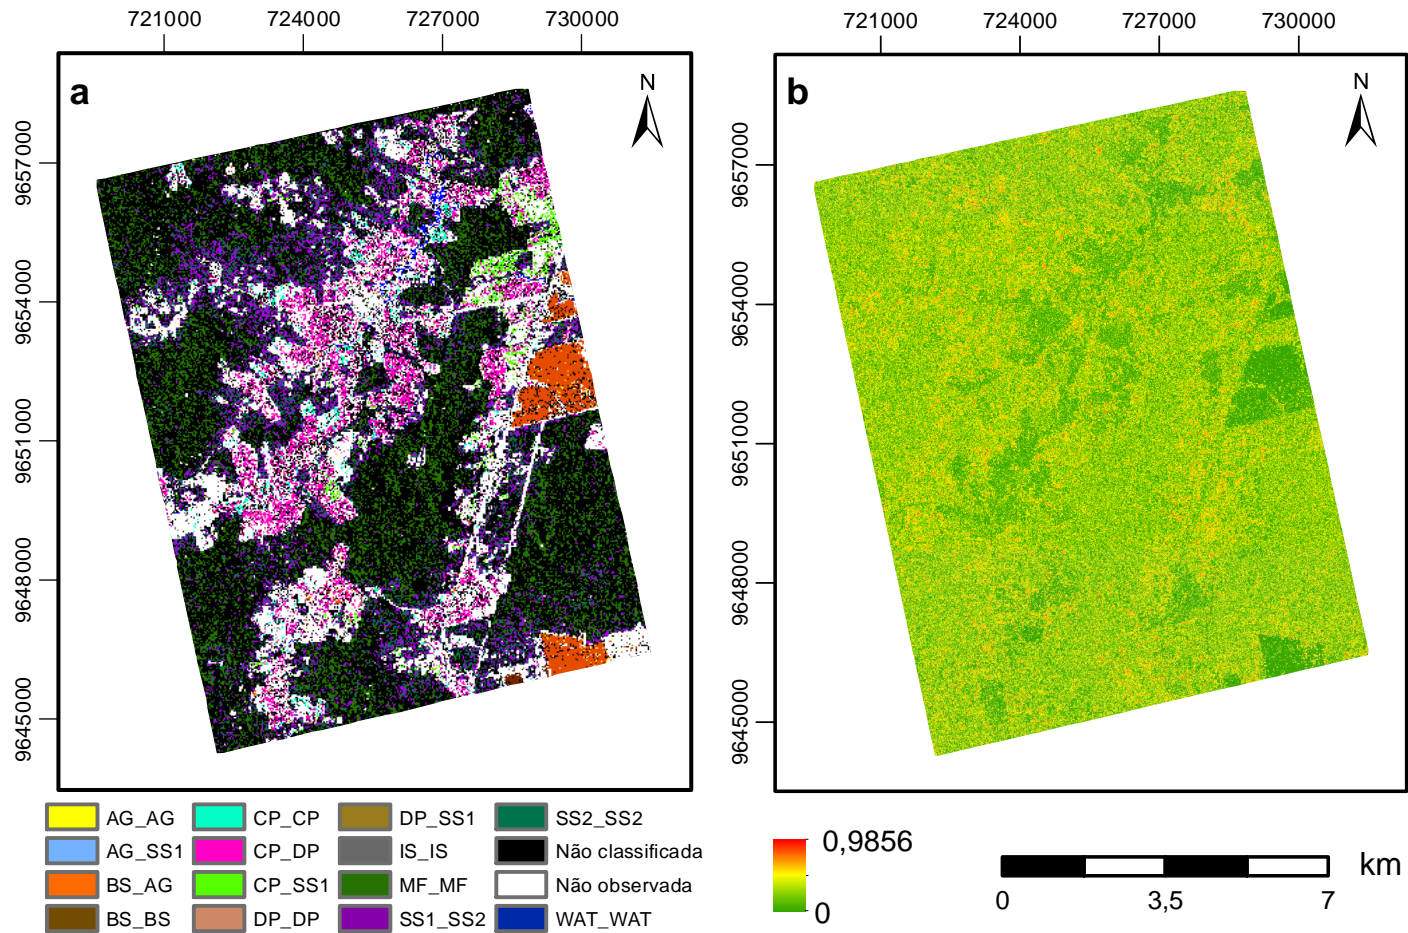


Figura 5.19 – a) Mapa de mudanças entre os anos de 2009 e 2013 gerado por comparação pós-classificação das classificações Maxver FQ13 e EO-1 ALI mais acuradas b) incerteza da detecção de mudança ($E_g = 0,264$).

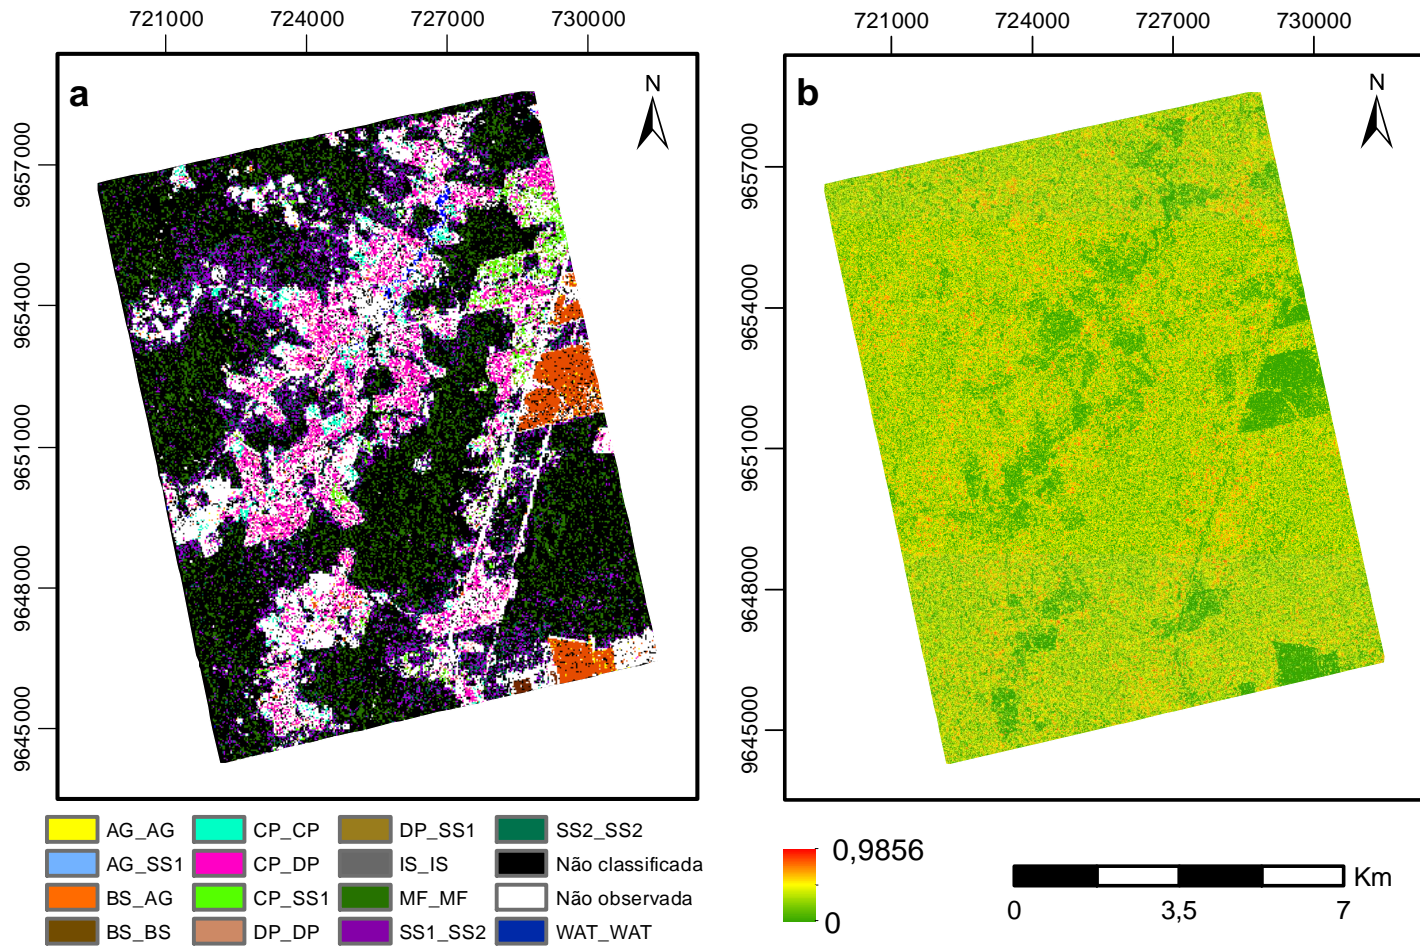


Figura 5.20 – Matrizes de confusão dos mapas de mudanças gerados por comparação pós-classificação, a partir das classificações Maxver mais acuradas a) FQ06 e EO-1 ALI ($E_g = 0,251$) e b) FQ13 e EO-1 ALI ($E_g = 0,264$).




Figura 5.21 – a) Mapa de mudanças entre os anos de 2009 e 2013 gerado por comparação pós-classificação das classificações SVM FQ06 e EO-1 ALI mais acuradas b) incerteza da detecção de mudança ($E_g = 0,222$).

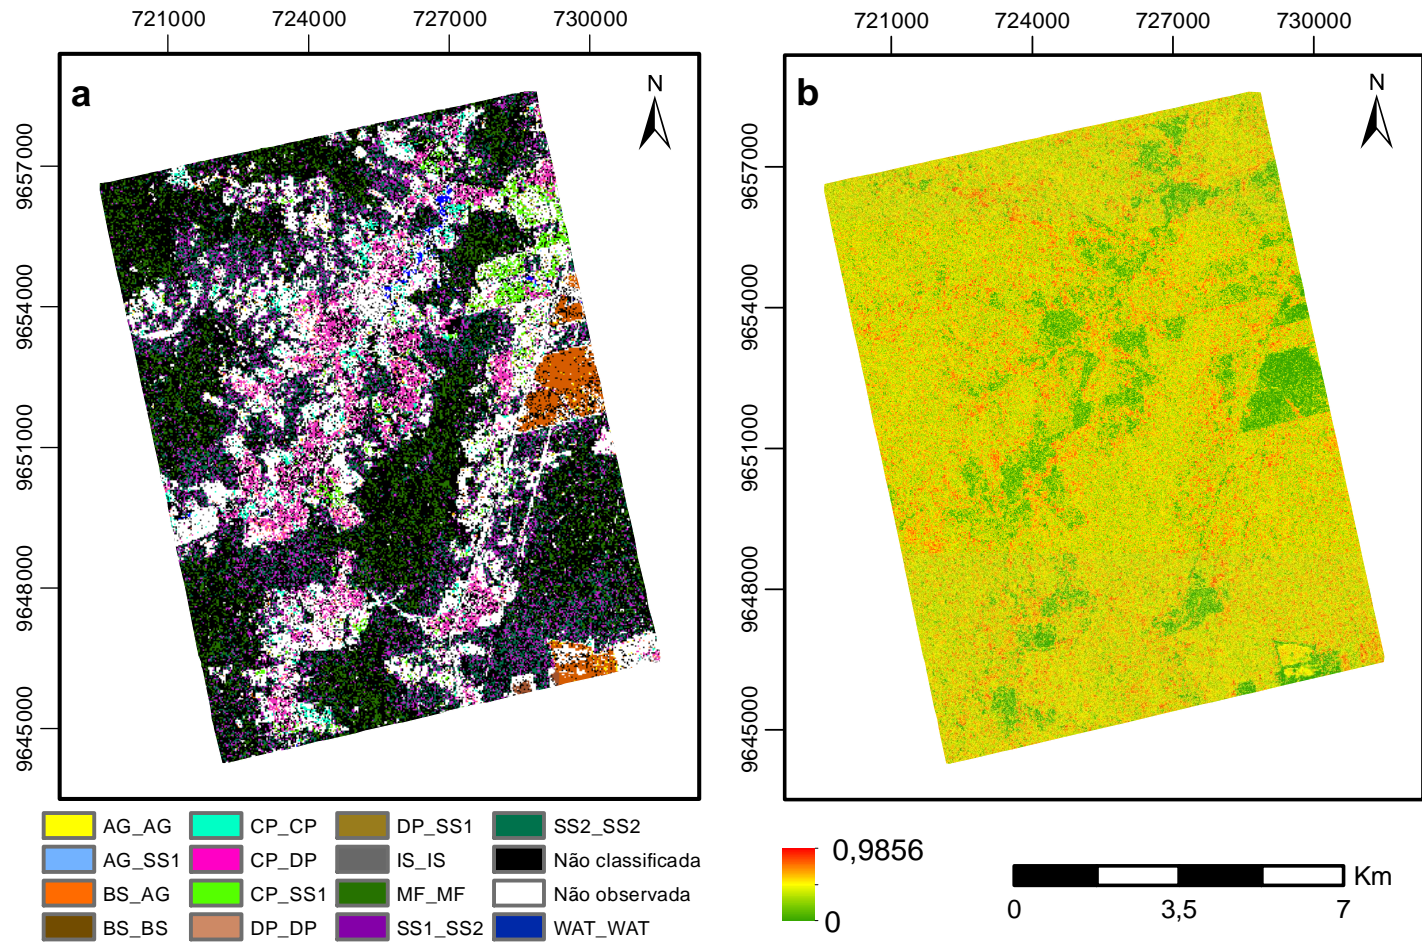


Figura 5.22 – a) Mapa de detecção de mudanças entre os anos de 2009 e 2013 gerado por comparação pós-classificação, das classificações SVM FQ13 e EO-1 ALI mais acuradas b) incerteza da detecção de mudança ($E_g = 0,268$).

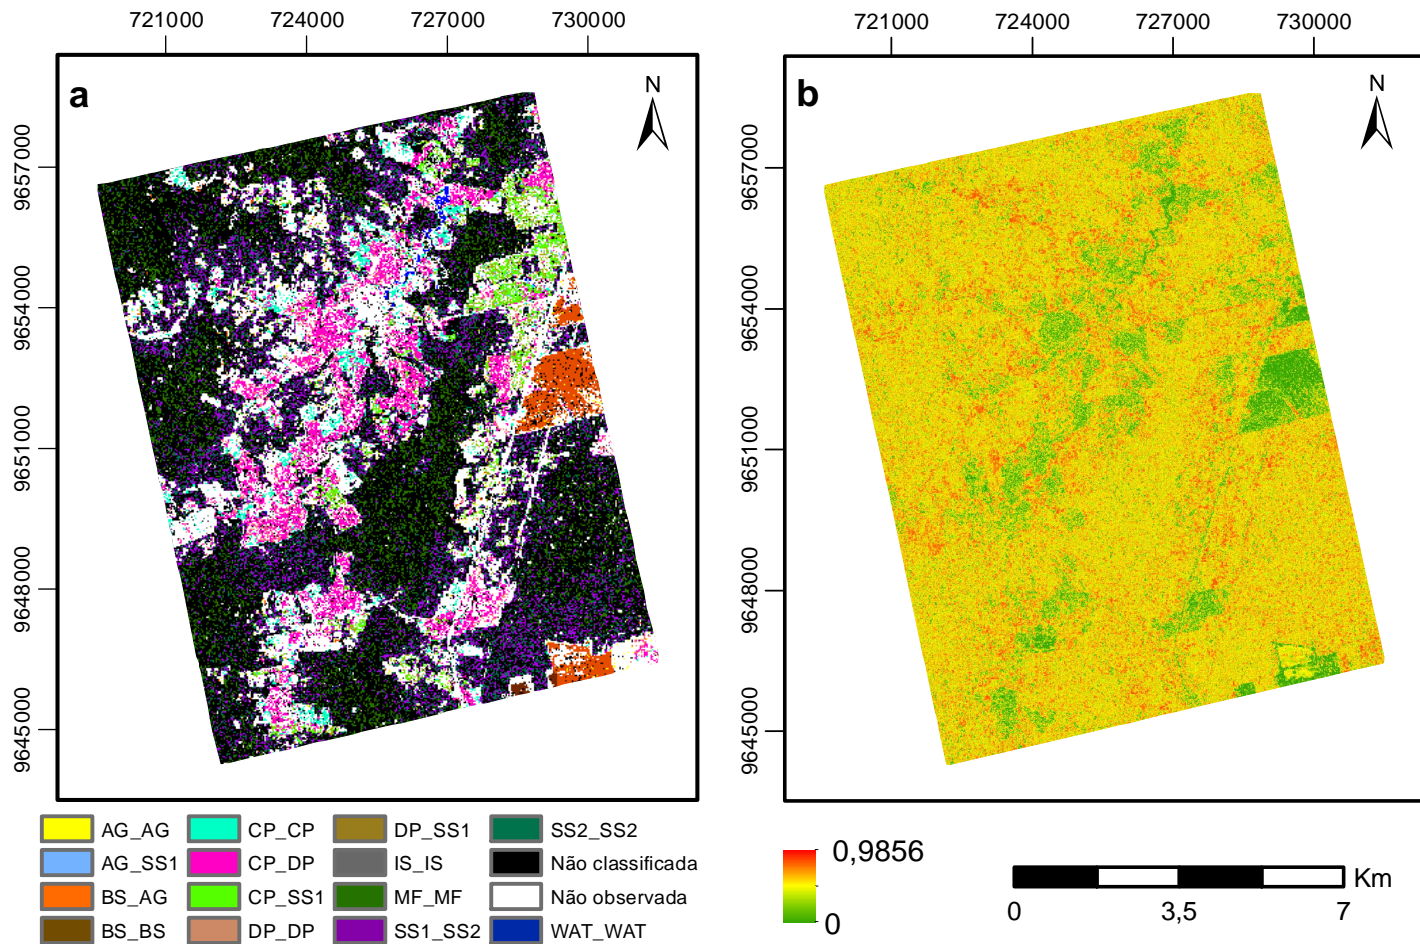


Figura 5.23 – Matrizes de confusão dos mapas de mudanças gerados por comparação pós-classificação, a partir das classificações SVM mais acuradas a) FQ06 e EO-1 ALI ($E_g = 0,222$) e b) FQ13 e EO-1 ALI ($E_g = 0,268$).




Figura 5.24 – a) Mapa de detecção de mudanças entre os anos de 2009 e 2013 gerado por comparação pós-classificação, das classificações SVM para dados SAR associados a dados de decomposição polarimétrica e EO-1 ALI mais acuradas b) incerteza da detecção de mudança ($E_g = 0,233$).

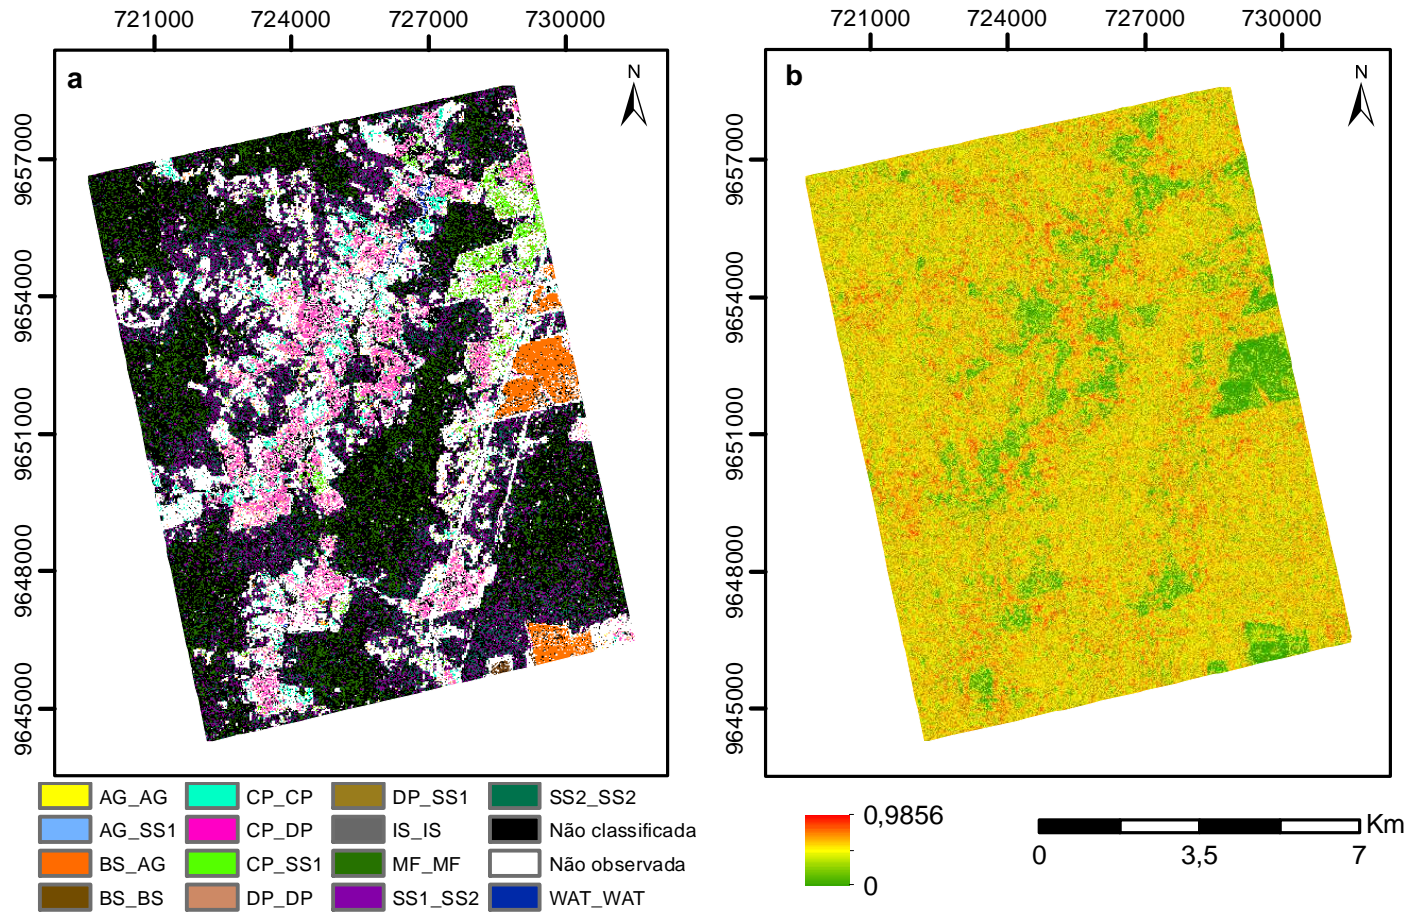



Figura 5.25 – Matriz de confusão do mapa de mudanças gerado por comparação pós-classificação, a partir das classificações SVM dos dados SAR associados a dados de decomposição polarimétrica e EO-1 ALI mais acuradas ($E_g = 0,233$).



Considerando os baixos valores de exatidão global obtidos pelas classificações dos dados SAR e SAR associado aos atributos de decomposições polarimétricas e a dependência que o método de detecção de mudança por comparação pós-classificação tem dessas classificações, resultados com baixo valor de acurácia já eram esperados. Mesmo baseado nas soluções ótimas, a exatidão global do método, para as classificações Maxver usando dados FQ06 e ALI e FQ13 e ALI foi de 0,251 e 0,264, respectivamente. Quando aplicado às classificações SVM dos conjuntos FQ06 e ALI e FQ13 e ALI o método de detecção de mudanças por comparação pós-classificação também resultou em baixos valores de exatidões globais de 0,222 e 0,268. Até a utilização da melhor classificação SAR associada à decomposição polarimétrica e da melhor

classificação obtida para os dados EO-1 ALI não resultou em um bom mapa de mudança, obtendo uma exatidão global de apenas 0,233.

Comparando os mapas de mudança obtidos entre si, apenas a comparação das classificações SVM para os dados SAR em modo FQ06 e EO-1 ALI apresentou resultado significativamente inferior aos restantes. Para os conjuntos SAR em modo FQ13 e EO-1 ALI o método de comparação pós-classificação não apresentou diferenças expressivas relacionadas aos classificadores. Ainda é preciso ressaltar que os dados SAR em modo FQ13, que apresentaram valores de exatidão global ligeiramente inferiores aos obtidos para as classificações dos dados SAR em modo FQ06 nas classificações individuais, tiveram um desempenho ligeiramente superior na detecção de mudanças por comparação pós-classificação.

Em geral as classes de mudança envolvendo a classe Solo Exposto (BS) para o ano de 2009 foram bem mapeadas. Isso ocorre devido à boa separação dessa classe nas classificações SAR originais. A classe de mudança Solo Exposto (BS) para Agricultura (AG) chega a alcançar 77% de acerto, no entanto, a confusão dessa classe com a classe de não mudança Agricultura (AG) para Agricultura (AG) que chega a 85,6% diminui a confiabilidade no resultado dessa classe. A classe de mudança Pasto Limpo (CP) para Pasto Sujo (DP) apresenta um acerto em torno de 60% para a mudança detectada pelas classificações SVM de dados FQ13 e ALI e as classes envolvendo Sucessão Secundária Inicial (SS1) e Sucessão Secundária Intermediária (SS2) apresentam acertos em torno de 30%.

Assim como nas classificações individuais, a análise dos mapas de incerteza, que para a detecção de mudanças por comparação pós-classificação são dadas pela incerteza acumulada, também mostram uma maior incerteza dos mapas de mudança gerados a partir das classificações SVM. Uma menor incerteza para as classes de mudança e não mudança envolvendo as classes Solo Exposto (BS) e Pasto Limpo (CP) para o ano de 2009 também pode ser

observada, o que era esperado devido a melhor separação destas classes nas classificações individuais utilizadas no processo de detecção de mudanças por comparação pós-classificação. As incertezas acumuladas médias para cada classe de mudança e não mudança bem como para as classes não classificada e não observada para cada um dos mapas de mudança gerados por comparação pós-classificação são apresentadas na Tabela 5.7.

Tabela 5.7 – Incerteza acumulada média das classes na detecção de mudanças por comparação pós-classificação.

Classe	Maxver		SVM		
	FQ06 EO-1 ALI	FQ13 EO-1 ALI	FQ06 EO-1 ALI	FQ13 EO-1 ALI	FQ06/FD EO-1 ALI
AG_AG	0,45	0,46	0,56	0,56	0,58
AG_SS1	0,54	0,53	0,59	0,55	0,60
BS_AG	0,05	0,06	0,16	0,15	0,12
BS_BS	0,25	0,06	0,11	0,10	0,07
CP_CP	0,19	0,21	0,31	0,36	0,32
CP_DP	0,16	0,18	0,23	0,29	0,24
CP_SS1	0,18	0,22	0,27	0,34	0,28
DP_DP	0,49	0,45	0,58	0,59	0,55
DP_SS1	0,50	0,45	0,56	0,57	0,56
IS_IS	0,35	0,49	0,49	0,60	0,51
MF_MF	0,24	0,26	0,49	0,47	0,53
SS1_SS2	0,30	0,33	0,45	0,57	0,45
SS2_SS2	0,30	0,48	0,44	0,57	0,51
WAT_WAT	0,18	0,15	0,18	0,14	0,19
Não classificada	0,28	0,33	0,46	0,51	0,51
Não observada	0,26	0,29	0,44	0,51	0,47

Além das confusões entre as classes que de fato ocorreram, comprovadas tanto pelas matrizes de confusão quanto pela incerteza acumulada média de cada classe, a existência de classes impossíveis, improváveis e não encontradas em campo também é um problema da detecção de mudanças por comparação pós-classificação. Isso porque o uso de classificações pouco acuradas aumenta a possibilidade de um *pixel* ser classificado como uma dessas classes que não ocorrem de fato. A grande porcentagem de *pixels* sabidamente pertencentes a uma das classes existentes, mas erroneamente

classificados como não encontrada ou não observada, comprova a existência do problema. Isso pode ser visto na última linha das matrizes de confusão não quadradas associadas aos mapas de mudança por comparação pós-classificação que chega a conter, para as classes mais difíceis de serem separadas, 70 à 80% dos pixels das amostras de validação e que mesmo para classes com maiores valores de acerto na classificação inicial ainda ficam em torno de 20 a 30%. Neste contexto, mesmo apresentando alguma separação para classes específicas, a detecção de mudanças por comparação pós-classificação não pode ser considerada como um método capaz de detectar corretamente as mudanças ocorridas na área de estudo durante o intervalo proposto.

O mesmo não ocorre para a detecção de mudanças por classificação direta, como mostram os mapas de mudanças e as matrizes de confusão apresentados nas Figuras 5.26, 5.27, 5.28, 5.29, 5.30 e 5.31. Os mapas de mudanças citados foram gerados tanto para o conjunto baseado nos dados SAR em modo FQ06 associados aos dados ópticos quanto para o conjunto baseado nos dados SAR em modo FQ13 associados aos dados ópticos através dos classificadores Maxver e SVM. Os mapas de incerteza associados a cada um dos mapas de mudança também são apresentados. Nestes mapas de incerteza a cor verde representa a inexistência de incerteza ($IC = 0$), a cor vermelha representa a maior incerteza possível para o conjunto de 14 classes de mudança e não mudança adotadas para este estudo ($IC = 0,92$) e os valores de incerteza intermediários são associados proporcionalmente à escala de cor entre verde e vermelho como mostram as figuras. A classificação direta dos dados SAR em modo FQ06 associados aos dados ópticos a partir do classificador Maxver resultou em uma exatidão global de 0,836. Para os dados SAR em modo FQ13 associados aos dados ópticos também classificados pelo Maxver o valor obtido para a exatidão global foi de 0,821. A classificação direta a partir do SVM resultou em exatidões globais de 0,820 e 0,798 para os conjuntos FQ06 e óptico e FQ13 e óptico, respectivamente. As matrizes associadas a estes mapas de mudanças são consideradas matrizes de

confusão quadradas pois a linha referente aos *pixels* classificados como não classificada ou não observada é nula. Isso devido as classes não classificada e não observada existirem apenas na detecção de mudanças por comparação pós-classificação. Por fim, o mapa de mudança gerado por classificação direta, baseado na classificação SVM dos dados FQ06 associados aos canais P_V , P_D e P_S , gerados pela decomposição polarimétrica de Freeman e Durden, e dos dados EO-1 ALI, com exatidão global de 0,776 é apresentado na Figura 5.32. A matriz de confusão associada a este mapa de mudança pode ser observada na Figura 5.33.

Figura 5.26 – a) Mapa de mudanças entre os anos de 2009 e 2013 gerado por classificação direta a partir do classificador Maxver para dados FQ06 e EO-1 ALI b) incerteza da detecção de mudança ($E_g = 0,836$; $\sigma = 0,011$).

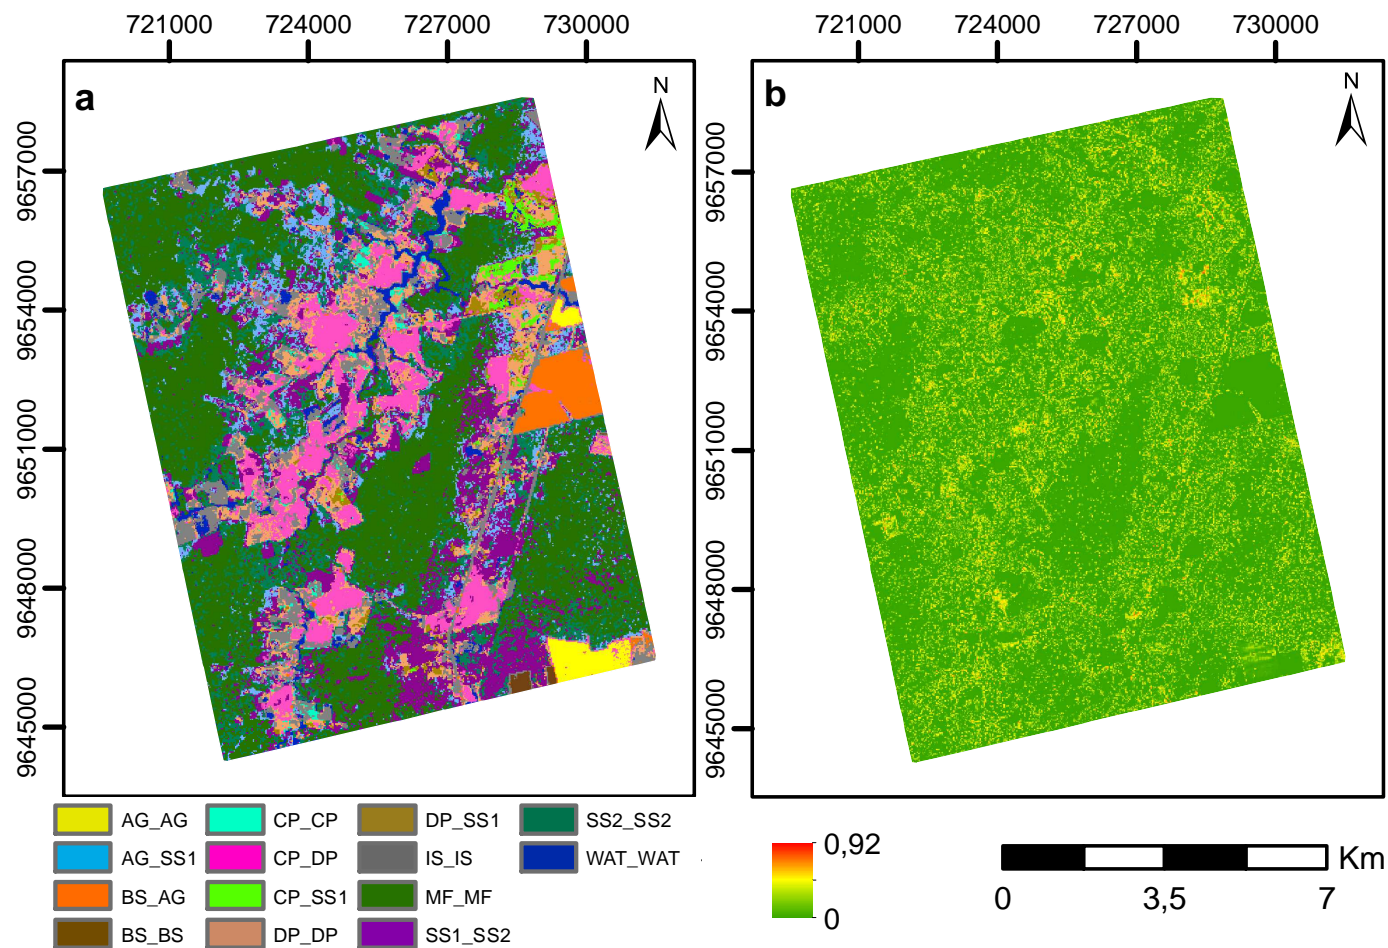


Figura 5.27 – a) Mapa de mudanças entre os anos de 2009 e 2013 gerado por classificação direta a partir do classificador Maxver para dados FQ13 e EO-1 ALI b) incerteza da detecção de mudança ($E_g = 0,821$; $\sigma = 0,01$).

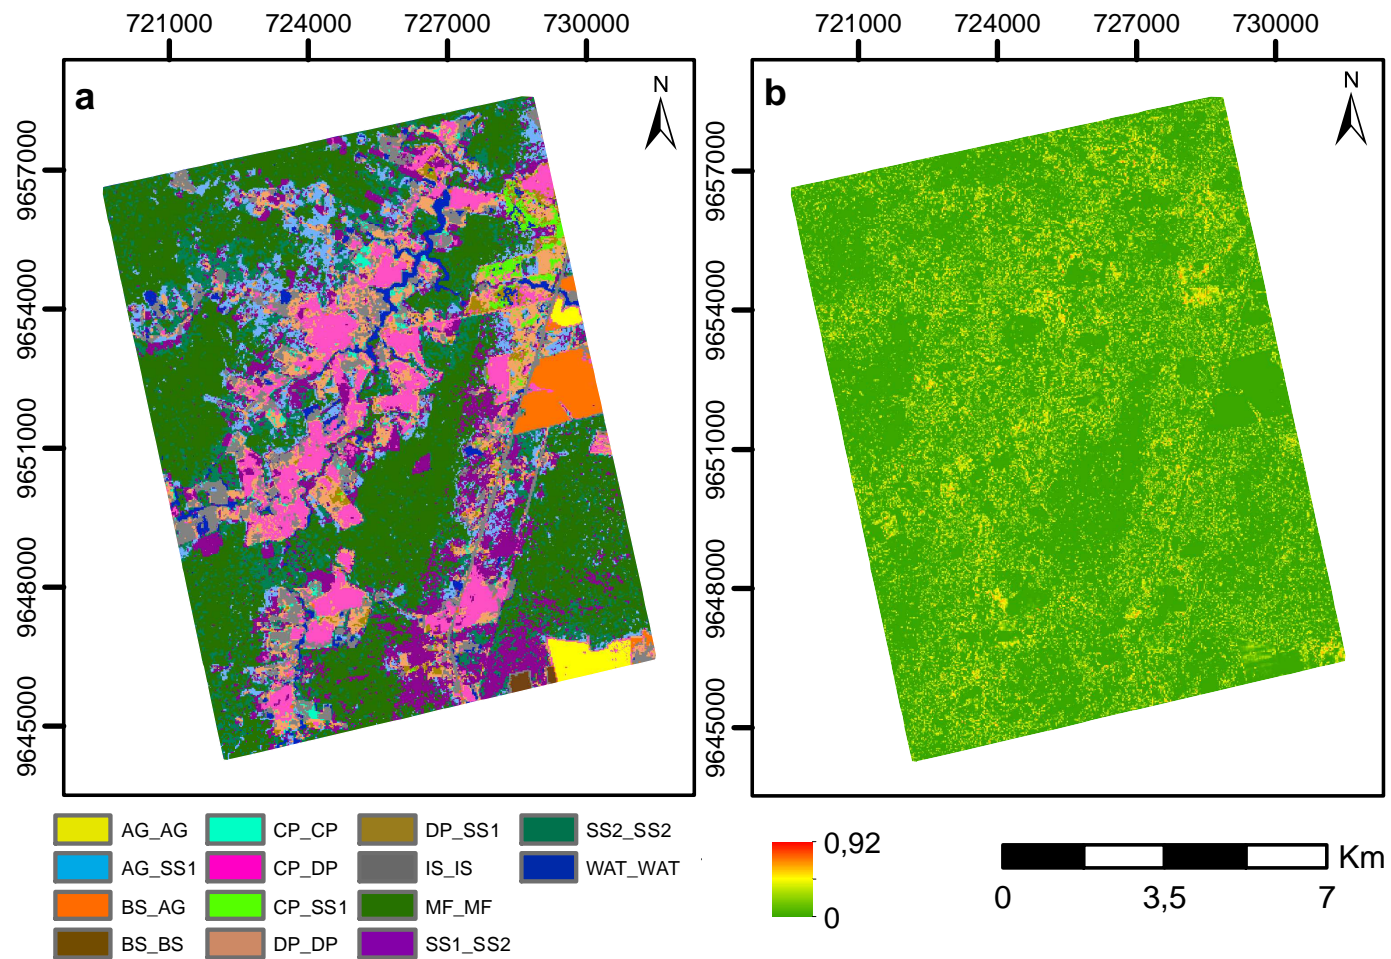


Figura 5.28 – Matrizes de confusão dos mapas de mudanças gerados por classificação direta, a partir das classificações Maxver para os dados a) FQ06 e EO-1 ALI ($E_g = 0,836$; $\sigma = 0,011$) e b) FQ13 e EO-1 ALI ($E_g = 0,821$; $\sigma = 0,01$).





Figura 5.29 – a) Mapa de mudanças entre os anos de 2009 e 2013 gerado por classificação direta a partir do classificador SVM para dados FQ06 e EO-1 ALI b) incerteza da detecção de mudança ($E_g = 0,820$; $\sigma = 0,012$).

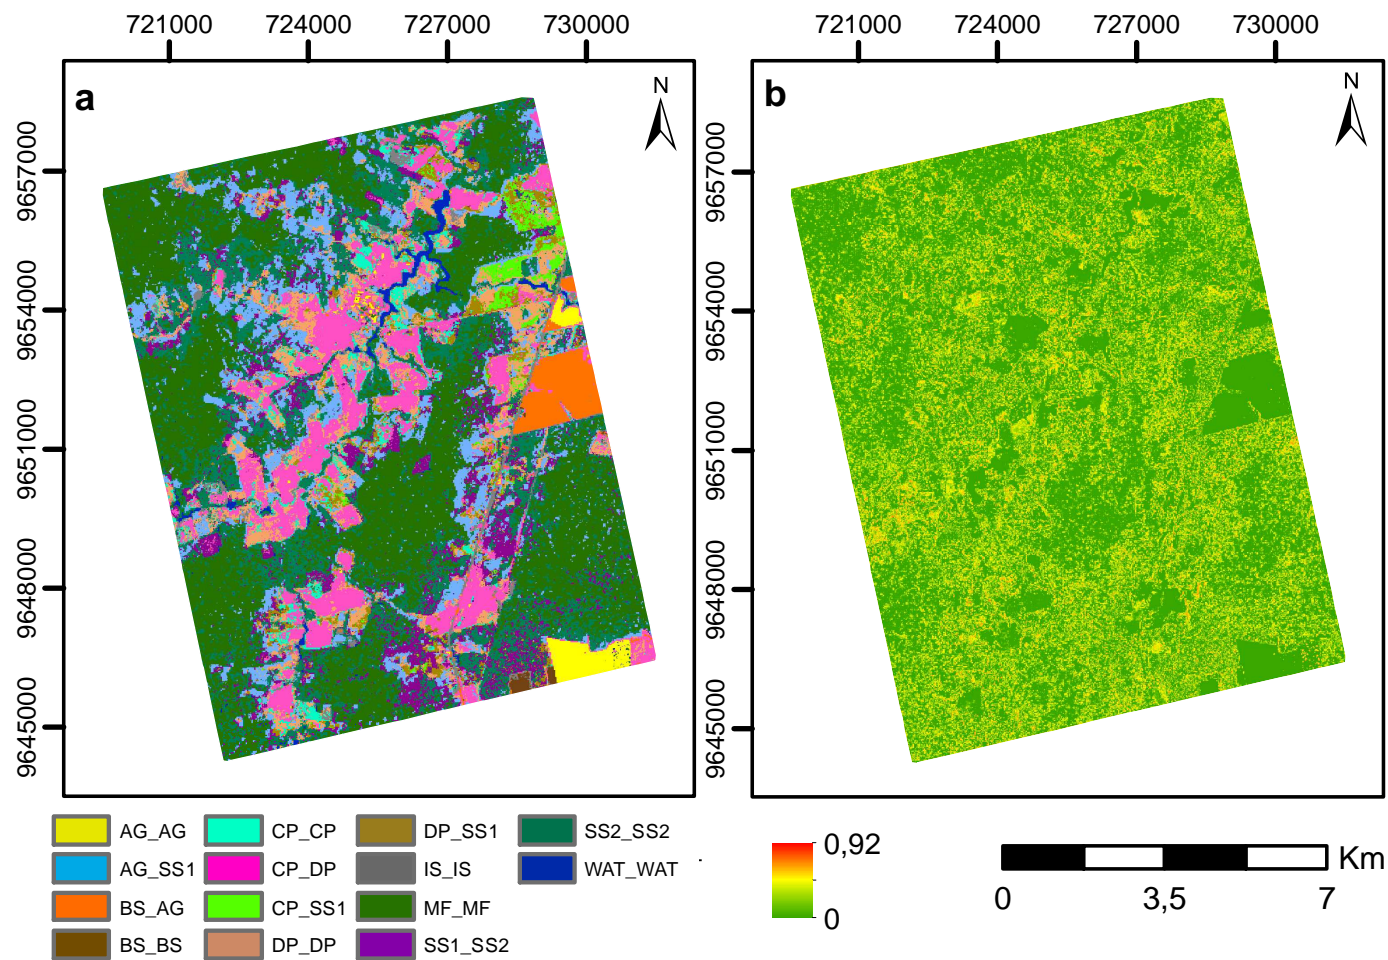


Figura 5.30 – a) Mapa de detecção de mudanças entre os anos de 2009 e 2013 gerado por classificação direta a partir do classificador SVM para dados FQ13 e EO-1 ALI b) incerteza da detecção de mudança ($E_g = 0,798$; $\sigma = 0,009$).

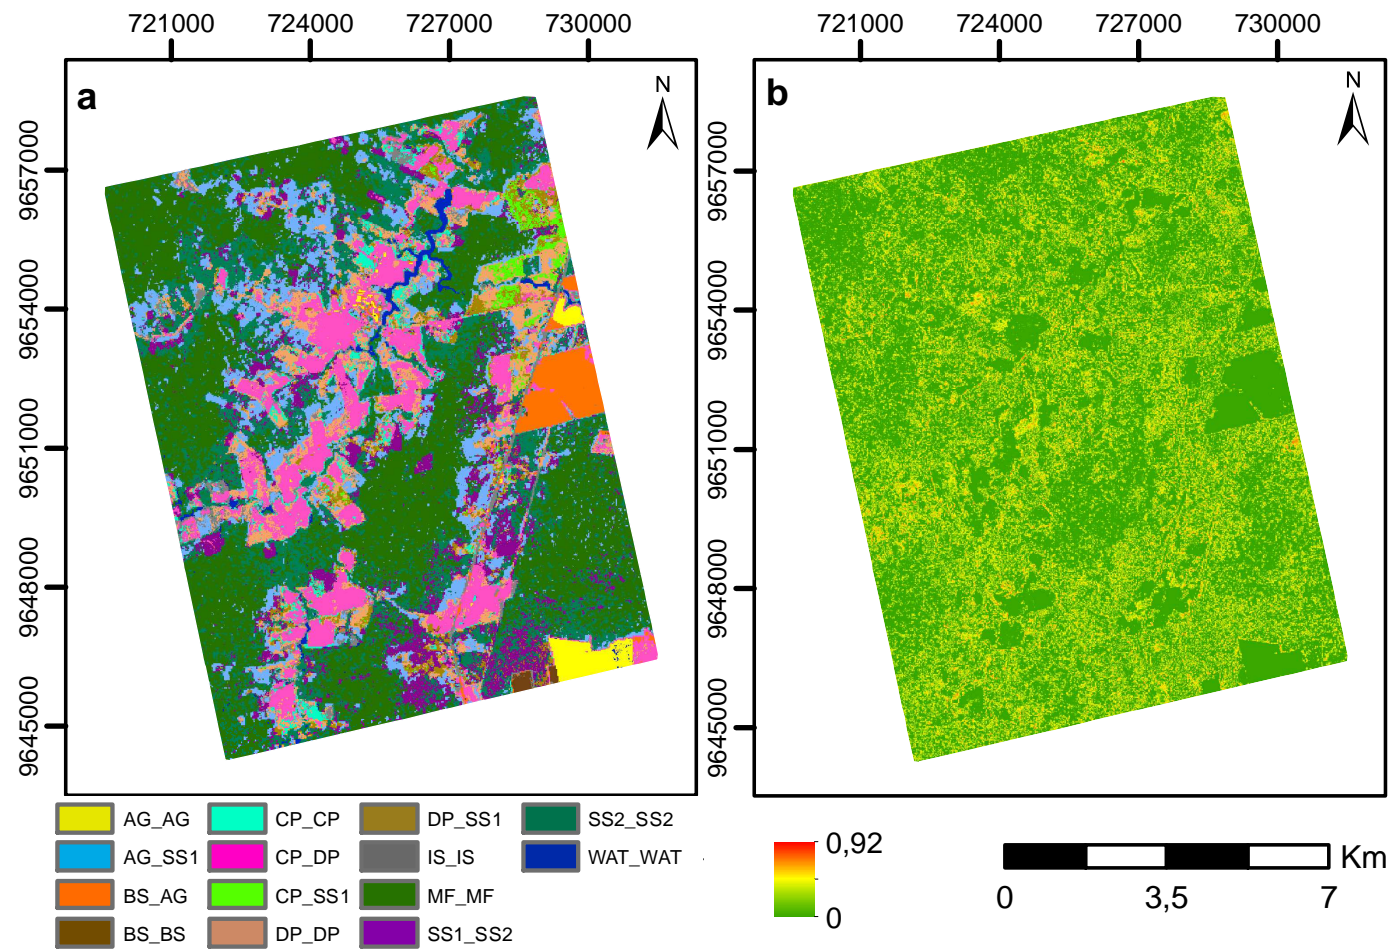


Figura 5.31 – Matrizes de confusão dos mapas de mudanças gerados por classificação direta, a partir das classificações SVM para os dados a) FQ06 e EO-1 ALI ($E_g = 0,82$; $\sigma = 0,012$) e b) FQ13 e EO-1 ALI ($E_g = 0,798$; $\sigma = 0,009$).


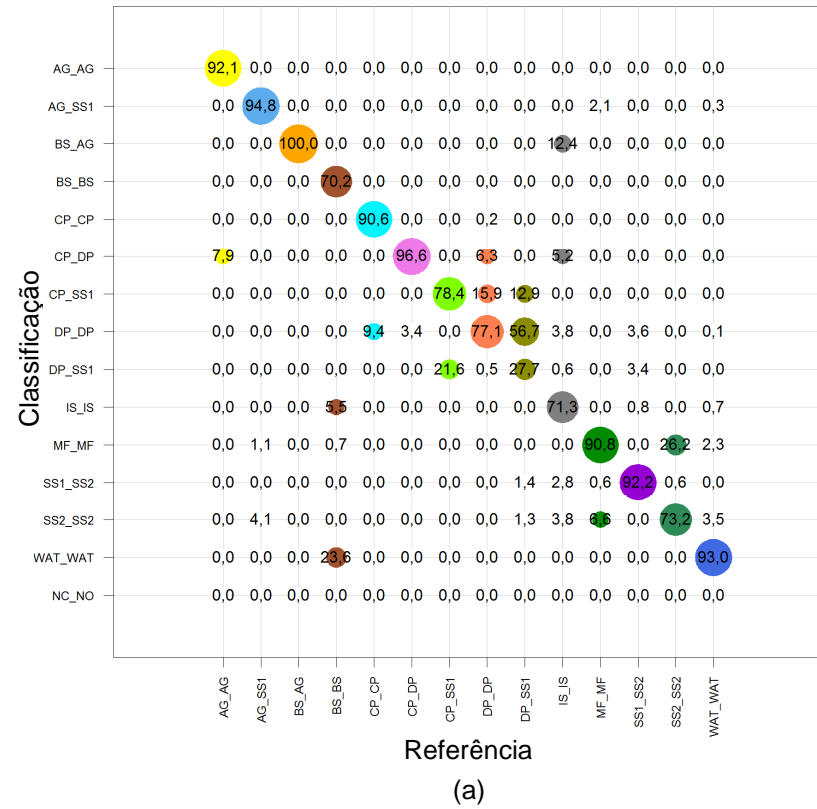


Figura 5.32 – a) Mapa de detecção de mudanças entre os anos de 2009 e 2013 gerado por classificação direta a partir do classificador SVM para dados FQ06 associadas aos canais FD e EO-1 ALI b) incerteza da detecção de mudança ($E_g = 0,776$; $\sigma = 0,013$).

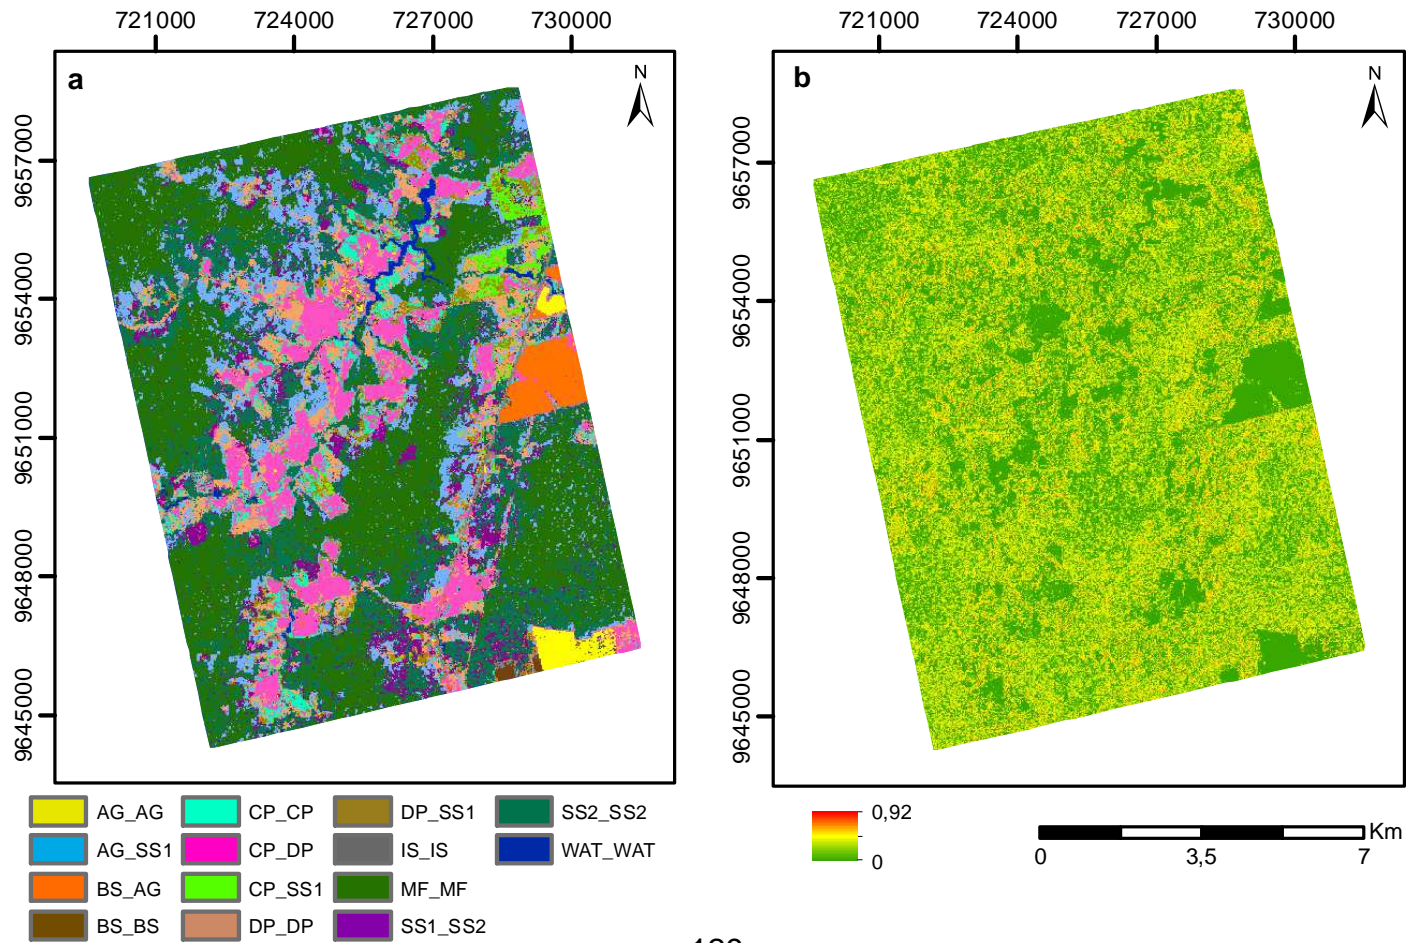



Figura 5.33 – Matriz de confusão do mapa de mudanças gerado por classificação direta, a partir da classificação SVM dos dados FQ06 associados aos canais FD e EO-1 ALI.



Diferentemente dos resultados obtidos pela detecção de mudança por comparação pós-classificação, os resultados apresentados para a classificação direta mostram uma quase que completa separação entre as classes de mudanças e não mudanças ocorridas na área de interesse no intervalo temporal estudado. A exatidão global de 83,6% obtida pela melhor detecção de mudanças por classificação direta envolvendo 14 classes de mudanças e não mudanças é considerado expressivo, uma vez que Reiche et al. (2012) obteve uma exatidão global de 89% ao aplicar uma metodologia de detecção de mudanças em área de floresta, através de dados SAR e ópticos para separar apenas 3 classes. Uma análise classe à classe mostra, que as mudanças Agricultura para Sucessão Secundária Inicial (AG_SS1), Solo Exposto para Agricultura (BS_AG), Pasto Limpo para Pasto Sujo (CP_DP), Pasto Limpo para

Sucessão Secundária Intermediária (CP_SS2) e Sucessão Secundária Inicial para Sucessão Secundária Intermediária (SS1_SS2) foram classificadas com acertos sempre superiores a 75%, chegando a 100% em alguns casos. No entanto, a classe de mudança Pasto Sujo para Sucessão Secundária Inicial (DP_SS1) apresenta um baixo acerto, em torno de 25%, quando a detecção de mudanças é conduzida através do classificador SVM. Com o uso da decomposição polarimétrica essa confusão é ainda maior, com um acerto de apenas 20%. Mesmo apresentando uma melhora quando conduzida pelo classificador Maxver, com acerto próximo a 43%, o resultado ainda não é confiável para essa classe em específico. Além das matrizes de confusão e da exatidão global, a incerteza média por classe, obtida a partir dos dados de incerteza calculados para cada *pixel* dos mapas de mudança obtidos por classificação direta, apresentados na Tabela 5.8, também são utilizados como forma de validação dos resultados.

Tabela 5.8 – Incerteza média das classes na detecção de mudanças por classificação direta.

Classe	Maxver		SVM		
	FQ06 + EO-1 ALI	FQ13 + EO-1 ALI	FQ06 + EO-1 ALI	FQ13 + EO-1 ALI	FQ06/FD + EO-1 ALI
AG_AG	0,05	0,06	0,02	0,01	0,04
AG_SS1	0,09	0,09	0,10	0,09	0,15
BS_AG	0,02	0,02	0,02	0,03	0,02
BS_BS	0,01	0,01	0,03	0,05	0,21
CP_CP	0,10	0,10	0,19	0,18	0,24
CP_DP	0,07	0,08	0,10	0,09	0,11
CP_SS1	0,11	0,10	0,23	0,15	0,25
DP_DP	0,12	0,12	0,21	0,21	0,24
DP_SS1	0,13	0,13	0,18	0,19	0,27
IS_IS	0,11	0,11	0,24	0,25	0,25
MF_MF	0,04	0,04	0,11	0,11	0,22
SS1_SS2	0,09	0,09	0,22	0,18	0,31
SS2_SS2	0,11	0,10	0,17	0,17	0,26
WAT_WAT	0,01	0,01	0,38	0,29	0,09

Os valores de incerteza média das classes nos mapas de mudança obtidos por classificação direta nos permitem primeiramente comparar o desempenho dos

dois classificadores utilizados na detecção de mudança por classificação direta. Assim, como para as incertezas médias por classe já apresentadas para as classificações individuais e para a detecção de mudança por comparação pós-classificação, o classificador Maxver apresentou valores de incerteza inferiores aos obtidos pelo classificador SVM. Essa disparidade entre as incertezas também pode ser constatada através dos mapas de incerteza apresentados, uma vez que todos aqueles associados a classificações SVM se mostram visivelmente mais amarelos que os mapas de incerteza associados a classificações Maxver. No entanto, essa diferença não ocorreu para todas as classes. Classes como Agricultura- Sucessão Secundária Inicial (AG-SS1) e Solo Exposto - Solo Exposto (BS-BS) apresentam valores de incerteza médios muito próximos para ambos os classificadores enquanto a classe Agricultura – Agricultura (AG-AG) apresenta incerteza média extremamente menor para o classificador SVM.

Os resultados apresentados também permitem uma comparação entre os mapas de mudança obtidos pela detecção de mudanças por classificação direta e pela detecção de mudança por comparação pós-classificação com base na informação de incerteza. Assim como para os valores de exatidão global, a informação de incerteza também demonstra a diferença expressiva entre os dois métodos quando aplicados a dados multissensor SAR e óptico. Enquanto os valores máximos de incerteza média por classe não passam de 0,13 para a classificação direta com o uso do classificador Maxver, a incerteza média por classe ultrapassa 0,50 com o uso do mesmo classificador Maxver. E mesmo para o classificador SVM que apresenta uma alta incerteza para a classe de não mudança (WAT-WAT) na classificação direta a diferença em relação aos mapas de mudança obtidos por comparação pós-classificação ainda é extremamente significativa.

Após a obtenção de todos os resultados apresentados, os mapas de mudança mais acurados foram selecionados como etapa final do estudo. Essa seleção baseou-se nos valores de exatidão global apresentados e ocorreu tanto para o

método por comparação pós-classificação quanto para o método por classificação direta, observando o desempenho dos diferentes classificadores utilizados. Para a detecção de mudança por comparação pós-classificação, o conjunto composto pelas classificações dos canais HH, $(HV+VH)/2$, VV da imagem Radarsat-2 em modo FQ13 e das 9 bandas da imagem EO-1 ALI através do classificador SVM é considerado o mais acurado, com uma exatidão global de 0,268. Para a detecção de mudanças por classificação direta, o mapa de mudanças mais acurado foi gerado através da classificação em única etapa do conjunto composto pelo canal $(HV+VH)/2$ da imagem Radarsat-2 em modo FQ06 e das bandas 3, 6, 7, 9 da imagem EO-1 ALI através do classificador Maxver, com exatidão global de 0,836.

Buscando destacar as mudanças ocorridas na área de estudo, os melhores mapas de mudanças finais são apresentados nas Figuras 5.34-a e 5.35-a, considerando as 8 classes de não mudança como uma única classe chamada não mudança. As informações de incerteza associadas a cada um desses mapas de mudanças também são apresentadas (Figuras 5.34-b e 5.35-b). As matrizes de confusão desses dois conjuntos são rerepresentadas, contendo todas as não mudanças como uma única classe, na Figura 5.36. No entanto novos indicadores de exatidão não são calculados, pois a não consideração dos erros ocorridos entre diferentes classes de não mudança elevariam esses índices equivocadamente.

Figura 5.34 – a) Mapa de detecção de mudanças entre os anos de 2009 e 2013 por comparação pós-classificação com maior valor de exatidão global, obtido através do classificador SVM para os conjuntos de dados FQ13, canais HH, (HV+VH)/2, VV, e EO-1 ALI com 9 bandas e b) incerteza da detecção de mudança.

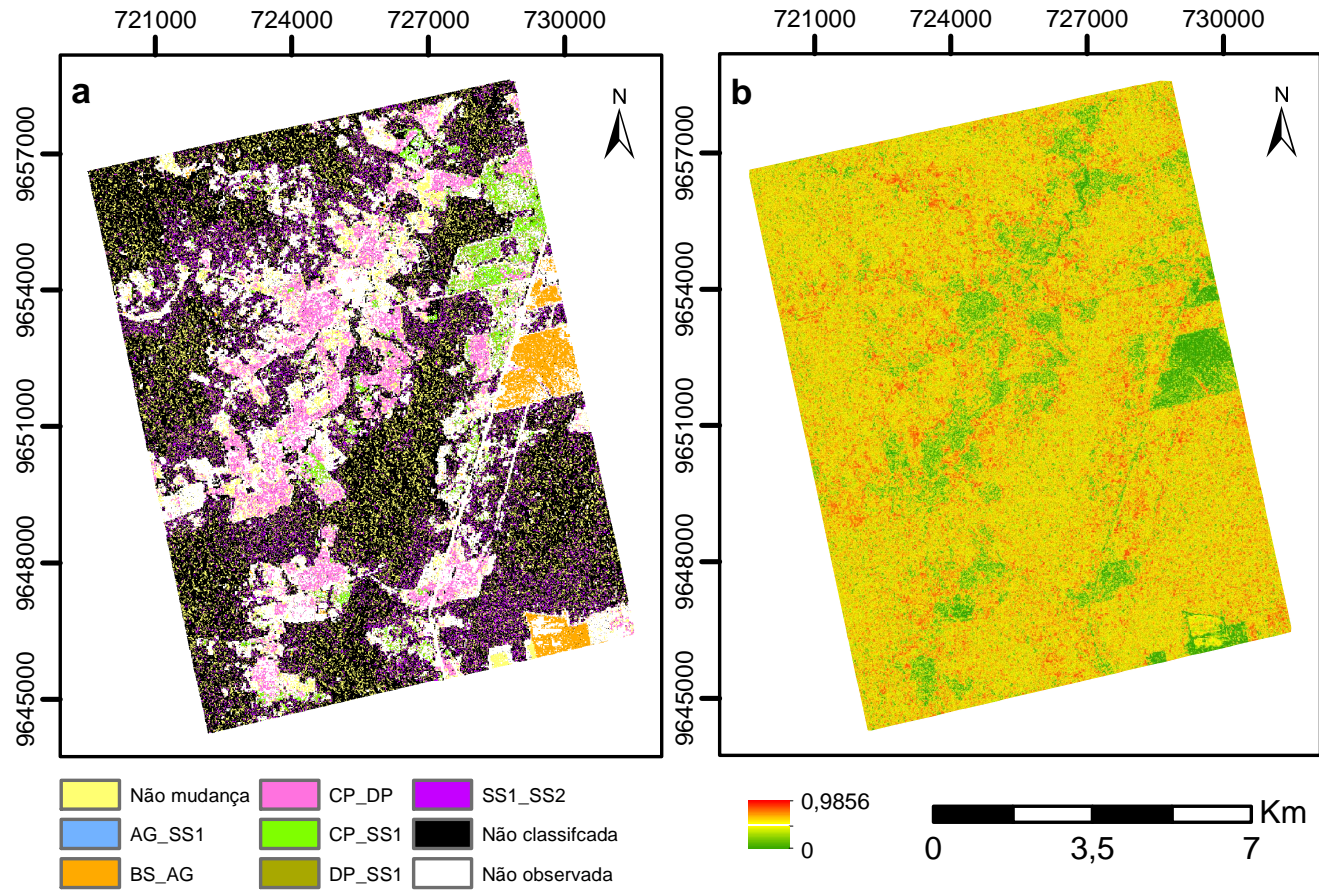


Figura 5.35 – a) Mapa de detecção de mudanças entre os anos de 2009 e 2013 por classificação direta com maior valor de exatidão global, obtido através do classificador Maxver, para os conjuntos de dados FQ06, canal (HV+VH)/2 e EO-1 ALL, bandas 3,6,7,9 e b) incerteza da detecção de mudança.

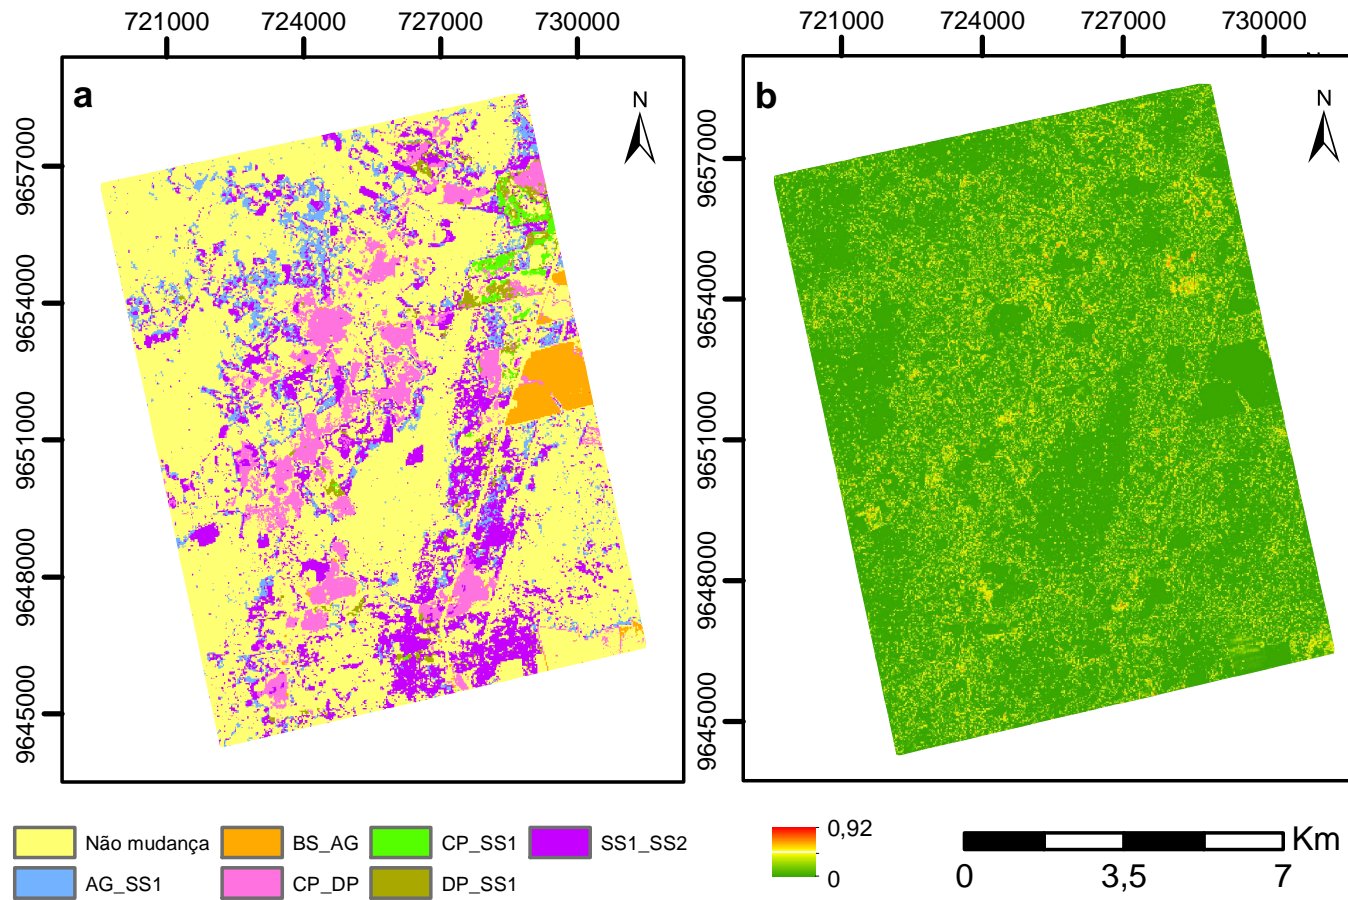

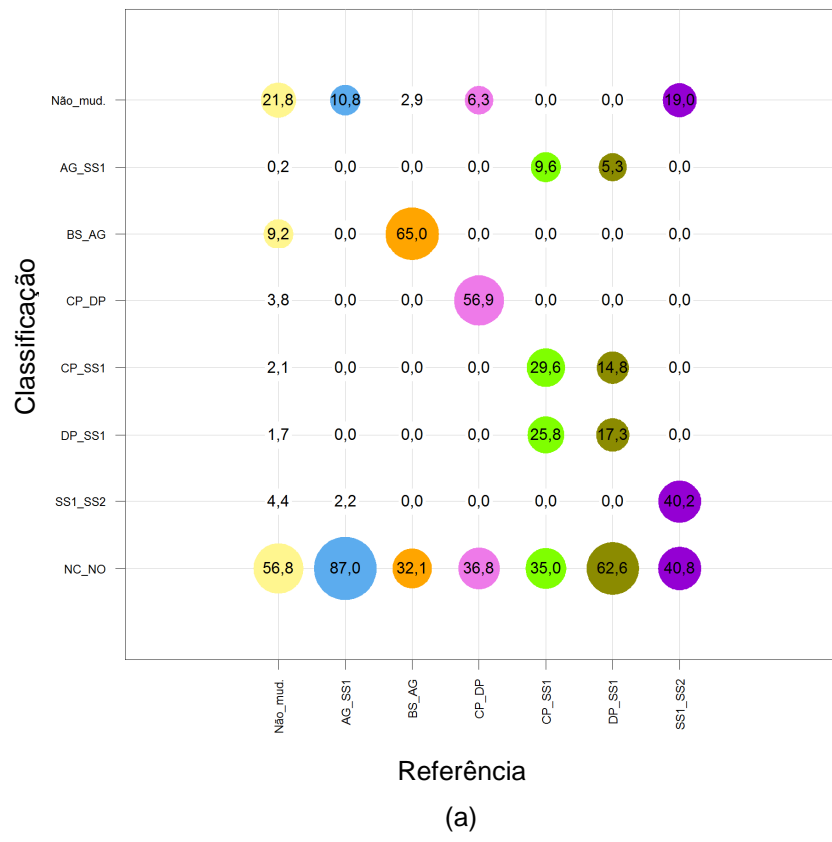


Figura 5.36 – Matrizes de confusão dos mapas de mudanças entre os anos de 2009 e 2013 com maiores valores de exatidão gerados por a) comparação pós-classificação, a partir do classificador SVM, para os conjuntos de dados FQ13, canais HH,(HV+VH)/2, VV, e EO-1 ALI com 9 bandas e b) classificação direta, a partir do classificador Maxver, para os conjuntos de dados FQ06, canal (HV+VH)/2 e EO-1 ALI, bandas 3,6,7,9.



Os melhores resultados obtidos para cada um dos métodos utilizados mostram uma enorme diferença entre a separabilidade das classes de mudança e a acurácia obtidos pela detecção de mudanças por comparação pós-classificação e por classificação direta. O mesmo ocorre para as incertezas médias das classes, que são consideravelmente menores para os mapas obtidos por detecção de mudança por classificação direta. No entanto, vale ressaltar que os bons resultados obtidos pela classificação direta estão associados ao conjunto de dados amostrais utilizados no processo, e que esses dados se referem apenas as classes de mudança e não mudança encontradas em campo. Dessa forma, a comprovação de que essas classes eram de fato as classes existentes na região no intervalo estudo se fez necessária.

Para mostrar a representatividade das classes adotadas no estudo, mapas de cobertura da terra, para os anos de 2009 e 2013, foram gerados a partir das informações do mapa de mudança mais acurado obtido através da detecção de mudança por classificação direta. Esse processo se baseia na inferência de uma classe para cada *pixel* em cada um dos mapas. Para o mapa de cobertura da terra do ano de 2009 cada *pixel* recebeu como rótulo a parte inicial do nome da classe à qual pertencia no mapa de mudanças. Para o mapa de cobertura da terra do ano de 2013 cada *pixel* recebeu como rótulo a parte final do nome da classe à qual pertencia no mapa de mudanças.

Esses mapas de cobertura são apresentados na Figura 5.37 e suas validações foram realizadas de forma independente com base nas amostras de validação para os anos de 2009 e 2013 já apresentadas na Tabela 4.1. A metodologia de validação destes mapas de cobertura da terra foi a mesma realizada para a validação de todas as classificações aqui apresentadas. Os valores de exatidão global média para os mapas de cobertura da terra de 2009 e 2013 foram de 0,742 e 0,824, respectivamente. As matrizes de confusão associadas a esses mapas são apresentadas na Figura 5.38, nas quais informações referentes à separabilidade das 9 classes de cobertura da terra para os anos de 2009 e 2013 podem ser obtidas.

Figura 5.37 – Mapas de cobertura da terra para os anos de a) 2009 ($E_g = 0,742$; $\sigma = 0,013$) e b) 2013 ($E_g = 0,824$; $\sigma = 0,007$), obtidos a partir da inferência de classes de cobertura com base no mapa de detecção de mudanças por classificação direta, pelo classificador Maxver, para os conjuntos de dados FQ06, canal (HV+VH)/2 e EO-1 ALI, bandas 3,6,7,9.

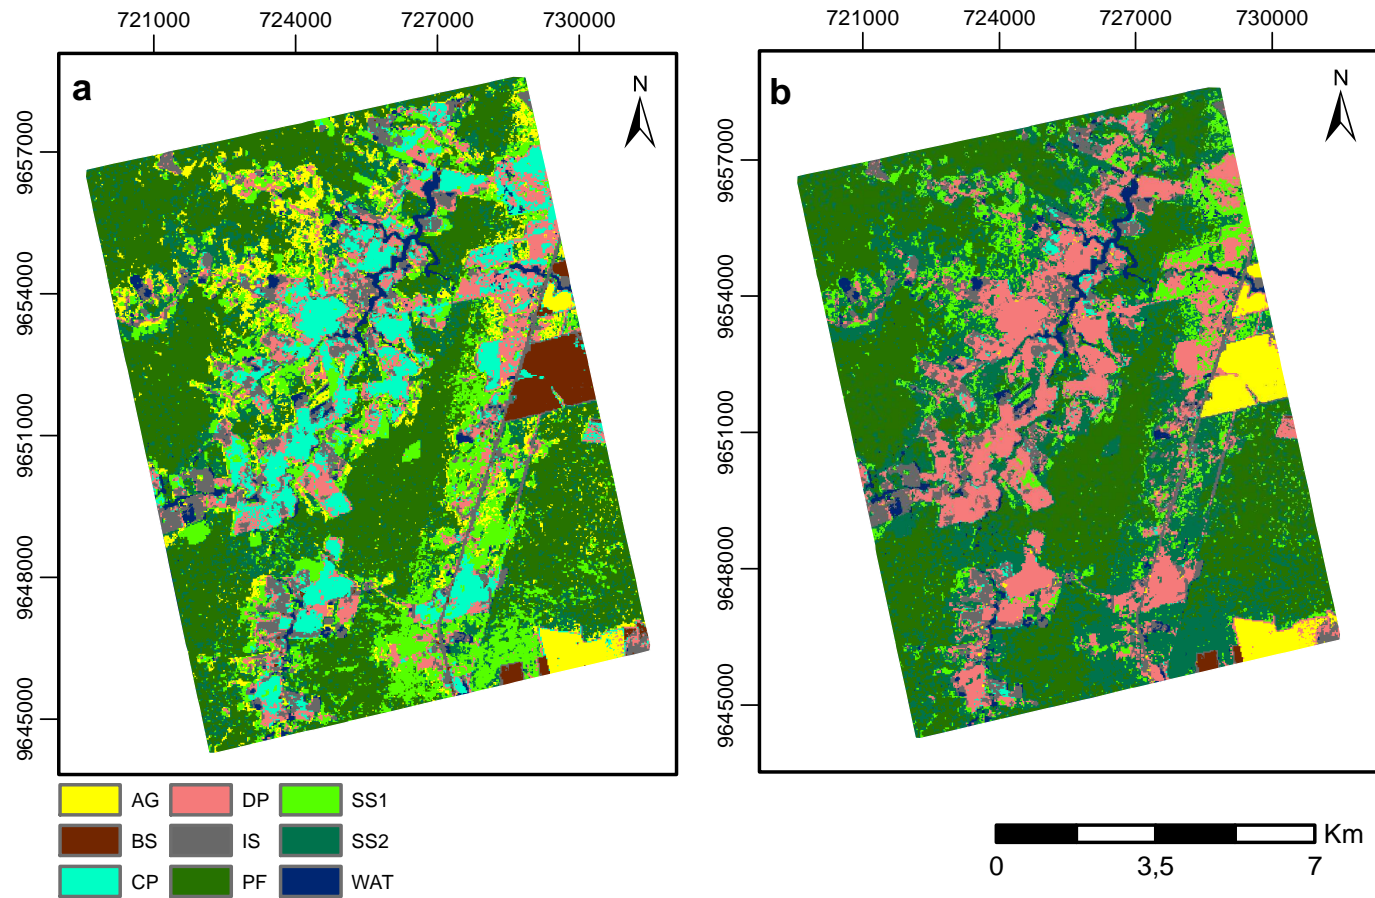



Figura 5.38 – Matrizes de confusão dos mapas de cobertura da terra para os anos de a) 2009 e b) 2013, obtidos a partir da inferência de classes de cobertura com base no mapa de detecção de mudanças por classificação direta, pelo classificador Maxver, para os conjuntos de dados FQ06, canal (HV+VH)/2 e EO-1 ALI, bandas 3,6,7,9.



Os valores de exatidão global de 0,742 para o mapa de 2009 e de 0,824 para o mapa de 2013 implicam que as 14 classes de mudança e não mudança utilizadas no processo de detecção de mudanças foram capazes de gerar classificações consistentes para 2009 e 2013. Também é interessante observar que o mapa de mudança apresenta uma exatidão global mais elevada do que as exatidões globais dos mapas de cobertura da terra para os anos de 2009 e 2013, o que pode indicar a importância da correlação espacial existente entre duas imagens de uma mesma região, mesmo que em diferentes datas, na melhora da acurácia. Outra observação de extrema importância vem da comparação do mapa de cobertura da terra para o ano de 2009 obtido através da informação de mudança com os resultados obtidos pelas classificações individuais dos dados SAR de 2009. Enquanto o mapa gerado a partir das informações de mudança apresenta uma exatidão global de 0,742 a melhor classificação dos dados SAR, dentre todas as realizadas neste estudo, alcança uma exatidão global de apenas 0,296.

Comparando estes dados percebe-se que o resultado da classificação da cobertura da terra obtido a partir de uma detecção de mudança acurada apresenta um grande potencial para uma possível superação dos problemas de classificações de dados SAR podendo fornecer como resultado uma classificação muito melhor.

6 CONSIDERAÇÕES FINAIS

6.1. Conclusões

Os resultados obtidos pelo estudo mostram o potencial do uso de dados multissensor SAR em banda C e óptico EO-1 ALI para detecção de mudanças em áreas de floresta. Dentre os métodos utilizados, a classificação direta se destaca por apresentar, para todos os conjuntos de dados, uma alta separabilidade das classes de mudanças e não mudanças existentes na área de estudo e no intervalo analisado. Dessa forma, é possível afirmar que dados SAR podem sim ser utilizados na detecção de mudanças em regiões de floresta, produzindo resultados acurados. É preciso destacar, no entanto, que esses bons resultados foram obtidos através do uso de dados SAR e ópticos em abordagens multissensor. Mas ainda assim, os resultados obtidos neste trabalho podem ser considerados como um passo na superação do problema da disponibilidade de dados recorrente em regiões de florestas tropicais, principalmente quando existe a necessidade de obtenção de informação de forma imediata.

Considerando os resultados obtidos, o uso da detecção de mudança por classificação direta em estudos que envolvam dados multissensor SAR e óptico é indicado sempre que possível. A validação das classes de mudança e não mudança utilizadas neste tipo de estudo, até hoje pouco explorada, também é indicada. Isso porque mudanças consideradas possíveis podem não ocorrer de fato para o intervalo estudado. Para tanto, a abordagem proposta neste estudo, baseada na obtenção de mapas de cobertura da terra a partir dos resultados da detecção de mudança por classificação direta, que se mostrou capaz de agregar confiabilidade às classes utilizadas, também é indicada.

Quando amostras de mudança e não mudança não estão disponíveis, o método de comparação pós-classificação acaba sendo escolhido, mesmo não sendo o ideal. Nessas situações a busca de técnicas que aumentem a precisão de classificações de cobertura da terra a partir de dados SAR em banda C

deve ser fortemente perseguida para que um aumento na exatidão das mudanças possa ser observado. Também é importante ressaltar que a comparação pós-classificação cria classes de mudança e não mudança que podem não ter ocorrido de fato. Assim, estudos que envolvam esta técnica devem ser acompanhados por um especialista capaz de agrupar as potenciais classes de mudanças entre possíveis, impossíveis e improváveis para a área e o intervalo de tempo do estudo. Isso possibilitará a obtenção de índices de exatidão global baseados em matriz não quadradas, como o realizado neste trabalho, o que fará com que os valores de exatidão global obtidos sejam mais próximos da realidade e os mapas de mudança gerados sejam comparáveis aos obtidos por outros métodos de detecção de mudanças.

Apesar da classificação da cobertura da terra ter se mostrado superior quando realizada a partir do modo FQ06 o mesmo não se comprovou para a detecção de mudanças. A utilização das decomposições polarimétricas de Cloude e Pottier e de Freeman e Durden também não apresentaram melhora significativa nos mapas de mudanças. Assim, podemos concluir que para esse estudo, nesta área de estudo e no intervalo adotado o fator de maior interferência no resultado final foi a escolha do método de detecção de mudanças.

6.2. Trabalhos futuros

Como trabalhos futuros recomenda-se a primeiramente a busca da melhora das classificações SAR como tentativa de melhorar a detecção de mudanças por comparação pós-classificação. Testes realizados com o classificador Maxver baseado em distribuições Wishart para dados polarimétricos apresentaram uma melhora nos resultados das classificações SAR individuais, no entanto a significância dessa melhora na detecção de mudanças por comparação pós-classificação multissensor envolvendo dados SAR e ópticos ainda não foi analisada. A possibilidade de se trabalhar com diferentes segmentações para os dados ópticos e SAR, gerando classificações por região e uma posterior comparação pixel a pixel também deve ser observada na busca de melhores resultados para detecção de mudanças por comparação

pós-classificação. Já a busca por uma segmentação capaz de ser utilizada tanto para os dados ópticos quanto para os dados SAR, poderá possibilitar a utilização de classificações por região tanto na detecção de mudanças por comparação pós-classificação quanto na detecção de mudanças por classificação direta e por essa razão é aconselhada como forma de se aprofundar nas diferentes possibilidades de obtenção de mapas de mudança.

Outra sugestão para trabalhos futuros é a busca por formas de determinar limiares de exatidão global a partir dos quais a representatividade do conjunto de amostras de mudança/não mudança utilizado seja aceita, o que ainda não foi tratado. Finalmente, e com maior ênfase indica-se examinar a potencialidade do uso da detecção de mudanças multissensor por classificação direta na melhora das classificações da cobertura da terra para datas em que apenas dados SAR estejam disponíveis. Para tanto, indica-se o uso de dados ópticos de qualidade para uma das datas e a correta qualificação das classes de mudança/não mudança entre possíveis, impossíveis e improváveis para a área e o intervalo do estudo. Assim, espera-se determinar se os excelentes resultados obtidos neste trabalho para a cobertura da terra do ano de 2009, no qual apenas dados SAR em banda C estavam disponíveis, podem ser replicados para diferentes tipos de dados SAR, com diferentes comprimentos de onda e ainda para diferentes áreas de estudo com diferentes conjuntos de classes de interesse.

REFERÊNCIAS BIBLIOGRÁFICAS

ADAMS, J.B.; SABOL, D.E.; KAPOS, V.; FILHO, R.A.; ROBERTS, D.A.; SMITH, M.O.; GILLESPIE, A.R. Classification of multispectral images based on fractions of endmembers: application to land-cover change in the Brazilian Amazon. **Remote Sensing of Environment**, v. 52, p. 137-154, 1995.

ALBA, J. M.F.; SCHRODER, V. F.; NOBREGA, M. R. R. Land cover change detection in southern Brazil through orbital imagery classification methods. In: RAMIREZ, B.E. (Ed). **Remote Sensing: Applications**. Intech, 2012. p. 99-116.

ALBERGA, V. Similarity measures of remotely sensed multisensor images for change detection Applications. **Remote Sensing**, v. 1, p. 122-143, 2009.

ALMUTAIRI, A.; WARNER, T. Change detection accuracy and image properties: A study using simulated data. **Remote Sensing**, v.2, p. 1508-1529, 2010.

ALVES, D. S. Cenários de cobertura e uso da terra e dimensões humanas no LBA. In: COSTA, W. M.; BECKER, B. K.; ALVES, D. S. (Ed.). **Dimensões Humanas da Biosfera-Atmosfera da Amazônia**, São Paulo:EDUSP, 2007. p. 39-64.

ALVES, D. B.; PÉREZ-CABELLO, F.; MIMBRE, M., R. Land use and land cover dynamics monitored by NDVI multitemporal analysis in a selected southern Amazonian area (Brazil) for the last three decades, **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 40, n. 7, p. 329-335, 2015.

AGÊNCIA NACIONAL DE ÁGUAS (ANA). **Sistema de informações hidrológicas**: HidroWeb. 2013. Disponível em: <<http://hidroweb.ana.gov.br/>>. Acesso em: 11 fev. 2016.

ANJOS, D. S.; LU, D.; DUTRA, L. V.; SANT'ANNA, S.J.S. Change Detection Techniques Using Multisensor Data. In: THENKABAIL, P.S (Ed). **Remotely Sensed Data Characterization, Classification, and Accuracies**. London: crc press, 2015. v. 1, p. 375-395.

BAKER, C.; LAWRENCE, R.; MONTAGNE, C.; PATTEN, D. Change detection of wetland ecosystems using Landsat imagery and change vector analysis. **Wetlands**, v. 27, p. 610-619, 2007.

BECKER, B. **Amazônia**. São Paulo: Atica, 1991. 112 p. 2 ed.

BHAGAT, V.S. Use of remote sensing techniques for robust digital change detection of land: a review. **Recent Patents on Space Technology**, v. 2, p. 123-144, 2012.

- BICKNELL, W.E.; DIGENIS, C. J.; FORMAN, S. E.; LENCIONI, D. E. EO-1 Advanced Land Imager. In: SPIE CONFERENCE ON EARTH OBSERVING SYSTEMS, 4., 1999, Denver, Colorado. **Proceedings...** Denver: SPIE, 1999.
- BITTENCOURT, H.R. **Detecção de mudanças por imagem fração**. 2011, 103 f. Tese (Doutorado) - Instituto de Geociências, Universidade Federal do Rio Grande do Sul, Porto Alegre. 2011.
- BONTEMPS, S.; LANGNER, A.; DEFOURNY, P. Monitoring forest changes in Borneo on a yearly basis by an object-based change detection algorithm using SPOT- VEGETATION time series. **International Journal of Remote Sensing**, v.33, n. 15, p. 4673-4699, 2012.
- BORGHYS, D., SHIMONI, M., PERNEEL, C. Change detection in urban scenes by fusion of SAR and hyperspectral data. **Proceedings of SPIE, the International Society for Optical Engineering**, v. 6749, p. 27-38, 2007.
- BRISCO, B.; SCHMITT, A.; MURNAGHAN, K.; KAYA, S. ROTH, A. SAR polarimetric change detection for flooded vegetation. **International Journal of Digital Earth**, v. 6 ,n.2 , p. 103-11, 2013.
- BRUZZONE, L.; COSSUA, R.; VERNAZZAB, G. Detection of land-cover transitions by combining multirate classifiers. **Pattern Recognition Letters**, v.25, p.1491-1500, 2004.
- BRUZZONE, L.; BOVOLO, F. Unsupervised change detection in multi-temporal SAR images. In: CHEN, C. H. (Ed.). **Image processing for remote sensing**. London: Taylor and Francis, 2008. p. 107-134.
- BRUZZONE, L.; SERPICO, S. B. An iterative technique for the detection of landcover transitions in multitemporal remote-sensing images. **IEEE Transactions on Geoscience and Remote Sensing**, v.35, p. 858-867, 1997.
- CHATELAIN, F.; TOURNERET, J.Y.; INGLADA, J. Change detection in multisensor SAR images using bivariate gamma distributions. **IEEE Transactions on Image Processing**, v. 17, n. 3, 2008.
- CHEN, G.; HAY, G.J.; CARVALHO, L.M.T.; WULDER, M.A. Object-based change detection. **International Journal of Remote Sensing**, v. 33, p. 4434-4457, 2012.
- CIHLAR, J. Land cover mapping of large areas from satellites: status and research priorities. **International Journal of Remote Sensing**, v. 21, p. 1093-1114, 2000.
- CLOUDE, S. R.; POTTIER, E. A review of target decomposition theorems in radar polarimetry. **IEEE Transactions on Geoscience and Remote Sensing**, v. 34, p. 498-518, 1996.

CLOUDE, S. R.; POTTIER, E. An entropy based classification scheme for land applications of polarimetric SAR. **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, n.1, p. 68-78, 1997.

COLLINS, J. B.; WOODCOCK, C. E. An assessment of several linear change detection techniques for mapping forest mortality using multitemporal Landsat TM data. **Remote Sensing of Environment**, v. 56, p. 66-77, 1996.

CONGALTON, R.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers, 1999. 160 p.

CONGALTON, R.G. Putting the map back in map accuracy assessment. In: LUNETTA, R.L.; LYONS, J.G. (Eds.). **Remote Sensing and GIS Accuracy Assessment**. Las Vegas: U.S. Environmental Protection Agency, 2004. p. 1-11.

COPPIN, P.; NACKAERTS, K.; QUEEN, L.; BREWER, K. Operational monitoring of green biomass change for forest management. **Photogrammetric Engineering and Remote Sensing**, v. 67, p. 603-611, 2001.

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

CORREA, Y.T.S.; BOVOLO, F.; BRUZZONE, L. Change detection in very high-resolution multisensor optical images. In: SPIE IMAGE AND SIGNAL PROCESSING FOR REMOTE SENSING, 20., 2014, October 29, Amsterdam, Netherlands. **Proceedings...** Amsterdam: SPIE, 2014.

DENG, J. S.; WANG, K.; DENG, Y. H.; QI, G. J. PCA-based land-use change detection and analysis using multi-temporal and multisensor satellite data. **International Journal of Remote Sensing**, v.29, p. 4823-4838, 2008.

DESCLEÉ, B.; BOGAERT, P.; DEFOURNY, P. Forest change detection by statistical object-based method. **Remote Sensing of Environment**, v. 102, p. 1-11, 2006.

DI GIROLAMO, P. A. A comparison of change detection methods in an urban environment using Landsat TM and ETM+ satellite imagery: a multi-temporal, multi-spectral analysis of Gwinnett County, GA 1991-2000. **Anthropology Theses**, Paper 18, 2006.

DOBSON, J. E.; BRIGHT, E.A.; FERGUSON, R. L.; FIELD, D. W.; WOOD, L. L.; HADDAD, K. D.; IREDALE III, H.; JENSEN, J. R.; KLEMAS, V. V.; ORTH, R. J.; THOMAS, J. P. **NOAA Coastal change analysis program: guidance for regional implementation**. National Marine Fisheries Service Department of Commerce United States of America, 1995. 97 p. NOAA Technical Report NMFS 123.

DONG, Y.; MILNE, A.K.; FORSTER, B.C. A review of SAR speckle filters: texture restoration and preservation. **IEEE International Geoscience Remote Sensing Symposium**, v.2, p. 633-635, 2000.

DU, P.; LIU, S; GAMBA, P.; TAN K.; XIA J. Fusion of difference images for change detection over urban areas. **IEEE Journal of selected topics in applied Earth Observation and Remote Sensing**, v.5, p. 1076 - 1086, 2012.

DUARTE, V.; MARTINI, P. R.; SHIMABUKURO, Y. E.; FREITAS, R. M.; ARAI, E. Monitoramento de desflorestamento em escala global: uma proposta baseada nos projetos Prodes digital e Deter. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 2007, Florianópolis, Brasil. **Anais...** São José dos Campos: INPE, 2007. p. 6687 - 6694.

ENGESET, R. V.; KOHLER, J.; MELVOLD, K.; LUNDEN, B. Change detection and monitoring of glacier mass balance and facies using ERS SAR winter images over Svalbard. **International Journal of Remote Sensing**, v.23, p. 2023-2050, 2002.

ESCADA, M. I. S.; KAMPEL, S. A.; RENNÓ, C. D.; PINHEIRO, T. F. **Levantamento do uso e cobertura da terra e da rede de infra-estrutura no distrito florestal da BR-163**. Instituto Nacional de Pesquisas Espaciais, Projeto Integrado de Modelagem da Cobertura da Terra no Pará, 2009.

FREEMAN, A.; DURDEN, S.L. A three-component scattering model for polarimetric SAR data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 36, n. 3, p. 963-973, 1998.

FREITAS, C. C.; SANT'ANNA, S. J. S.; RENNÓ, C. D.; CORREA, A. H. **Utilização de imagens de radar de abertura sintética na classificação de uso e ocupação do solo**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2007. Disponível em: <<http://www.dpi.inpe.br/ofigeo.PDF>>. Acesso em: 10 jul. 2013.

FRERY, A.C. **Algumas ferramentas estatísticas na síntese, processamento e análise de imagens de Radar de abertura sintética**. 1993. 244 p. Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1993.

FRERY, A. C.; CORREIA, A. H.; FREITAS, C. C. Classifying multifrequency fully polarimetric imagery with multiple sources of statistical evidence and contextual information. **IEEE Transactions on Geoscience and Remote Sensing**, v.45, p. 3098-3109, 2007.

GLOBAL FOREST OBSERVATION INITIATIVE (GFOI). **Integrating remote-sensing and ground-based observations for estimation of emissions and removals of greenhouse gases in forests: methods and guidance from the global forest observations initiative**. Group on Earth Observations, Geneva, Switzerland, 2014. 164 p. Disponível em:

<http://www.wmo.int/pages/prog/gcos/documents/Mitigation_GFOI_methodology_guidance.pdf >. Acesso em: 10 dez. 2015.

GOODMAN, J. W. Some fundamental properties of speckle. **Journal of the Optical Society of America**, v. 66, n. 11, p. 1145-1150, 1976.

HAACK, B.; BECHDOL, M. Multisensor remote sensing data for land use/cover mapping. **Computers, Environment and Urban Systems**, v. 23, p. 53-69, 1999.

HAERTEL, V.; SHIMABUKURO, Y.E.; ALMEIDA-FILHO, R. Fraction images in multitemporal change detection. **International Journal of Remote Sensing**, v. 25, n.23, p. 5473-5489, 2004.

HANSEN, M.C.; LOVELAND, T.R. A review of large area monitoring of land cover change using Landsat data. **Remote Sensing of Environment**, v. 122, p. 66-74, 2012.

HAYES, D. J.; SADER, S. A. Comparison of change detection techniques for monitoring tropical forest clearing and vegetation regrowth in a time series. **Photogrammetric Engineering and Remote Sensing**, v. 67, p. 1067-1075, 2001.

HOUHOULIS, P.F.; MICHENER, W.K. Detecting Wetland Change: A Rule-Based Approach Using NWI and SPOT-XS Data, **Photogrammetric Engineering & Remote Sensing**, v. 66, n. 2, p. 205-211, 2000.

HUANG, C.; GOWARD, S. N.; MASEK, J. G.; THOMAS, N.; ZHU, Z.; VOGELMANN, J. E. An automated approach for reconstructing recent forest disturbance history using dense Landsat time series stacks. **Remote Sensing of Environment**, v. 114, p. 183-198, 2010.

HUSSAIN, M.; CHEN, D.; CHENG, A.; WEI, H.; STANLEY, D. Change detection from remotely sensed images: from *pixel*-based to object-based approaches. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 80, p. 91-106, 2013.

INSTITUTO BRASILEIRO DO MEIO AMBIENTE E DOS RECURSOS NATURAIS RENOVÁVEIS (IBAMA). **Floresta Nacional do Tapajós plano de manejo**: volume I informações gerais. Brasília: IBAMA, 2004. Disponível em: <http://www.icmbio.gov.br/portal/images/stories/imgs-unidades-coservacao/flona_tapajoss.pdf>. Acesso em: 13 fev. 2013.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Detecção de áreas desflorestadas em tempo real (projeto deter) para os anos de 2005 e 2006**. São José dos Campos, 2007. 69 p. Disponível em: <http://www.dsr.inpe.br/laf/panamazonia/arquivos/Yosio_et_al_Relatorio_Completo_DETER_INPE_2008.pdf> Acesso em: 15 jul. 2012.

_____. **Monitoramento da cobertura florestal da Amazônia por satélites:** sistema de detecção do desmatamento em tempo real na Amazônia - DETER: aspectos gerais, metodológicos e plano de desenvolvimento. São José dos Campos, 2008a. 16 p. Disponível em: <http://www.obt.inpe.br/deter/metodologia_v2.pdf>. Acesso em: 22 out. 2015.

_____. **Monitoramento da cobertura florestal da Amazônia por satélites:** sistemas PRODES, DETER, DEGRAD E QUEIMADAS 2007-2008. São José dos Campos, 2008b. 47p. Disponível em: <http://www.obt.inpe.br/prodes/Relatorio_Prodes2008.pdf>. Acesso em: 07 de maio de 2012.

_____. **Mapeamento da degradação florestal na Amazônia brasileira DEGRAD.** São José dos Campos, 2010. [on line]. Disponível em: <<http://www.obt.inpe.br/degrad/>>. Acesso em: 22 out. 2015.

_____. **Metodologia para o cálculo da taxa anual de desmatamento na Amazônia Legal.** São José dos Campos, 2013. 37p. Disponível em <http://www.obt.inpe.br/prodes/metodologia_TaxaProdes.pdf>. Acesso em: 21 jan.2016.

_____. **Projeto PRODES** - divulgação da taxa estimada do desmatamento da Amazônia Legal para período ago./2014-jul./2015. São José dos Campos, 2015a. 14p. Disponível em: <http://www.obt.inpe.br/prodes/Prodes_Taxa2015_estimativa.pdf>. Acesso em: 22 mar 2016.

_____. **Projeto PRODES** - divulgação da taxa consolidada do desmatamento da Amazônia Legal para período ago./2013-jul./2014. São José dos Campos, 2015b. 14p. Disponível em: <http://www.obt.inpe.br/prodes/Prodes_Taxa2014.pdf>. Acesso em: 22 out 2015.

JENSEN, J.R. **Sensoriamento remoto do ambiente:** uma perspectiva em recursos terrestres. Tradução de J.C.N. Epiphanyo Sao Jose dos Campos, SP: Parentese, 598p. 2009. (Prentice Hall Series IN Geographic Information Science) Tradução de: Remote sensing of the environment: an earth resource perspective. 2009.

KENNEDY, R.E.; TOWNSEND, P.A.; GROSS, J.E. , COHEN, W.B.; BOLSTAD, P.; WANG, Y.Q.; ADAMS, P. Remote sensing change detection tools for natural resource managers: understanding concepts and tradeoffs in the design of landscape monitoring projects. **Remote Sensing of Environment**, v. 113, p. 1382-1396, 2009.

KIEL, R. **Detecção de mudanças no uso e cobertura do solo em uma série temporal de imagens da região da Campanha no Rio Grande do Sul.** 2008. 203 f. Dissertação (Mestrado) - Centro Estadual de Pesquisa em

Sensoriamento Remoto e Meteorologia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2008.

KINTISCH, E. Improved Monitoring of Rainforests Helps Pierce Haze of Deforestation. **Science**, v.316, p. 536-537, 2007.

LAMBIN, E.; GEIST, H. **Land-use and land-cover change**: local processes and global impacts. Berlin: Springer, 2006. 240 p.

LEE J.; POTTIER, E. **Polarimetric radar imaging from basics to applications**. New York: CRC Press, 2009.

LEFSKY, M. A.; COHEN, W. B. Selection of remotely sensed data. In: WULDER; M.A; FRANKLIN, S.E. (Eds.). **Remote sensing of forest environments**: concepts and case studies. Boston: Kluwer, p. 13-46, 2003.

LEWIS, A.; HENDERSON, F. Radar fundamentals: the geosciences perspective. In: HENDERSON, F.; LEWIS, A. (Eds.). **Manual of remote sensing**: principles and applications of imaging radar. 3. ed. New York: Wiley, 1998. v. 3. 896 p.

LILLESAND, T. M., KIEFER, R. W. **Remote sensing and image interpretation**. New York, Chichester, Brisbane, Toronto, Singapore: John Wiley & Sons, 1994. 3rd ed. xvi + 750 pp. ISBN 0 471 30575 8 (pb).

LILLESTRAND, R.L. Techniques for change detection. **IEEE Transactions Computers**, C-21, p. 654-659, 1972.

LIU, D.; SONG, K.; TOWNSHEND, J.R.G.; GONG, P. Using local transition probability models in Markov random fields for forest change detection. **Remote Sensing of Environment**, v.112, n. 5, p. 2222-2231, 2008.

LO, C.P.; SHIPMAN, R.L. A GIS approach to land-use change dynamics detection. **Photogrammetric Engineering & Remote Sensing**, v. 56, p. 1483-1491, 1990.

LU, D.; MAUSEL, P.; BRONDIZIO, E.; MORAN, E. Change detection techniques. **International Journal of Remote Sensing**, v. 25, p. 2365-2401, 2004a.

LU, D.; MAUSEL, P.; BATISTELLA; M., MORAN; E. Comparison of land-cover classification methods in the Brazilian Amazon basin. **Photogrammetric Engineering and Remote Sensing**, v. 70, p. 723-731, 2004b.

LU, D.; BATISTELLA, M.; MORAN, E. Integration of Landsat TM and SPOT HRG images for vegetation change detection in the Brazilian Amazon. **Photogrammetric Engineering and Remote Sensing**, v.74, p.421-430, 2008.

LU, D.; HETRICK, S.; MORAN, E.; LI, G. Detection of urban expansion in an urban-rural landscape with multitemporal QuickBird images. **Journal of Applied Remote Sensing**, v. 4, 2010.

LU, D.; MORAN, E.; HETRICK, S.; LI, G. Land-use and land-cover change detection. In: WENG, Q. (Ed.). **Advances in environmental remote sensing sensors, algorithms, and applications**. New York : CRC Press Taylor & Francis Group, p. 273-290, 2011.

LU, D., LI, G.; MORAN, E.; HETRICK, S. Spatiotemporal analysis of land-use and land-cover change in the Brazilian Amazon. **International Journal of Remote Sensing**, v. 34 , n. 16, p. 5953-5978, 2013a.

LU, D.; LI, G.; MORAN, E.; HETRICK, S. Vegetation change detection in the Brazilian Amazon with multitemporal Landsat images. In: WANG, G.; WENG, Q. (eds.). **Remote sensing of natural resources**. Boca Raton, FL: CRC Press/Taylor and Francis, p. 127-140, 2013b.

LU, D.; LI, G.; MORAN, E. Current situation and needs of change detection techniques. **International Journal of Image and Data Fusion**, v. 5, n. 1, p. 13-38, 2014.

LUI, G. V.; COOMES, D. A. A comparison of novel optical remote sensing-based technologies for forest-cover/change monitoring. **Remote Sensing**, v. 7, p. 2781-2807, 2015.

LUNETTA, R.S.; KNIGHT, J.F.; EDIRIWICKREMA, J.; LYON, J.G.; WORTHY, L.D. Land-cover change detection using multi-temporal MODIS NDVI data. **Remote Sensing of Environment**, v. 105, n. 2, p. 142-154, 2006.

MANDANICI, E.; BITELLI, G. Multi-image and multi-sensor change detection for long-term monitoring of arid environments with Landsat series. **Remote Sensing**, v.7, p. 14019-14038, 2015.

MANSOURPOUR, M.; RAJABI, M.A.; BLAIS, J.A.R. Effects and performance of speckle noise reduction filters on active radar and SAR images, In: WORKSHOP ON TOPOGRAPHIC MAPPING FROM SPACE, 3006, Feb, 14-16, Ankara, Turkey. **Proceedings...** Ankara: ISPRS, 2006.

MAS, J. F. Monitoring land-cover change: a comparison of change detection techniques. **International Journal of Remote Sensing**, v. 20, p. 139-152, 1999.

MISHRA, B.; SUSAKI, J. Optical and SAR data integration for automatic change pattern detection. **ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 2, n.7, p. 39-46, 2014.

MYERS, N. Tropical forests: much more than stocks of wood. **Journal of Tropical Ecology**, v. 4, p. 209-221, 1988.

NASCIMENTO Jr., W.R.; SOUZA-FILHO, P.W.M.; PROISY, C.; LUCAS, R.M.; ROSENQVIST, A. Mapping changes in the largest continuous Amazonian mangrove belt using object-based classification of multisensor satellite imagery. **Estuarine, Coastal and Shelf Science**, v. 117, p. 83-93, 2013.

NEGRI, R. G. **Avaliação de dados polarimétricos do sensor ALOS PALSAR para classificação da cobertura da terra da Amazônia**. 2009. 170 p. Dissertação (Mestrado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009. Disponível em: <<http://urlib.net/8JMKD3MGP8W/35AKRR5>>. Acesso em: 06 abr. 2016.

NEGRI, R. G. **Máquina de vetores de suporte adaptativa ao contexto: formalização e aplicações em sensoriamento remoto**. 2013. 140 p. Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3EEEGJP>>. Acesso em: 06 abr. 2016.

OLIVEIRA, M. A. F.; ALBUQUERQUE, P. C. G.; SANTANNA, S. J. S.; DUTRA, L. V.; ANJOS, D. S.; COSTA, G. A. O. P. Avaliação do padrão de exatidão cartográfica de imagens Quickbird e RapidEye em uma área do Tapajós, Pará. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 17, 2015, João Pessoa, Paraíba. **Anais...** São José dos Campos: INPE, 2015. p. 7545-7552.

OLIVER, C.; QUEGAN, S. **Understanding synthetic aperture radar images**. Raleigh: Scitech Publishing, 2004. 479 p.

ORSOMANDO, F.; LOMBARDO, P.; ZAVAGLI, M.; CONSTANTINI, M. SAR and optical data fusion for change detection. In: URBAN REMOTE SENSING JOINT EVENT, 2007, Paris, França. **Proceedings...** Paris, 2007. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4234369&isnumber=4234359>>. Acesso em: 10 de fev. 2013.

PANDA, S. S.; RAO, M. N.; THENKABAIL, P.S.; FITZGERALD, J.E. Remote Sensing Systems - Platforms and Sensors: Aerial, Satellite, UAV, Optical, Radar, and LiDAR. In: THENKABAIL, P.S. (Ed). **Remotely sensed data characterization, classification, and accuracies**. London: crc press, v. 1, p. 3-57. 2015.

PAOLO, V. Change detection techniques. **Laboratorio di Geomatica Politecnico Di Milano**. 2012. Disponível em: <http://geomatica.como.polimi.it/corsi/rs_ia/remote_sensing_como_l13_change_detection_techniques.pdf>. Acesso em: 13 ago. 2012.

PEREIRA, L. O.; SILVA, A. E. P.; NEGRI, R. G.; SANT'ANNA, S. J. S.; DUTRA, L. V.; FREITAS, C. C.; ERTHAL, G.J. Análise comparativa dos métodos de classificação SVM e Maxver-ICM Polarimétrico em imagem de radar ALOS PALSAR. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO

(SBSR), 15, 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011. p. 8223-8230.

PEREIRA, L.O. **Avaliação de métodos de integração de imagens ópticas e de radar para a classificação do uso e cobertura da terra na região Amazônica.** 2012. 236p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2012. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3CHCSD5>>. Acesso em: 06 abr. 2016.

PEREIRA, L.O.; FREITAS, C.C; SANT'ANNA, S.J.S.; LU, D.; MORAN, E.F. Optical and radar data integration for land use and land cover mapping in the Brazilian Amazon. **GIScience Remote Sensing**, v. 50, n. 3, p. 301-321, 2013.

PILLAY, K. **Land use change detection of small scale sugarcane: a case study of Umbumbulu, South Africa.** 2009.58p. Dissertação (Mestrado) - Centre for Environment, Agriculture and Development School of Environmental Sciences. University of KwaZulu, Pietermaritzburg, 2009.

RADKE, R. J.; ANDRA, S.; AL-KOFAHI, O.; ROYSAM, B. Image change detection algorithms: a systematic survey. **IEEE Transactions Image Process.**, v. 14, p. 294-307, 2005.

RANEY, R. Radar fundamentals: technical perspective. In: HENDERSON, F.; LEWIS, A. (Ed.). **Manual of remote sensing: principles and applications of imaging radar.** 3. ed. New York: Wiley, 1998. v. 3. 896

REICHE, J.; SOUZA, C. M.; HOEKMAN, D. H.; VERBESSELT, J.; PERSAUD, H.; HEROLD, M. Feature Level Fusion of Multi-Temporal ALOS PALSAR and Landsat Data for Mapping and Monitoring of Tropical Deforestation and Forest Degradation. **IEEE Journal of Selected Topics In Applied Earth Observations And Remote Sensing**, v. 6, p. 2159 - 2173, 2013.

REIS, M. S. **Detecção de mudanças de uso e cobertura da terra utilizando dados ópticos e de micro-ondas em uma região da Amazônia brasileira.** 2014. 331 p. (sid.inpe.br/mtc-m21b/2014/06.30.19.09-TDI). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2014. Disponível em: <<http://urlib.net/8JMKD3MGP5W34M/3GJ7LFB>>. Acesso em: 27 out. 2015.

REIS, M. S.; SANT'ANNA, S. J. S; Analysis of binary land cover change detection methods using optical and radar data. In: GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, (IGARSS), 2015, Milan. **Proceedings...** IEEE International, 2015. p.4236-4239.

RIBEIRO, J.C.; PARADELLA, W.R.; SILVA, A.Q. Avaliação de dados polarimétricos ALOSPALSAR para discriminação litológica no Vale do Rio Curaçá - BA utilizando técnicas de decomposição de alvos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 16, 2013, Foz do Iguaçu, Paraná. **Anais...** São José dos Campos: INPE, 2013. p. 3611-3618.

RICHARDS, J. **Remote sensing with imaging radar (signals and communication technology)**. Springer, 2009.

ROBERTS, D.A.; BATISTA, G.T.; PEREIRA, J.L.G.; WALLER, E.K.; NELSON, B.W. Change identification using multitemporal spectral mixture analysis: applications in eastern Amazônia In: Lunetta, S. e Elvidge C. D. (Ed). **Remote sensing change detection: environmental monitoring methods and applications**. Ann Arbor: Ann Arbor Press, 1998. p. 137-161.

ROGAN, J.; FRANKLIN, J.; ROBERTS, D. A. A comparison of methods for monitoring multitemporal vegetation change using Thematic Mapper imagery. **Remote Sensing of Environment**, v.80, p.143-156, 2002.

ROGAN, J.; CHEN, D. M. Remote sensing technology for mapping and monitoring land-cover and land-use change. **Progress in Planning**, v. 61, p. 301-325, 2004.

ROKNI, K.; AHMAD, A.; SELAMAT, A.; HAZINI, S. Water feature extraction and change detection using multitemporal landsat imagery. **Remote Sensing**, v.6, p. 4173-4189, 2014.

ROSENDO, J. S.; ROSA, R. Análise da detecção de mudanças no uso da terra e cobertura vegetal utilizando a diferença de índices de vegetação. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 13, 2007, Florianópolis. **Anais...** São José dos Campos: INPE, 2007. p. 4209-4216.

ROSENFELD, A. Automatic detection of changes in reconnaissance data. In: NATIONAL CONFERENCE ON MILITARY ELECTRONICS, 5., 1961, Washington. Proceedings... New York : Institute of Radio Engineers, 1961. p. 492-499.

SANT'ANNA, S. J. S.; LACAVA, J. C. S.; FERNANDES, D. Análise do efeito da rotação do plano de polarização em imagens SAR. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 14, 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 7433-7440.

SCHOWENGERDT, R. **Remote sensing: models and methods for image processing**. USA: Academic Press, 2006. 560 p. 3. ed.

SERRA, P., PONS, X., SAURI, D. Post-classification change detection with data from different sensors: some accuracy considerations. **International Journal of Remote Sensing**, v. 24, p. 3311-3340, 2003.

SERVELLO, E. L.; KUPLICH, T. M.; SHIMABUKURO, Y. E. Tropical land cover change detection with polarimetric SAR data. In: GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, (IGARSS), 2010, Honolulu. **Proceedings...** New York: IEEE, 2010.

SHEPARD J. R. A concept of change detection. **Photogrammetric Engineering**, v. 30, p. 648-651, 1964.

SINGH, A. Digital change detection techniques using remotely-sensed data. **International Journal of Remote Sensing**, v. 10, p. 989-1003, 1989.

SOUZA, C. M. Jr.; SIQUEIRA, J. V.; SALES, M. H.; FONSECA, A. V.; RIBEIRO, J. G.; NUMATA, I. Ten-year Landsat classification of deforestation and forest degradation in the Brazilian Amazon. **Remote Sensing**, v. 5, n.11, p. 5493–5513, 2013.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern recognition**. Canada: Academic Press, 2009. 961 p.

TORRES, L.; SANT'ANNA, S. J. S.; FREITAS, C. C.; FRERY, A. C. Speckle reduction in polarimetric SAR imagery with stochastic distances and nonlocal means. **Pattern Recognition**, v. 47, n. 1, p. 141–157, Jan. 2014. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m19/2013/06.09.02.13.18>>. Acesso em: 17 jun. 2015.

TREITZ, P.; ROGAN, J. Remote sensing for mapping and monitoring land-cover and land-use change: an introduction. **Progress in Planning**, v. 61, p. 269-279, 2004.

VAPNIK, V.; GOLOWICH, S. E.; SMOLA, A. Support vector method for function approximation, regression estimation, and signal processing. In: **Advances in neural information processing systems**. MIT Press, p. 281-287, 1996.

VIEIRA, P. R.; YANASSE, C. C. F.; FRERY, A.C., SANT'ANNA, S.J.S. Um sistema de análise e classificação estatística para imagens SAR. In: LATIN-AMERICAN SEMINAR ON RADAR SENSING, 1., 2996, Buenos Aires, AR. **Anais...** Buenos Aires, 1996. p. 179-185, 1996. Image Processing Techniques.

VOLPI, M.; TUIA, D.; BOVOLO, F.; KANEVSKI, M; BRUZZONE, L. Supervised change detection in VHR images using contextual information and support vector machines. **International Journal of Applied Earth Observation and Geoinformation**, v. 20, p. 77-85 , 2013.

WANG, J. R.; ENGMAN, E. T.; SHIUE, J. C.; RUSEK, M.; STEINMEIER, C. The SIR-B observations of microwave backscatter dependence on soil-moisture, surface-roughness, and vegetation covers. **IEEE Transactions on Geoscience and Remote Sensing**, v. 24, n. 4, p. 510- 516, 1986.

WHITTLE, M.; QUEGAN, S.; URYU, Y.; STÜEWE, M.; YULIANTO, K. Detection of tropical deforestation using ALOS-PALSAR: A Sumatran case study. **Remote Sensing of Environment**, v. 124, p. 83-98, 2012.

WU, F.; WANG, C.; ZHANG, H.; ZHANG, B. Change detection and analysis with Radarsat-1 SAR image. In: GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2007, Barcelona. **Proceedings...** IEEE International, 2007. p.2601-2604.

YANG, Z.; QIAN, X. Change Detection Algorithm Using Multitemporal SPOT Images. **Remote Sensing, Environment and Transportation Engineering**, p.1-4, 2012.

YEH, A.G., LI, X. Measurement and Monitoring of Urban Sprawl in a Rapidly Growing Region Using Entropy. **Photogrammetric Engineering & Remote Sensing**, v. 67, n.1, p 83-90, 2001.

ZANOTTA, D.C.; HAERTEL, V. Gradual land cover change detection based on multitemporal fraction images. **Pattern Recognition**, v. 45,p. 2927-2937, 2012.

ZEE BR-163. **Zoneamento ecológico-econômico da rodovia BR-163:** caracterização da área de estudo. 2008. [on line]. Disponível em: <<http://zeebr163.cpatu.embrapa.br>>. Acesso em Acesso em: 23 ago. 2012.