

CARLOS RODRIGO TANAJURA CALDEIRA



**DETECÇÃO DE MUDANÇAS NO ENTORNO DE RESERVATÓRIOS A
PARTIR DE SÉRIE TEMPORAL DE IMAGENS ORBITAIS**

Presidente Prudente
2016

CARLOS RODRIGO TANAJURA CALDEIRA

**DETECÇÃO DE MUDANÇAS NO ENTORNO DE RESERVATÓRIOS A
PARTIR DE SÉRIE TEMPORAL DE IMAGENS ORBITAIS**

Dissertação de Mestrado apresentada
ao PPGCC - Programa de Pós-
Graduação em Ciências Cartográficas
da FCT - Faculdade de Ciências e
Tecnologia da UNESP – Universidade
Estadual Paulista “Julio de Mesquita
Filho”, Campus de Presidente
Prudente.

Orientador: **Prof. Dr. Maurício Galo.**

Presidente Prudente
2016

FICHA CATALOGRÁFICA

Caldeira, Carlos Rodrigo Tanajura.

C151d Detecção de mudanças no entorno de reservatórios a partir de série temporal de imagens orbitais / Carlos Rodrigo Tanajura Caldeira. - Presidente Prudente: [s.n.], 2016

138 f.

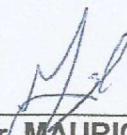
Orientador: Maurício Galo

Dissertação (mestrado) - Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia.

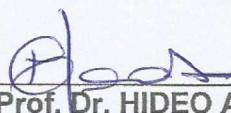
Inclui bibliografia

1. Técnicas de detecção automática de mudanças. 2. Sensoriamento remoto. 3. Uso da Terra. I. Galo, Maurício. II. Universidade Estadual Paulista. Faculdade de Ciências e Tecnologia. III. Título.

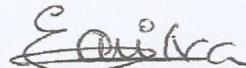
BANCA EXAMINADORA



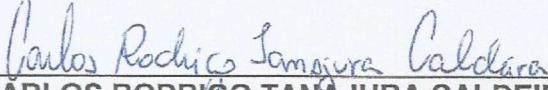
Prof. Dr. MAURICIO GALO
(ORIENTADOR)



Prof. Dr. HIDEO ARAKI
(UFPR)



Prof. Dr. ERIVALDO ANTONIO DA SILVA
(UNESP/FCT)



CARLOS RODRIGO TANAJURA CALDEIRA

Presidente Prudente (SP), 15 de fevereiro de 2016.

Resultado: APROVADO

A Deus.

Aos meus amados pais Carlos Alberto e Roseli, pois nada é mais importante do que a presença dos pais na formação familiar, pessoal e profissional de um jovem, seja pelo exemplo ou motivação, os pais são o alicerce da vida.

As minhas amadas irmãs, Marielle e Daniela, parceiras de todos os momentos.

Ao meu grande amor e futura esposa Mayara, por todo amor, ajuda e compreensão.

AGRADECIMENTOS

A Deus por me amparar nos momentos difíceis, me dar força interior para superar as dificuldades, mostrar os caminhos nas horas incertas e me suprir em todas as minhas necessidades.

Aos meus pais Carlos e Roseli, por me ensinar que nada é em vão, que Deus tem planos para cada um de nós e que só basta confiar, crer e correr atrás de nossos sonhos que um dia eles serão alcançados. Obrigado Pai por me mostrar que qualquer obstáculo pode ser superado quando se tem fé. Obrigado por ser meu exemplo, meu espelho, meu motivo de inspiração. Obrigado Mãe por ter me dado todo apoio e nunca me deixar desistir. Obrigado por ser minha base, meu apoio, meu porto seguro. Amo muito este casal que é minha inspiração de vida.

Às minhas irmãs que sempre estavam compartilhando das vitórias e dos tropeços e por sempre estar ao meu lado nos momentos difíceis. Sem vocês nenhuma vitória seria alcançada.

À minha futura esposa e grande amor, Mayara, pois sem você nada teria sentido, nada seria tão grandioso, sem você nada teria cor. Obrigado por me apresentar a uma nova família, família Cobacho e Ortega, pessoas que me ensinaram que amar outra família como amamos a nossa é possível. Obrigado por fazer parte da minha vida e por me dar força, e me ensinar a viver e ver o mundo de uma forma diferente.

A todos os meus familiares, primos, tios, sobrinho. Mas há aquelas pessoas especiais, aos modelos em que procuro me espelhar sempre: aos meus avôs Euclides e Antonio por toda paciência e amor em que conduzem nossa família; as avós Edna (*in memoriam*) e Antonieta (*in memoriam*), que onde quer que estejam, com toda certeza estarão muito felizes com todos nós. Ao meu tio, pai e irmão Adilson por toda força e apoio. A minha tia avó Neusa, por ser sempre o anjo de minha família.

Ao meu orientador Prof.^º Maurício Galo, pela dedicação, carinho, ensinamentos, paciência, humildade e por ter recebido meu trabalho de forma profissional e honrosa. Por todos os momentos difíceis, ter "segurado as pontas" e ter demonstrado todo seu lado humano ao lidar com os problemas.

Aos irmãos que Deus colocou em minha vida e escolhi para conviver: Heloísa, Marcelo, Nariane e Nemer. Obrigado por sempre estarem ao meu lado me dando muita força e conselhos.

Aos estagiários e amigos de projeto e da vida: Thaís, Maurício, Natielly, Wilson, João, André, Jéssica e Léslie. Obrigado por todo apoio e dedicação ao projeto.

Aos professores que pertencem ao projeto e que sem eles nada seria possível realizar: Maria de Lourdes, Imai, Amilton, Milton e Júlio. Obrigado pela paciência, ensinamentos e dedicação.

Aos meus colegas de pós-graduação, pois sempre estão prontificados a ajudar a resolver problemas tanto de caráter científico quanto pessoal.

A todos os professores do Departamento de Cartografia e do PPGCC Programa de Pós-Graduação em Ciências Cartográficas, que sempre estiveram dispostos a auxiliar os alunos e transmitirem seus amplos conhecimentos.

À banca de qualificação e da defesa final, pelas sugestões que contribuíram para a versão final deste trabalho.

À empresa Duke Energy, pelo apoio, parceria e fomentos.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pelo suporte financeiro durante o desenvolvimento da pesquisa.

*“E aprendi que se depende sempre
De tanta, muita, diferente gente
Toda pessoa sempre é as marcas
das lições diárias de outras tantas pessoas.
É tão bonito quando a gente entende
Que como criar blog a gente é tanta gente
Onde quer que a gente vá.
É tão bonito quando a gente sente
Que nunca está sozinho
Por mais que pense estar...”*
(Caminhos do coração – Gonzaguinha).

EPÍGRAFE

"Senhor eu creio, mas aumentai minha fé."

Lucas 17, 5.

RESUMO

Realizar detecções de mudanças de características da superfície da Terra é importante para a compreensão tanto da dinâmica dos fenômenos quanto para a previsão dos impactos, bem como para o apoio na tomada de decisões. Durante as últimas décadas foram desenvolvidas várias técnicas de detecção de mudanças a partir de imagens, dentre elas as baseadas em imagens de Sensoriamento Remoto. Em geral, a detecção de mudança envolve a utilização de um conjunto de dados multi-temporais, que permite a análise quantitativa do fenômeno de interesse. Uma aplicação de grande interesse destas técnicas é a detecção automática de mudanças no entorno de reservatórios, que podem ser utilizados como dados auxiliares em um sistema de monitoramento das áreas de interesse. Em um sistema desta natureza espera-se que as mudanças decorrentes da ação humana sejam detectadas, mesmo na presença de diferenças entre as cenas provenientes de mudanças nas condições atmosféricas, iluminação da cena, ângulos de visada do sensor, umidade do solo, dentre outros fatores. Considerando este contexto, este trabalho apresenta resultados da avaliação de uma abordagem de detecção de alterações baseada numa modificação aplicada à técnica RCEN (*Radiometric Rotation Controlled by Nonchange axis*). O método foi implementado e aplicado em um conjunto de imagens ortorretificadas obtidas pelo sistema orbital SPOT-6, tomadas em duas épocas distintas, sobre o reservatório de Canoas I, sob concessão da Duke Energy. Os resultados mostraram que o algoritmo baseado na técnica RCEN modificada mostrou-se eficiente para a detecção de mudanças de forma automática.

Palavras chaves: Detecção automática de mudanças; Sensoriamento Remoto; Uso da Terra.

ABSTRACT

Perform change detection of Earth's surface features is important to understanding both the dynamics of the phenomena and for the prediction of impacts and to support decision-making. During the last decades were developed several change detection techniques from images, among them those based on remote sensing images. In general, the change detection involves the use of a set of multi-temporal data, which allows quantitative analysis of the phenomenon of interest. An application of great interest of these techniques is the automatic detection of changes in the vicinity of reservoirs, which can be used as auxiliary data in a monitoring system of the areas of interest. In such a system it is expected that the changes resulting from human activity are detected even if there are factors that cause differences between scenes, such as atmospheric conditions, scene lighting, sensor view point, soil moisture, among other factors. Considering this context, this paper presents the evaluation results of a change detection approach based on a modification applied to the RCEN technique (Radiometric Rotation Controlled by Nonchange axis). The method was implemented and applied to a set of orthorectified images obtained by orbital system SPOT-6, taken at two different times on the Canoas I reservoir, under concession from Duke Energy. The results showed that the algorithm based on modified RCEN technique was efficient to detect automatically changes.

Key words: Automatic change detection; Remote Sensing; Land use.

LISTA DE FIGURAS

Figura 1. Localização do reservatório Canoas I	45
Figura 2. Recorte do reservatório de Canoas I, composições coloridas (R, G, B), nas datas 5/11/2012 (a) e 29/04/2013 (b).	46
Figura 3. Recorte das imagens do sensor SPOT-6 do reservatório de Canoas I, representando as 4 bandas multiespectrais em 05/11/2012.	47
Figura 4. Mapa do uso do Solo de Canoas I.	48
Figura 5. Imagem obtida pelo sensor SPOT-6 (data 05/11/2012) do reservatório Canoas I mostrando o limite da área de estudo.	49
Figura 6. Representação gráfica da linha de não mudança e do valor de I_{INT}	51
Figura 7. Situação simulada onde não há mudança entre as datas, em (a) Imagem na época 1, em (b) Imagem na época 2 e em (c) Eixo de não mudança, situação ideal.....	52
Figura 8. Situação simulada onde há mudança entre as datas, em (a) Imagem na época 1, em (b) Imagem na época 2 e em (c) Eixo de não mudança, situação real.	53
Figura 9. Ilustração do mapeamento do valor de Z_0	55
Figura 10. Fluxograma do método proposto para a detecção de mudanças a partir de imagens.....	58
Figura 11. Imagem do reservatório de Canoas I, do sensor SPOT-6, com a combinação colorida (R, G e B), para a data de 05/11/2012.....	61
Figura 12. Imagem do reservatório de Canoas I, do sensor SPOT-6, com a combinação colorida (R, G e B), para a data de 29/04/2013.....	61
Figura 13. Imagem $I_{detecção}$	62
Figura 14. I_{INTB1} , Banda Intermediária do Vermelho, do sensor SPOT-6.	62
Figura 15. I_{INTB2} , Banda Intermediária do Verde, do sensor SPOT-6.....	62
Figura 16. I_{INTB3} , Banda Intermediária do Azul, do sensor SPOT-6.	63
Figura 17. I_{INTB4} , Banda Intermediária do Infravermelho Próximo, do sensor SPOT-6.	63
Figura 18. Imagem do reservatório de Canoas I, para a data de 05/11/2012, com a representação do limite da área de interesse e as detecções realçadas.....	63

Figura 19. Área teste 1, com destaque para a construção de duas casas.....	64
Figura 20. Área teste 2, com destaque para a remoção de uma casa.....	65
Figura 21. Área teste 3, com destaque para a construção de um tanque rede.....	66
Figura 22. Área teste 4 com destaque para a detecção de sombras em uma mata natural.....	67
Figura 23. Parâmetros de qualidade para o reservatório de Canoas I, sendo em (a) Comparação entre a completeza e o nível de acerto e (b) qualidade. (a)	68
Figura 24. Gráfico com a comparação entre os Falsos Positivos e os Falsos Negativos.....	69
Figura 25. Imagem de sensoriamento remoto utilizada no projeto, sendo mostrado em amarelo os limites da área de interesse.....	71
Figura 26. Banda do Vermelho do sensor Spot-6 em 05/11/2012, com destaque para os pontos de não mudança.....	72
Figura 27. Distribuição dos valores de ND, em a) ND's de toda imagem, em b) ND's dos pontos de não mudança.....	72
Figura 28. Histogramas das quatro bandas multiespectral do sensor SPOT-6, do reservatório de Canoas I, na data de 05/11/2012.....	75
Figura 29. Histogramas das quatro bandas multiespectral do sensor SPOT-6, do reservatório de Canoas I, na data de 29/04/2013.....	75
Figura 30. Correção atmosférica, em (a) a Imagem original e em (b) Imagem corrigida atmosfericamente pelo método DOS, ambas imagens do sensor SPOT-6, reservatório de Canoas I, na data de 05/11/2012.....	77
Figura 31. Correção atmosférica, em (a) a Imagem original e em (b) Imagem corrigida atmosfericamente pelo método DOS, ambas imagens do sensor SPOT-6, reservatório de Canoas I, na data de 29/04/2013.....	77
Figura 32. Comparação dos parâmetros de qualidade em áreas com e sem aplicação da correção atmosférica.....	78
Figura 33. Comparação dos valores de (a) Falso Positivo e (b) Falso Negativo para imagens com e sem correção atmosférica.....	79
Figura 34. Figura representativa da intersecção da área de interesse e da área agrícola.....	80
Figura 35. Recorte da imagem do sensor SPOT-6, do reservatório de Canoas I, na data de 05/11/2012.....	80

Figura 36. Comparação entre as áreas com cultura e sem cultura para os parâmetros de qualidade, (a) Completeza; (b) Nível de Acerto e (c) Qualidade.....	81
Figura 37. Comparação entre os valores de Falso Positivo (a) e Falso Negativo (b) para as áreas com e sem cultura.....	81
Figura 38. Comportamento espectral de alguns alvos na superfície terrestre.....	83
Figura 39. Área teste 1, combinação colorida (RGB), do sensor SPOT-6.	85
Figura 40. Parâmetros de qualidade para as quatro bandas multiespectrais da área 1.	86
Figura 41. Falso Positivo (a) e Falso Negativo (b) das quatro bandas multiespectrais da área 1.	88
Figura 42. Análise das quatro bandas multiespectrais da área 1, para os cinco parâmetros de qualidade.....	89
Figura 43. Área teste 2, combinação colorida (RGB), do sensor SPOT-6, do reservatório de Canoas_1.	90
Figura 44. Parâmetros de qualidade para as quatro bandas multiespectrais da área 2.	91
Figura 45. Falso Positivo (a) e Falso Negativo (b) das quatro bandas multiespectrais da área 2.	93
Figura 46. Análise das quatro bandas multiespectrais da área 2, para os cinco parâmetros de qualidade.....	94
Figura 47. Área teste 3, combinação colorida (RGB), do sensor SPOT-6, para o reservatório de Canoas I.	95
Figura 48. Parâmetros de qualidade para as quatro bandas multiespectrais da área 3.	96
Figura 49. Falso Positivo (a) e Falso Negativo (b) das quatro bandas multiespectrais da área 3.	97
Figura 50. Análise das quatro bandas multiespectrais da área 3, para os cinco parâmetros de qualidade.....	98
Figura 51. Área teste 4, combinação colorida (RGB), do sensor SPOT-6, para o reservatório de Canoas_I.	99
Figura 52. Parâmetros de qualidade para as quatro bandas multiespectrais da área 4.	100

Figura 53. Falso Positivo (a) e Falso Negativo (b) das quatro bandas multiespectrais da área 4.	101
Figura 54. Análise das quatro bandas multiespectrais da área 4, para os cinco parâmetros de qualidade.....	102
Figura 55. Parâmetros de qualidade para as quatro bandas multiespectrais da área 5.	103
Figura 56. Falso Positivo (a) e Falso Negativo (b) das quatro bandas multiespectrais da área 5.	105
Figura 58. Parâmetros de qualidade empregando a combinação de bandas para área 1.....	108
Figura 59. Falso Positivo (a) e Falso negativo (b) para as bandas e composições referente a área 1.	110
Figura 60. Análise das quatro bandas multiespectrais e da combinação de bandas da área 1, para os cinco parâmetros de qualidade.....	111
Figura 61. Parâmetros de qualidade empregando a combinação de bandas para área 2.....	112
Figura 62. Falso Positivo (a) e Falso negativo(b) para as bandas e composições referente a área 2.....	113
Figura 63. Análise dos cinco parâmetros de qualidade empregando as quatro bandas multiespectrais e as combinação de bandas na área 2.....	114
Figura 64. Parâmetros de qualidade empregando a combinação de bandas para área 3.....	116
Figura 65. Falso Positivo (a) e Falso Negativo (FN) das quatro bandas multiespectrais e da combinação das bandas da área 3.....	117
Figura 66. Análise dos cinco parâmetros de qualidade empregando as quatro bandas multiespectrais e as combinação de bandas na área 3.....	118
Figura 67. Parâmetros de qualidade empregando a combinação de bandas para área 4.....	119
Figura 68. Falso Positivo (a) e Falso Negativo (FN) das quatro bandas multiespectrais e da combinação das bandas da área 4.....	121
Figura 69. Análise das quatro bandas multiespectrais e da combinação de bandas da área 4, para os cinco parâmetros de qualidade.....	121
Figura 70. Parâmetros de qualidade empregando a combinação de bandas para área 5.....	123

Figura 71. Falso Positivo (a) e Falso Negativo (b) das quatro bandas multiespectrais e da combinação das bandas da área 5.....	124
Figura 72. Análise das quatro bandas multiespectrais e da combinação de bandas da área 5, para os cinco parâmetros de qualidade.....	125
Figura 73. Comparação dos parâmetros de qualidade entre o resultado final utilizando todas as bandas RGNIR e somente a banda R, como sugerido no Quadro 7.....	127
Figura 74. Número de Valores de Falsos Positivos (a) e Falsos Negativos (b) para as bandas RGNIR e somente a melhor banda R.....	127

Sumário

1 Introdução.....	18
1.1 Objetivos.....	20
1.1.1 Objetivo Geral	20
1.1.2 Objetivos específicos	20
1.2 Estrutura do trabalho	21
2 FUNDAMENTAÇÃO TEÓRICA.....	23
2.1 Detecção automática de alterações.....	23
2.1.1 Processamentos prévios à aplicação de técnicas de detecção de mudanças em Sensoriamento Remoto	24
2.2 Correção Geométrica	26
2.3 Correção Atmosférica	27
2.4 Detecção de Mudanças	30
2.5 Técnicas de Detecção de Mudanças.....	31
2.5.1 Técnicas algébricas	32
2.5.1.1 Método de detecção de mudanças baseado na diferença temporal de NDVI	33
2.5.2 Técnicas baseadas em transformações.....	34
2.5.2.1 Técnica RCEN (<i>Radiometric Rotation Controlled by Nochange axis</i>)	35
2.5.3 Técnicas baseadas em classificação	36
2.5.4 Técnicas baseadas em modelos avançados	37
2.5.5 Abordagens baseadas em SIG	38
2.5.6 Técnicas baseadas em análise visual.....	39
2.5.7 Outras técnicas	40
2.6 Parâmetros de qualidade.....	41
3 MateriaL e Métodos.....	44

3.1	Área de Estudo	44
3.2	Material empregado.....	45
3.3	Método RCEN modificado	50
3.4	Seleção das mudanças mais significativas.....	54
3.5	Estudos preliminares e fluxograma do método proposto	56
4	Experimentos e Discussão dos resultados	60
4.1	Descrição dos experimentos	60
4.2	Experimentos preliminares	61
4.3	Análise da obtenção do coeficiente angular	70
4.4	Análise da influencia da correção atmosférica na detecção de mudanças...	73
4.5	Inserção de máscaras para minimização de falsos positivos	79
4.6	Influência das bandas multiespectrais na detecção de mudanças	82
4.7	Efeito da combinação de bandas	106
4.7.1	Análise quantitativa dos resultados.....	125
5	CONCLUSÕES E RECOMENDAÇÕES.....	129
	Referências Bibliográficas	132
	BIBLIOGRAFIA CONSULTADA	136

1 INTRODUÇÃO

Nas últimas quatro décadas, imagens orbitais passaram a ser frequentemente utilizadas em pesquisas ligadas a aplicações ambientais, geológicas e oceanográficas, atuando como ferramenta auxiliar e por vezes principal na detecção de mudanças.

Em geral, a detecção de mudanças envolve a aplicação de conjuntos de dados multitemporais para analisar quantitativamente os efeitos do fenômeno avaliado. Devido às vantagens decorrentes da aquisição periódica de dados, de sua visão sinóptica, e disponibilização em formato digital adequado para o processamento em computador, os dados de sensoriamento remoto, principalmente orbital, tornaram-se as principais fontes de dados em diferentes aplicações de detecção de alterações (LU et al, 2004).

De acordo com Rodrigues e Ramos (2013) investigar e acompanhar a evolução de uma determinada área vem sendo uma prática importante para entender de que forma e a que taxa essas mudanças ocorrem ao longo de um determinado período. Segundo Aragão e Almeida (2009), o Sensoriamento Remoto com base em imagens de satélite é um dos meios mais eficientes para acelerar os trabalhos, pois o detalhamento da área a ser estudada e o recobrimento deste tipo de imagem faz com que se reduzam os custos dos mapeamentos visando a detecção de mudanças ocorridas no meio ambiente.

A premissa básica da utilização de dados de sensoriamento remoto na detecção de alterações é que as mudanças nos objetos de interesse resultam em variações nos valores de reflectância ou na textura local, mas essas podem ser separadas de mudanças causadas por outros fatores, como diferenças nas condições atmosféricas, iluminação, ângulo de visada e umidade do solo (DEER, 1995). Considerando que a detecção de alterações é afetada por restrições espaciais, espectrais, temáticas e temporais, projetar um conjunto de algoritmos capaz de detectar de modo eficiente as alterações de interesse não é uma tarefa simples. Devido aos impactos decorrentes de fatores complexos, citados anteriormente, tais como diferenças nas condições atmosféricas, iluminação, ângulo de visada, entre outros, muitas vezes, diferentes autores chegaram a diferentes e

por vezes controversas conclusões sobre quais técnicas de detecção de mudança são mais eficazes. Por isso, uma revisão das técnicas de detecção de mudança utilizadas em pesquisas e aplicações anteriores é útil para entender como essas técnicas podem ser melhor utilizadas para ajudar a resolver os problemas concretos.

Existem muitos métodos diferentes em uso, desenvolvidos ao longo de várias décadas de sensoriamento remoto por satélite. Estas abordagens foram consolidadas em vários artigos de revisão (COPPIN et al, 2004; HUSSAIN et al, 2013; LU et al, 2004; RADKE et al, 2005; WARNER et al, 2009; TEWKESBURY et al, 2015), cada um com o objetivo de melhor informar e orientar sobre as técnicas correntes em uso bem como desenvolvimentos futuros. No entanto, a maioria dos autores concordam que uma técnica de detecção de mudança universal ainda não existe (Ehlers et al., 2014) deixando os usuários com uma tarefa cada vez mais difícil de selecionar uma abordagem adequada. Por exemplo, Lu et al. (2004) apresentam 31 (trinta e uma) técnicas, que são classificadas em 7 (sete) categorias, o que mostra a diversidade de alternativas. Em geral, os processos de detecção de mudanças geralmente envolvem a atividade intensiva de um analista preparado para realizar esse tipo de tarefa. Essa atividade poderia ser minimizada com a adoção de um sistema computacional projetado para realizar a maioria dos processamentos automaticamente.

Para comparar imagens multissensor tomadas em duas datas diferentes, Maldonado et. al. (2007) apresentam uma técnica denominada RCEN (*Radiometric Rotation Controlled by Nonchange Axis*) baseada em uma rotação controlada dos eixos ortogonais do espaço de atributos radiométricos das imagens (mesma banda espectral em diferentes datas), em relação ao eixo formado a partir de pontos de não-mudança. Essa técnica, denominada rotação radiométrica controlada por eixo de não-mudança - RCEN é bastante flexível e dispensa a correção dos efeitos atmosféricos ou de diferenças entre os sensores (ARASATO et. al., 2012).

Essa flexibilidade é importante em algumas aplicações, quando se coloca a necessidade de automação no processo de detecção de alterações. Um exemplo de aplicação em que a automação do processo é relevante é o monitoramento de alterações de áreas marginais dos reservatórios de UHEs (Usinas Hidrelétricas), uma vez que as concessionárias de UHEs são responsáveis por garantir a manutenção das margens dos reservatórios sob sua concessão, tanto por imposição

legal, quanto pela necessidade de minimizar processos erosivos responsáveis pela diminuição da vida útil dos reservatórios. Nesse sentido, face à necessidade de fiscalizar as áreas sob sua concessão, surgiu a possibilidade de utilizar imagens multiespectrais e multitemporais de satélite para detectar alterações nas áreas marginais aos reservatórios, ou mais especificamente, nas Áreas de Proteção Permanente (APP), e utilizar essa informação para otimizar o processo de fiscalização nessas áreas.

Deste modo, o uso combinado de imagens de sensoriamento remoto de alta e média resoluções, mesmo considerando as limitações inerentes às imagens de média resolução, pode constituir uma abordagem de maior interesse para esse tipo de monitoramento. Nesse contexto, e com o objetivo de contribuir para a especificação de um conjunto de algoritmos adequados para uma abordagem automática de detecção de alterações foram analisados os resultados da aplicação de uma abordagem baseada na técnica RCEN. Esta abordagem foi considerada em função da facilidade da sua aplicação e dos resultados obtidos pelo método RCEN original, como pode-se ver em (MALDONADO et. al., 2007) e (ARASATO et. al., 2012), indicando que é possível incorporá-lo na especificação de um sistema computacional de detecção automática de mudanças.

1.1 Objetivos

1.1.1 Objetivo Geral

Com base na análise dos métodos de detecção de mudança atualmente disponíveis, o propósito central deste trabalho consiste em implementar e testar o método de detecção de mudanças RCEN modificado, a partir de uma série temporal de imagens orbitais, aplicando os testes em áreas no entorno de reservatórios.

1.1.2 Objetivos específicos

Como objetivos específicos pretende-se:

- Com base na revisão, selecionar alguns métodos de detecção de mudanças, como por exemplo, o método NDVI, e comparar com o método proposto, baseado em modificações aplicadas ao método RCEN, visando escolher o método mais adequado para a detecção automática de mudanças;
- Avaliar os efeitos da correção atmosférica, visando verificar a necessidade da aplicação da mesma neste problema;
- Analisar as influências de cada banda multiespectral na detecção de mudanças;
- Realizar a combinação de bandas multiespectral, visando melhorar os resultados na detecção de mudanças;
- Automatizar o processo de detecção de mudanças, de modo que forneça subsídios para a verificação *in-loco* das potenciais mudanças;
- Testar e avaliar, com base em dados reais e de modo qualitativo e quantitativo, os resultados obtidos com o método proposto.

1.2 Estrutura do trabalho

Essa dissertação segue uma estrutura composta por cinco capítulos. O primeiro fornece uma introdução do conteúdo abordado no projeto, englobando a justificativa para tal, assim como os objetivos.

O Capítulo 2 trata de forma geral da fundamentação teórica, onde são abordados os seguintes tópicos: Detecção automática de alterações, Correção Geométrica, Correção atmosférica, Detecção de Mudança, Técnicas de detecção de mudanças e por fim são apresentados os índices usados na avaliação quantitativa.

No Capítulo 3 são descritos os materiais utilizados, assim como suas características técnicas, bem como os softwares utilizados neste projeto. Ainda neste capítulo, formula-se o método de detecção de mudança RCEN modificado, utilizado neste trabalho.

O Capítulo 4 aborda os resultados obtidos com o método proposto, assim como os experimentos que foram realizados para a validação do método.

Concluindo este capítulo são apresentadas algumas análises quantitativas dos resultados, definindo assim valores indicados para alguns parâmetros utilizados no método proposto, para definir um limiar adequado para a detecção de mudança.

Por fim, a conclusão é abordada no Capítulo 5, assim como recomendações para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Detecção automática de alterações

Mudanças na cobertura terrestre são fenômenos inerentes ao mundo dinâmico e podem ocorrer em diferentes escalas e a diferentes taxas ao longo do tempo. A dinâmica dos tipos de mudança depende de fatores naturais ou artificiais e podem afetar seriamente o meio ambiente e os processos ambientais (ARASTOO e GHAZARYAN, 2013). Desse modo, uma resolução temporal adequada e uma abordagem precisa de detecção das mudanças da superfície física da Terra fornecem a base para uma melhor compreensão das relações e interações entre os fenômenos naturais e antrópicos e possibilitam melhor gerir e utilizar os recursos disponíveis.

Uma variedade de técnicas de detecção de mudanças tem sido desenvolvidas, e muitos autores documentaram, revisaram e compararam essas técnicas (SINGH, 1989; MOUAT et al., 1993; DEER, 1995; COPPIN e BAUER, 1996; JENSEN, 1997; SERPICO e BRUZZONE, 1999; LU et al., 2004, COPPIN et al, 2004; RADKE et al, 2005; WARNER et al, 2009; HUSSAIN et al 2013; TEWKESBURY et al, 2015). Devido à importância cada vez maior de monitorar as mudanças na superfície da Terra, a pesquisa por técnicas de detecção de mudanças é um tópico ativo e novas técnicas são constantemente desenvolvidas.

Todas as técnicas de detecção de alterações têm vantagens e desvantagens, de modo que indicar um método como o melhor ou a técnica como a mais aplicável para todas as situações é impossível. A técnica mais adequada para cada situação é definida, principalmente pela natureza e características do fenômeno que se pretende monitorar, mas também em função das imagens disponíveis para tal tarefa. Além disso, segundo Arastoo e Ghazaryan (2013), fatores como: a abrangência espectral de dados, acessibilidade e qualidade dos dados, condições ambientais, conhecimento e habilidade do analista, tempo e o custo, também são determinantes na seleção da técnica mais apropriada.

Via de regra, conforme destacado por Arastoo e Ghazaryan (2013), um estudo adequado de detecção de alterações, em relação à técnica aplicada, deve

fornecer informações como: área e a taxa de alteração, distribuição espacial das alterações, tendência de mudanças em diferentes tipos de cobertura da terra, bem como a possibilidade de avaliar a exatidão dos resultados obtidos. Essa mesma colocação foi feita anteriormente por Lu et al. (2004), ao relatarem que uma pesquisa fundamentada sobre detecção de mudanças deve fornecer as seguintes informações: (a) variação de área e a taxa de alteração; (b) a distribuição espacial dos tipos alterados; (c) as trajetórias das mudanças em relação aos tipos de cobertura do solo; e (d) a avaliação da acurácia na detecção da mudança.

Esses últimos autores acrescentam que, na implementação de um projeto de detecção de mudanças, três etapas principais estão envolvidas: (a) pré-processamento das imagens, incluindo retificação geométrica e registro, correção radiométrica e atmosférica, além de uma ortorretificação das imagens; (2) seleção de técnicas adequadas para implementar a detecção de alterações; e (3) avaliação precisa das mudanças. O desenvolvimento que consistente dessas etapas, segundo Lu et al (2004), depende de muitos fatores, incluindo:

- a) Registro geométrico preciso entre imagens multitemporais;
- b) Calibração e/ou normalização radiométrica entre imagens multitemporais;
- c) A disponibilidade de referência terrestre para análise de qualidade;
- d) A complexidade da paisagem e do ambiente da área de estudo;
- e) Métodos de detecção de mudança e algoritmos utilizados,
- f) Os sistemas de classificação e de detecção de mudanças;
- g) As habilidades e experiência do analista;
- h) Conhecimento e familiaridade com a área de estudo; e
- i) Restrições de tempo e custo.

2.1.1 Processamentos prévios à aplicação de técnicas de detecção de mudanças em Sensoriamento Remoto

Lu et al. (2005) destacam que para implementar uma detecção de mudanças a partir de dados de sensoriamento remoto, e para que esta detecção

seja bem sucedida, é necessário levar em conta vários aspectos. Esses aspectos referem-se a fatores como: as características do sistema do sensor, características ambientais e os métodos de processamento e análise de imagens. Para se obter bons resultados em um projeto de detecção de mudanças, as resoluções: temporal, espacial, espectral e radiométrica dos dados de sensoriamento remoto têm um impacto significativo. As condições atmosféricas, condições de umidade do solo e características fenológicas da vegetação, como destacado por Jensen et al. (1997), são os fatores ambientais mais importantes e que devem ser levados em conta. Dos vários requisitos relacionados ao pré-processamento para detecção de mudanças, o registro multitemporal e as correções radiométrica e atmosférica são os mais importantes. A importância de registro geométrico preciso das imagens multitemporais é simples de se entender, pois resultados espúrios de detecção de alterações serão produzidos se houver erro de registro, causando assim "detecções fantasmas" e que podem corresponder a falsos positivos na avaliação da qualidade.

Complementando os raciocínios anteriores Lu et al.(2004) colocam que, em algumas situações específicas de detecção de alterações, devem ser contempladas outras condições como: as imagens multitemporais devem contemplar estágios fenológicos similares, quando se trata da cobertura vegetal e prever a necessidade de ajustes entre imagens multitemporais obtidas por diferentes sensores, quando não for possível dispor de dados de mesma resolução espacial e espectral.

Segundo Tewkesbury et al (2015), devido ao impacto de fatores complexos, muitas vezes, diferentes autores chegam a conclusões diferentes, e por vezes controversas, sobre quais técnicas de detecção de alterações seriam mais eficientes em situações similares. Na prática, a escolha de um algoritmo apropriado para detecção de uma mudança específica não é trivial e essa especificação torna-se ainda mais complexa quando se trata da detecção simultânea e automática de mudanças que ocorrem em diversas escalas temporais e espaciais.

2.2 Correção Geométrica

Em sensoriamento remoto, na maioria das análises onde há uma comparação entre imagens multitemporais, ou na utilização de imagens de diferentes sensores orbitais sobre uma mesma área, se faz necessária à correção geométrica. Sendo assim, para tais análises é necessário que os pixels destas imagens sejam registrados, ou seja, correspondam às mesmas áreas no terreno. Porém as imagens de sensores orbitais apresentam uma série de distorções espaciais, tornando-as sem uma exatidão cartográfica suficiente, perante o posicionamento de objetos, superfícies ou fenômenos nelas representados. Dentre os fenômenos que podem causar as distorções geométricas, tem-se o movimento de rotação da Terra, curvatura da Terra, variações da altitude, posição e velocidade da plataforma, distorção topográfica, entre outros, como destaca Silva (2007).

Sendo assim, ao aplicar uma correção geométrica a produtos do sensoriamento remoto, diferentes aspectos podem ser considerados, tais como: correção dos erros sistemáticos, quando se refere ao processo de aquisição das imagens; e registro de imagens, quando o propósito for utilizar imagens obtidas em diferentes épocas, de um mesmo sensor, como pode-se ver em Bessa (2005).

A correção dos erros sistemáticos é normalmente realizada pela própria empresa que fornece as imagens. Esta correção depende das efemérides, da altitude do satélite, além dos parâmetros do sistema de imageamento, que são normalmente disponibilizados no arquivo de metadados da imagem. A partir destes parâmetros, define-se uma direção de visada, que após interceptar o elipsoide de referência possibilita estimar as coordenadas geodésicas do pixel imageado naquele instante. Portanto, as imagens orbitais são fornecidas com uma pré-correção geométrica e georreferenciada, o que pode não ser suficiente para algumas aplicações, como pode-se ver em Meneses e Almeida (2012).

Como pode-se ver em Galo (2003), o registro de imagens consiste na sobreposição de imagens contíguas, de modo que haja uma sobreposição dos elementos comuns às imagens consideradas. De um modo geral pode-se considerar que este processo pode ser realizado em quatro fases, como descrito por Fonseca e Manjunath (1996):

- Seleção das entidades (pontos, linhas e etc.) comuns às imagens de referência e a imagem a ser registrada;
- Estabelecimento da correspondência entre as entidades;
- Obtenção dos parâmetros de uma transformação que permite o mapeamento entre as imagens envolvidas;
- Aplicação dos parâmetros obtidos na fase anterior, permitindo o registro das imagens. Nesta etapa normalmente é necessário a reamostragem de uma das imagens.

Assim sendo, o estabelecimento da correspondência é uma etapa primordial no processo de registro visto que para determinar os parâmetros de uma transformação, dependerá da etapa de estabelecimento da correspondência.

Porém, como destacam Fonseca e Manjunath (1996), embora o princípio de correspondência seja único, não se deve esperar que os métodos de correspondência proporcionem resultados satisfatório em todas as aplicações. Ao desenvolver os métodos, deve-se considerar alguns fatores, como, a diversidade dos sensores disponíveis, as características dos alvos presentes nas cenas, entre outros.

Os métodos de correspondência podem ser divididos em métodos de correspondência baseada em áreas (*area-based methods ou template matching*), onde o princípio deste método consiste na obtenção de pontos correspondentes a partir da análise do coeficiente de correlação entre os níveis de cinza de subimagens das imagens disponíveis; e os métodos de correspondência baseada em características ou atributos (*feature-based methods ou feature matching*), onde tais métodos constituem uma classe mais abrangente, no qual os valores de brilho não são utilizados diretamente e sim as primitivas obtidas a partir das imagens, como podem ser visto detalhadamente em Galo (2003).

2.3 Correção Atmosférica

Como destacado na introdução, a utilização de dados de sensoriamento remoto para detecção de mudanças é um tópico importante nas pesquisas ligadas a esta área do conhecimento. Na aquisição de uma imagem multiespectral, deve-se

considerar que os sinais eletromagnéticos da radiação coletados pelos sensores instalados a bordo dos satélites são modificados, dispersos e absorvidos por gases e aerossóis quando sua passagem pela atmosfera, na trajetória entre a superfície da Terra e o sensor. Portanto, como destacado por Machado (2003), a variabilidade existente nas diferentes condições atmosféricas deve ser considerada para se obter valores mais acurados de reflectância e radiância da superfície.

A radiância está sujeita a dois processos físicos resultantes da interação com a atmosfera: espalhamento (mudança aleatória da direção de propagação da radiação solar devido à sua interação elástica com os componentes atmosféricos (ZULLO JUNIOR, 1993) e absorção (fenômeno termodinâmico que resulta na perda efetiva de energia para os constituintes atmosféricos, ocorrendo de forma seletiva em comprimentos de onda específicos, mas abrangendo todo o espectro óptico. A combinação desses dois efeitos é denominada atenuação atmosférica (NOVO, 1992).

Como enfatizado por Verstraete (1994), o efeito da atmosfera pode impedir a correta interpretação das imagens, se não for considerado. Porém, a aplicação de determinados métodos destinados para tal correção requerem a extração de dados atmosféricos no momento da aquisição da imagem. Assim, a seleção do método é uma etapa de suma importância no processamento, considerando as limitações impostas por alguns deles, principalmente quando se trata da detecção de mudanças de forma automática. Para muitas outras aplicações que envolvem classificação de imagens e detecção de mudanças, a correção atmosférica é trivial, como por exemplo, em casos em que a precisão possui baixo rigor (SONG, 2001).

A correção atmosférica é uma fase do pré-processamento que deve ser realizada em aplicações direcionadas à análise radiométrica. Embora esta correção seja de grande importância, já que possibilita a correta identificação do comportamento espectral dos alvos, a sua correção de modo rigorosa não é simples. De acordo com Soares (2014), os algoritmos destinados à correção atmosférica podem ser classificados em empíricos, cuja aplicação baseia-se apenas em dados contidos na cena; de transferência radiativa, que utilizam modelos matemáticos para aproximar a atmosfera de planos paralelos e calcular a absorção e o espalhamento dos gases atmosféricos de cada um; e os métodos híbridos.

Segundo Ponzoni e Shimabukuro (2007), os modelos de transferência radiativa mais utilizados incorporam o algoritmo *Moderate Resolution Transmission model* (MODTRAN), que oferece variadas possibilidades de entradas de dados provenientes da caracterização espectral da atmosfera, principalmente em relação às concentrações de vapor d'água, ozônio, profundidade óptica e concentração de aerossóis.

Dos modelos empíricos discutidos na literatura, o *Dark Object Subtraction* (DOS) pode ser apontado como o mais simples e mais amplamente utilizada para correção absoluta no contexto de detecção de mudanças e classificação de imagens (SPANNER et al., 1990; EKSTRAND, 1994; JAKUBAUSKAS, 1996; HUGUENIN et al., 1997 apud SONG et al., 2001). O modelo DOS utiliza os pixels que teoricamente teriam valor nulo, ou seja, que não refletiriam radiação, absorvendo-a totalmente (como sombras na região do visível), ou com comportamento especular (corpos de água límpida na região espectral do infravermelho próximo ou médio, por exemplo). Caso estes pixels apresentem valores maiores que zero, o excedente teoricamente seria explicado pela interferência aditiva do espalhamento atmosférico. Assim, considerando que a interferência atmosférica seja uniforme em toda a cena e ignorando as influências de urbanização, topografia e outras, define-se o valor em contadores digitais ou reflectância a ser subtraído de toda a cena. Este método, embora seja de simples aplicação, não leva em conta o fenômeno da absorção atmosférica, considerando apenas a influência do espalhamento. Muito semelhante a este método, existe também a análise de histograma, que considera os valores extremos do histograma de frequência (CHAVEZ, 1988).

Uma vez que a aplicação deste trabalho visa a detecção de alteração de feições em um intervalo temporal, sem considerar uma análise muito rigorosa da radiometria dos alvos, uma possibilidade que pode ser avaliada é o uso da técnica DOS (CHAVEZ, 1988), dada sua simplicidade e rapidez, bem como independe de dados de campo.

2.4 Detecção de Mudanças

A detecção de mudanças é um processo de identificação de diferenças no estado de um objeto ou fenômeno, observando-o em momentos diferentes (SINGH, 1989; LU et al., 2004). A detecção de mudanças de características da superfície da Terra fornece uma base para uma melhor compreensão do relacionamento e as interações existentes entre os fenômenos naturais e humanos, propiciando um melhor gerenciamento e utilização dos recursos.

Em geral, a detecção de mudanças envolve a utilização de conjuntos de dados multitemporais para analisar quantitativamente os efeitos de algum fenômeno. Devido às vantagens da aquisição repetitiva de dados, a sua visão sinóptica, e em formato digital adequado para o processamento do computador, dados de sensoriamento remoto, como *Thematic Mapper* (TM), *Satellite Probatoire d'Observation de la Terre* (SPOT), *Radio Detection And Ranging* (RADAR) e *Advanced Very High Resolution Radiometer* (AVHRR), tornaram-se as principais fontes de dados para diferentes aplicações de detecção de mudança durante as últimas décadas, como destacam Lu et al (2004).

Determinar o método de detecção de mudança mais adequado para uma área de estudo, muitas vezes não é simples, devido à natureza diferente das características físicas associadas com as características de interesse bem como os pontos fortes e fracos dos próprios métodos de detecção de mudança (TEWKESBURY et al, 2015). Deste modo, muitos fatores podem afetar os resultados da detecção de mudanças. Dentre estes fatores Lu et al. (2005) destacam: a qualidade do registro entre as imagens multitemporais, a qualidade da correção atmosférica ou a normalização entre as imagens multitemporais, as características das áreas de estudo (complexidade da paisagem e topografia), as habilidades e experiências do analista e os métodos de detecção de mudança utilizados.

Como mencionado na introdução, a detecção de alterações digitais é afetada por restrições espaciais, espectrais, temáticas e temporais. Com isso muitas técnicas de detecção de mudanças podem ser adotadas, como pode-se ver na literatura. A diversidade de método é grande e é um indicador da dificuldade de se ter técnicas robustas para diferentes aplicações.

Por uma questão de adequação, os métodos de detecção de mudanças são agrupadas em sete categorias, como destacam Lu et al. (2004): A categoria de técnicas Algébricas, Transformação, Classificação, Modelos Avançados, Abordagens de Sistema de Informação Geográfica (SIG), Análise Visual e outras abordagens. As primeiras seis categorias serão mais detalhadas na Seção 2.5. A sétima categoria envolve algumas técnicas de detecção de mudanças que não se enquadram exatamente em uma das seis categorias anteriores, segundo esta classificação. Na sequência, serão apresentadas algumas técnicas de detecção de mudanças, seguindo a classificação apresentada por Lu et al (2004).

2.5 Técnicas de Detecção de Mudanças

O objetivo da detecção de alterações é identificar mudanças no espaço a partir da comparação da representação espacial de uma mesma área ou região de interesse, no tempo, controlando todas as variações causadas por diferenças nas variáveis que não são de interesse, a fim de monitorar as mudanças causadas por diferenças nas variáveis de interesse (GREEN et al.; 1994).

De acordo com Deer (1995) e como destacado em Imai et al (2015) a premissa básica da utilização de dados de Sensoriamento Remoto na detecção de alterações é que as mudanças nos objetos de interesse resultam em variações nos valores de reflectância ou na textura local, mas essas podem ser separadas de mudanças causadas por outros fatores, como diferenças nas condições atmosféricas, iluminação, ângulo de visada e umidade do solo. Uma vez que a detecção de alterações é afetada por restrições espaciais, espectrais, temáticas e temporais, a identificação de um método ou algoritmo capaz de detectar de modo eficiente as alterações de interesse é determinante, mas não é uma tarefa trivial, dada a diversidade de variáveis e alternativas de soluções.

Deste modo, na sequência serão apresentadas algumas das técnicas de detecção de mudanças, separadas de acordo com a classificação proposta por Lu et al (2004).

2.5.1 Técnicas algébricas

As técnicas algébricas incluem a diferenciação de imagens, a regressão de imagens, razão de imagens, diferença entre imagens transformadas em índices de vegetação, análise de vetores de mudanças (*Change Vector Analysis - CVA*) e subtração do fundo. Além de se basearem na álgebra de imagens, esses algoritmos têm em comum a necessidade de selecionar limiares para definir as áreas alteradas. Exceto pelo CVA, esses métodos são relativamente simples, diretos, de fácil implementação e interpretação, mas não podem fornecer matrizes com informações sobre as alterações. A análise do vetor de mudanças (CVA), por outro lado, é uma abordagem que tem fornecido resultados superiores aos métodos que usam limiares, além de disponibilizar informações mais detalhadas sobre as mudanças.

De acordo com Lu et al. (2004) uma desvantagem nos métodos enquadrados nesta categoria é, sem dúvida, a dificuldade em definir limiares adequados para identificar os domínios da alteração. Além disso, devem ser considerados dois aspectos fundamentais na detecção das mudanças: a seleção de bandas espectrais ou índices de vegetação, as imagens apropriadas à detecção das mudanças de interesse e, por fim os limiares adequados para identificar as áreas alteradas.

Um bom exemplo para detecção de mudanças utilizando a diferenciação de imagens está escrito em Chavez e Mackinnon¹ (1994) *apud* LU et al. (2004), onde os autores afirmam que utilizando a diferenciação das bandas na região visível do vermelho, obtém-se melhores resultados na detecção de mudança na vegetação do que usar o *Normalized Difference Vegetation Index (NDVI)* em ambientes áridos e semi-áridos do sudoeste dos Estados Unidos.

Os autores Ridd e Liu (1998) compararam alguns métodos como, diferenciação de imagens, regressão de imagens, método de transformação de Kauth & Thomas ou transformação Tasseledcap (KT), bem como a transformação do qui-quadrado, para a detecção de mudanças no uso do solo urbano, na área de *Salt Lake Valley* usando dados Landsat TM. Eles concluíram que ao usar a banda TM 3,

¹ CHAVEZ, P. S. JR; MACKINNON, D. J. Automatic detection of vegetation changes in the southwestern United States using remotely sensed images. **Photogrammetric Engineering and Remote Sensing**, 60, 571–583. 1994.

os métodos de diferenciação e regressão de imagens, foram os que proporcionaram os melhores resultados. No entanto, nenhum dos algoritmos ou seleções de banda utilizados foi superior aos demais testados.

Na categoria de detecção de mudança baseada em técnicas algébricas, a técnica de diferenciação de imagens é a mais frequentemente utilizada na prática, como destacam Lu et al. (2004). Segundo Hussain et al (2013), diferentes autores têm chegado a diferentes conclusões sobre qual método proporcionou os melhores resultados dentre os seguintes: razão de imagens, diferença entre imagens transformadas em índices de vegetação, regressão de imagem, e as abordagens CVA; uma vez que os resultados variam de acordo com as características das áreas de estudo e das imagens utilizadas. O método de subtração de fundo não foi muitas vezes utilizado, devido à sua capacidade inferior quando comparados às demais técnicas de detecção de mudança.

2.5.1.1 Método de detecção de mudanças baseado na diferença temporal de NDVI

Para viabilizar a detecção de mudanças segundo essa abordagem é necessário realizar uma prévia normalização radiométrica (correção atmosférica relativa) nas bandas espectrais das imagens multitemporais envolvidas no processo.

O NDVI (Índice de Vegetação por Diferença Normalizada), proposto por Rouse et al. (1973), pode ser obtido pela normalização do índice Razão Simples a partir da Equação 1. O resultado da aplicação do NDVI estará no intervalo [-1:1] e a resposta está relacionada com a vegetação presente na cena. Quanto mais densa for esta vegetação o valor estará mais próximo de 1 e, quando não há vegetação (ex. solo exposto, construções, entre outros) este valor será o mais próximo de 0. Os valores negativos correspondem às áreas como corpos d'água e sombra (LIU, 2007).

$$NDVI = \frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + \rho_{red}} \quad (1)$$

onde, ρ_{nir} é o fluxo radiante refletido no infravermelho próximo e ρ_{red} é o fluxo radiante refletido no vermelho da região do visível.

Com base nos valores de NDVI calculados para cada imagem (de épocas distintas) pode-se calcular, com a Equação 2, o valor que deve indicar possíveis alterações.

$$NDVI_{detecção} = NDVI_{D2} - NDVI_{D1} \quad (2)$$

sendo: $NDVI_{detecção}$ a imagem NDVI de detecção de alterações e $NDVI_{D1}$ e $NDVI_{D2}$ os valores de NDVI para as datas D_1 e D_2 , respectivamente.

2.5.2 Técnicas baseadas em transformações

As técnicas baseadas em transformações incluem a análise de componentes principais (PCA – *Principal Component Analysis*), Tasseled Cap (ou transformação de Kauth & Thomas – KT), Transformação de Gramm-Schmidt (GS) e Transformações Qui-quadrado. Uma das vantagens comuns a esses métodos é a redução na redundância espectral entre as bandas, enfatizando informações diferentes e não correlacionadas nas imagens derivadas (denominadas componentes). No entanto, tais transformações não geram matrizes de informações detalhadas das mudanças e requerem a seleção de limiares para identificar as áreas alteradas. Outra desvantagem é a dificuldade que o analista terá em interpretar e rotular as informações de alteração nas imagens transformadas (componentes).

Um exemplo de aplicação de algumas destas técnicas encontra-se em Fung e LeDrew² (1987, *apud* Lu et al., 2004), onde os autores utilizaram o método PCA juntamente com diferenças nas imagens após transformação KT para detectar mudanças de cobertura da terra a partir de imagens multi-temporais MSS e TM.

De acordo com Lu et al. (2004) na categoria de transformação, as técnicas PCA e KT são as abordagens mais frequentemente utilizadas para detectar informações de alteração de não-mudança. Os métodos GS e qui-quadrado são utilizados com menor frequência na prática, devido à sua complexidade relativa em comparação com as transformações PCA e KT. Além disso, os métodos GS e qui-

² FUNG, T.; LEDREW, E. The application of principal component analysis to change detection. *Photogrammetric Engineering and Remote Sensing*, 53, 1649–1658. 1987.

quadrado não estão disponíveis na maior parte dos softwares comerciais para processamento de imagens de sensoriamento remoto.

Na próxima seção será apresentado um método apresentado por Maldonado et al. (2007) que pode ser enquadrado nesta categoria, uma vez que é baseado em uma transformação de rotação, tomando como referência o eixo de não mudança.

2.5.2.1 Técnica RCEN (*Radiometric Rotation Controlled by Nochange axis*)

A técnica RCEN é uma técnica de detecção de mudanças que foi proposta por Maldonado et. al. (2007). Os resultados da aplicação desta técnica chamaram atenção para a detecção de mudanças de forma automática, pois a mesma é bastante flexível e dispensa a correção dos efeitos atmosféricos ou de diferenças entre os sensores (ARASATO et al, 2012).

Esta técnica baseia-se em uma regressão linear dos valores de radiometria dos locais de amostragem de não mudança, definidos a partir de um levantamento de campo. Para esta regressão são utilizados os valores de ND de duas imagens, sendo a primeira correspondente à primeira data do período de detecção e a segunda à segunda data. A equação de regressão dos pontos de não mudança é obtida a partir da Equação 3, onde "m" é o coeficiente angular da reta de regressão, com $m=\tan(\theta)$, sendo θ a inclinação do eixo de não mudança, como pode-se ver em Maldonado et. al. (2007).

$$I_{D_2} = mI_{D_1} + O \quad (3)$$

onde m é o coeficiente angular do eixo de não mudança; O : origem da interceptação; I_{D_1} e I_{D_2} : valores de ND das imagens das datas D_1 e D_2 , respectivamente.

Este ângulo é o parâmetro principal da rotação, sendo utilizado na equação da transformação da técnica RCEN dada pela Equação 4, apresentada por Maldonado et al. (2007). Assumindo que as imagens de uma mesma região nas datas D_1 e D_2 sejam representadas respectivamente por I_{D_1} e I_{D_2} , a imagem residual

(I_{Res}) e a imagem de detecção de mudanças ($I_{detecção}$), como definida pelos autores, podem ser obtidas por:

$$\begin{pmatrix} I_{Res} \\ I_{detecção} \end{pmatrix} = \begin{pmatrix} \cos \theta & \sin \theta \\ -\sin \theta & \cos \theta \end{pmatrix} \begin{pmatrix} I_{D_1} \\ I_{D_2} \end{pmatrix} \quad (4)$$

Esta transformação corresponde a uma rotação dos eixos ortogonais do espaço de valores radiométricos das imagens (de uma mesma banda espectral em datas diferentes). Como resultado tem-se duas imagens, sendo a imagem (I_{Res}) denominada pelos autores imagem residual, não utilizada no processo de detecção. A imagem ($I_{detecção}$) é a imagem que contém a informação relacionada aos pontos onde ocorreram mudanças entre as datas D_1 e D_2 analisadas.

A imagem detecção é formada utilizando valores no domínio dos números reais. Nesta imagem os tons claros (valores altos) são os pixels que representam alvos que surgiram de um ano para outro, ou seja, alvos que não existiam na época I_{D_1} e passaram a existir na época I_{D_2} . Os pixels com tons mais escuros (valores baixos) representam o comportamento ao contrário, isto é, são alvos que deixaram de existir de uma época para outra. Assim, aplicando a rotação dada pela Equação 4 a imagem de detecção ($I_{detecção}$) é dada por.

$$I_{detecção} = \cos \theta I_{D_2} - \sin \theta I_{D_1}. \quad (5)$$

2.5.3 Técnicas baseadas em classificação

De acordo com Lu et al. (2004) as técnicas de detecção de mudanças que enquadram nesta categoria incluem a comparação pós-classificação, análise combinada espectro-temporal, detecção de mudança com base em algoritmos que tratam da maximização da expectativa (EM), detecção de mudanças não supervisionada, detecção de mudanças com métodos híbridos de classificação, e classificações baseadas em redes neurais artificiais (*Artificial Neural Network – ANN*). Dada a natureza desses métodos, os resultados da detecção de mudanças são altamente dependentes de uma classificação de boa qualidade.

A principal vantagem desses métodos é a capacidade de fornecer a matriz de informação de mudança, além da minimização do impacto de fatores externos às mudanças desejadas, como aqueles decorrentes das diferenças atmosféricas e ambientais entre as imagens multitemporais. Por outro lado, a dependência do resultado da classificação é a característica fundamental desse método, principalmente nas abordagens supervisionadas que implicam na aquisição de dados de treinamento de alta qualidade e suficientemente numerosos para caracterizar os tipos de ocorrência que devem ser mapeados em cada momento do tempo. A definição, rotulação e caracterização de classes consistentes no tempo é, muitas vezes, difícil, em particular para a classificação de dados históricos. O tempo requerido e a difícil tarefa de produzir classificações acuradas tornam os métodos baseados em classificação bastante complexos.

Estes métodos de classificação muitas vezes exigem uma grande quantidade de dados de amostra de treinamento para classificação supervisionada ou não supervisionada. Os métodos de transformação de imagem, índices de vegetação e os métodos avançados de classificação, modelam e integram diferentes fontes de dados que são muitas vezes utilizados para melhorar os resultados da classificação. A comparação pós-classificação é uma abordagem comum usada para a detecção de alterações, mas o histórico das dificuldades, na classificação de dados das imagens, indica que podem afetar seriamente os resultados na detecção de mudança, como destacam Lu et al. (2004).

2.5.4 Técnicas baseadas em modelos avançados

A categoria de detecção de alterações baseada em modelos avançados inclui o modelo de reflectância de Li-Strahler, os modelos de mistura espectral e os modelos de estimativa baseados em parâmetros biofísicos. Nesses métodos, os valores de reflectância extraídos da imagem são, muitas vezes, convertidos em parâmetros ou imagens-fração com significado físico, por meio de modelos lineares ou não lineares. Os resultados da aplicação dos modelos são, geralmente, de interpretação mais intuitiva e para o alvo vegetação, permitem extrair informações de modo mais fácil, quando assinaturas espectrais estão disponíveis. As desvantagens

desses métodos estão relacionadas com o maior tempo consumido no processo e com a dificuldade de desenvolver modelos adequados para a conversão dos valores de reflectância da imagem nos parâmetros biofísicos de interesse.

Nesta categoria, a análise linear de mistura espectral (LSMA – *Linear Spectral Mixture Analysis*) é o mais utilizado para a análise da cobertura da terra, como destacam Lu et al. (2004). Quando as medições de vegetação em campo estão disponíveis, o modelo de dossel Li-Strahler e o modelo de estimativa de parâmetros biofísicos são valiosos para a detecção quantitativa de mudança na vegetação. No entanto, aplicações de ambos os modelos são muitas vezes demorados e difíceis e podem fornecer apenas a detecção de alterações da vegetação, não sendo adequados para a detecção de alterações para alvos que não sejam vegetação. Um passo fundamental na implementação do LSMA para a detecção de mudanças é selecionar os membros de referência adequados para o desenvolvimento das imagens fração. Segundo Lu et al. (2004) a grande vantagem dessa abordagem é sua estabilidade, confiabilidade e repetibilidade, permitindo obter informações quantitativa de qualidade na detecção de mudança na cobertura da terra.

2.5.5 Abordagens baseadas em SIG

Nesta categoria de métodos de detecção de mudanças normalmente são integrados dados de sensoriamento remoto a dados de Sistemas de Informação Geográfica (SIG). A grande vantagem do uso do SIG está na sua capacidade de incorporar dados de origens diversas nas aplicações de detecção de mudanças (HUSSAIN, 2013).

Deve-se considerar, no entanto, que dados de origem diferentes podem possuir precisões diferentes, bem como ter formatos diferentes. No segundo caso, pressupõe-se que seja feita uma conversão de formatos e independente de haver ou não formatos diferentes, eventuais diferenças nas precisões podem afetar os resultados de detecção de mudanças.

As poderosas funções do SIG fornecem ferramentas úteis para o processamento de dados originários de múltiplas fontes e são eficazes no

tratamento da análise de detecção de mudança em diferentes ambientes. Segundo Lu et al. (2004) mais pesquisas com foco na integração do SIG e técnicas de sensoriamento remoto ainda são necessárias para uma melhor aplicação das análises de detecção de mudanças. Petit et al. (2001) apresentaram uma metodologia para a detecção de mudanças de cobertura da terra por meio da integração dos mapas de ocupação do solo derivados de dados de imagem.

2.5.6 Técnicas baseadas em análise visual

A detecção de mudanças por meio da análise visual não é, obviamente, um processo passível de automação, mas por considerar elementos essencialmente cognitivos da extração de informações a partir de imagens, tem uma importância significativa na caracterização das mudanças de interesse.

Nesse contexto, a categoria de análise visual inclui interpretação visual de cenas multitemporais, visualizadas na forma de composições coloridas, associadas aos canais R, G e B, seguida da posterior digitalização na tela das áreas alteradas. Esse método faz pleno uso da experiência e conhecimento do intérprete na identificação de elementos-chave na caracterização das mudanças, tais como: textura, forma, tamanho, padrão, localização e contexto (entre outros). Como um aspecto de desvantagem desta abordagem, segundo Lu et al. (2004), pode-se citar: o tempo consumido na detecção de mudanças em grandes áreas e a dificuldade de atualizar os resultados de detecção de mudanças.

Ainda de acordo com Lu et al. (2004) a interpretação visual foi amplamente utilizada em diferentes aplicações, como o inventário para florestas antes dos anos de 1970, quando os dados de satélite digitais não estavam disponíveis e a capacidade de técnicas de informática e processamento de imagem em lidar com uma grande quantidade de dados era limitada em relação às técnicas atuais. Com o rápido desenvolvimento de tecnologias de informática e técnicas de sensoriamento remoto bem como processamento de imagens, os processamentos digitais substituíram gradualmente a interpretação visual. No entanto, o processamento das imagens, de modo automático, nem sempre é possível em todos os casos. Por exemplo, a detecção de exploração seletiva de madeira florestal, em

muitos casos, é muito difícil de ser utilizada de forma automática por meio exclusivamente computacional, sendo necessário e essencial a interpretação visual, por um analista especializado.

2.5.7 Outras técnicas

Além das seis categorias de técnicas de detecção de mudança discutidas nos tópicos anteriores, há também alguns métodos que não podem ser enquadrados nestas categorias. Lu et al. (2004) destacam que, por exemplo, Henebry (1993) usou medidas de dependência espacial com dados TM para detectar mudança em pastagens. Wang (1993) usou um sistema de visão baseado no conhecimento para detectar mudanças de cobertura da terra em uma periferia urbana. Lambin e Strahler (1994b) utilizaram três indicadores, índices de vegetação, temperatura da superfície da terra e estrutura espacial, derivadas de AVHRR, para detectar mudanças de cobertura da terra na África ocidental. Lawrence e Ripple³ (1999, *apud* Lu et al. 2004) utilizaram curvas de mudança e Hussin et al. (1994) usaram um modelo de produção para detectar mudanças na cobertura florestal. Morissette et al.⁴ (1999, *apud* Lu et al., 2004) utilizaram modelos lineares generalizados para detectar mudanças de cobertura da terra.

A partir desta breve revisão, baseada principalmente no trabalho de Lu et al. (2004) é possível perceber a diversidade de alternativas de solução, o que indica que a solução do problema para uma gama maior de aplicações não é nada trivial, uma vez que são diversos os fatores que afetam a ocorrência das mudanças, sejam eles fatores relacionados ao sensores, ao meio ambiente, a atuação do Homem, às mudanças sazonais, dentre outros.

Além do trabalho de Lu et al. (2004), que traz uma detalhada revisão dos métodos até então propostos para a detecção de mudanças, outros trabalhos relevantes com o mesmo propósito podem ser citados. Dentre eles tem-se o trabalho de Tewkesbury et al. (2015) na qual os autores apresentam uma síntese crítica das

³ LAWRENCE, R. L.; RIPPLE, W. J. Calculating change curves for multitemporal satellite imagery: Mount St. Helens 1980–1995. **Remote Sensing of Environment**, 67, 309–319. 1999.

⁴ MORISSETTE, J. T.; KHORRAM, S.; MACE, T. Land-cover change detection enhanced with generalized linear models. **International Journal of Remote Sensing**, 20, 2703–2721. 1999.

soluções deste problema. Neste último e mais recente trabalho os autores analisam os métodos considerando diferentes unidades de análise tais como: pixel, grupo de pixels (*kernel*), sobreposição imagem-objeto, comparação imagem-objeto, imagem-objeto multitemporal, vetores (*vector polygon*) e híbrido. Independente da unidade de análise os autores também fazem uma comparação entre as diferentes abordagens, tais como: os métodos baseados em operações aritméticas, detecção de mudanças pós-classificação, classificação direta, transformação, análise do vetor de mudanças (CVA) e métodos híbridos.

Ao cotejar estes dois trabalhos de revisão, um de 2004 e outro de 2015, percebe-se que o modo de análise e agrupamento dos métodos seguem princípios diferentes. Embora o tempo decorrido entre eles seja de mais de uma década, é interessante perceber que estudos adicionais ainda são necessários, como pode-se ver de forma explícita na conclusão do trabalho mais recente, que menciona que mais pesquisas são necessárias para a identificação de abordagens ótimas para a detecção de mudanças.

2.6 Parâmetros de qualidade

São vários os aspectos que podem ser analisados para a avaliação de processos de extração de feições cartográficas, como, por exemplo, a completeza, o nível de acerto, a acurácia geométrica etc (MAIA, 2003).

A avaliação dos métodos de detecção de mudanças que serão objetos de análise neste trabalho, baseados na revisão apresentada na Seção 2.5, terá por base os parâmetros de qualidade definidos em Wiedemann et al. (1988) e Wiedemann e Hinz (1998). Embora os parâmetros de qualidade apresentados nestes dois trabalhos sejam aplicados na análise da extração automática de rodovias, eles podem ser adaptados a inúmeras aplicações, como a realizada neste trabalho. Na sequência estes parâmetros são apresentados, com base em Wiedemann et al. (1988):

- **Completeza (Comp):** Define-se completeza (derivado do termo inglês *completeness*), como sendo o índice que mede a porcentagem entre a quantidade de detecções coincidentes ao polígono de referência

detectado pelo método avaliado, com a quantidade de polígonos de referência. Este parâmetro varia no intervalo [0;1]. Caso o valor seja 0, nada do que foi extraído concorda com o conjunto de referência. Do contrário, se a completeza assumir valor igual a 1, indica que tudo que foi extraído pelo método concorda com a referência. Assim o parâmetro *Comp* é definido como:

$$Comp = \frac{nº\ de\ mudanças\ detectados\ como\ alteração,\ internos\ ao\ polígono\ referência}{nº\ de\ polígonos\ que\ formam\ o\ conjunto\ de\ referência} \quad (6)$$

$$Comp \in [0; 1], \text{que corresponde a } [0; 100\%]$$

- **Nível de Acerto (NA):** Define-se como sendo o índice que apresenta a porcentagem das modificações detectada como alteração, e que realmente estão localizados dentro do polígono de referência, ou seja, a quantidade do resultado que foi rotulado corretamente, e a quantidade total de detecções encontradas pelo método proposto. O termo original, apresentado por Wiedemann et al. (1988) em Inglês foi *correctness*, podendo ser traduzido como nível de acerto ou correteza, como pode-se ver em algumas referências. Este parâmetro varia no intervalo [0; 1]. Se o valor assumido for 0, nada do que foi extraído é validado e, pelo contrário, se o valor for igual a 1, significa que tudo é validado. Assim, o parâmetro *NA* é definido como:

$$NA = \frac{nº\ de\ mudanças\ detectados\ como\ alteração,\ internos\ ao\ polígono\ referência}{nº\ de\ polígonos\ detectados\ como\ alteração} \quad (7)$$

$$NA \in [0; 1], \text{que corresponde a } [0; 100\%]$$

- **Qualidade:** Esse parâmetro combina as duas medidas anteriores (completeza e nível de acerto). A qualidade é máxima quando a completeza e o nível de acerto são iguais a 1. Nesse caso, o parâmetro de qualidade também será igual a 1. Por outro lado, o parâmetro de qualidade será nulo, isto é, igual a 0, quando os valores para a

completeza ou para o nível de acerto forem iguais a 0. Portanto, o parâmetro de qualidade também assume valores no intervalo [0; 1].

$$Qualidade = \frac{Comp*NA}{Comp - Comp*NA + NA} \quad (8)$$

Como pode-se ver em Wiedemann et al. (1988), as Equações 6 a 8 podem ser escritas também em função da quantidade de Falsos Positivos, Verdadeiros Positivos e Falsos Negativos:

- **Verdadeiro Positivo:** Define-se como sendo a quantidade de alterações que foram detectadas como alteração pelo método, e são coincidentes com os polígonos de referência terrestre.
- **Falso Positivo:** Define-se como sendo a quantidade de alterações que foram detectadas como alteração pelo método, porém não estão coincidentes com os polígonos de referência terrestre.
- **Falso Negativo:** Define-se como sendo a quantidade de alterações que não foram detectadas como alteração pelo método, porém são alterações reais.

3 MATERIAL E MÉTODOS

Para o desenvolvimento deste trabalho, inicialmente realizou-se um levantamento bibliográfico dos trabalhos relacionados ao tema proposto, o qual serviu para aquisição dos fundamentos teóricos necessários para o estudo da detecção de mudanças, bem como os métodos disponíveis para tal.

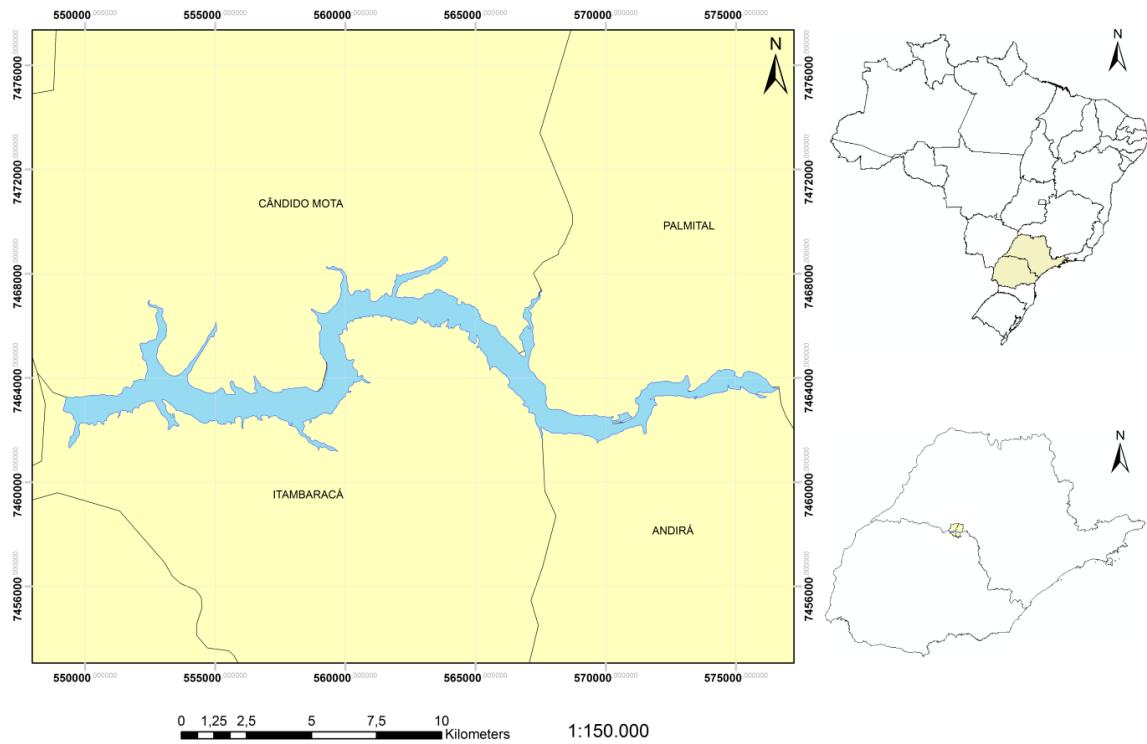
Neste capítulo será descrita a área de estudo, os materiais utilizados, bem como os métodos propostos para atender aos objetivos apresentados neste trabalho.

3.1 Área de Estudo

As UHEs Canoas I e Canoas II, junto com seus reservatórios, compõem o Complexo Canoas, que se localizam no médio curso do rio Paranapanema, na divisa dos estados de São Paulo e Paraná. Elas estão entre a UHE Salto Grande (a montante) e a UHE Capivara (a jusante). A Figura 1 apresenta a localização do reservatório do empreendimento Canoas I, que pertence a dois municípios paulistas, Cândido Mota e Palmital e dois paranaenses, Itambaracá e Andirá.

Esse complexo hidrelétrico é do tipo “a fio d’água”, não possuindo capacidade de retenção, ou seja, as águas são totalmente liberadas pelas turbinas e por estruturas de vertimento. Os reservatórios das UHEs Canoas I e Canoas II possuem um perímetro total de 223 km, nas cotas 351 m e 366 m, respectivamente.

Figura 1. Localização do reservatório Canoas I.



3.2 Material empregado

Os dados utilizados neste projeto, visando a detecção de mudanças de forma automática foram disponibilizados pela empresa Duke Energy. Estes dados são referentes às oito Usinas Hidrelétricas instaladas ao longo do rio Paranapanema, que são: Jurumirim, Chavantes, Salto Grande, Canoas I, Canoas II, Capivara, Taquaruçu e Rosana. Dentre estes reservatórios, foram selecionados os dados de Canoas I para a realização dos testes, já que o mesmo apresentava maior variabilidade e representatividade das possíveis intervenções.

Estes dados são basicamente imagens orbitais ortorretificadas do sensor SPOT 6. O Quadro 1 exibe as especificações técnicas das imagens do sensor SPOT 6.

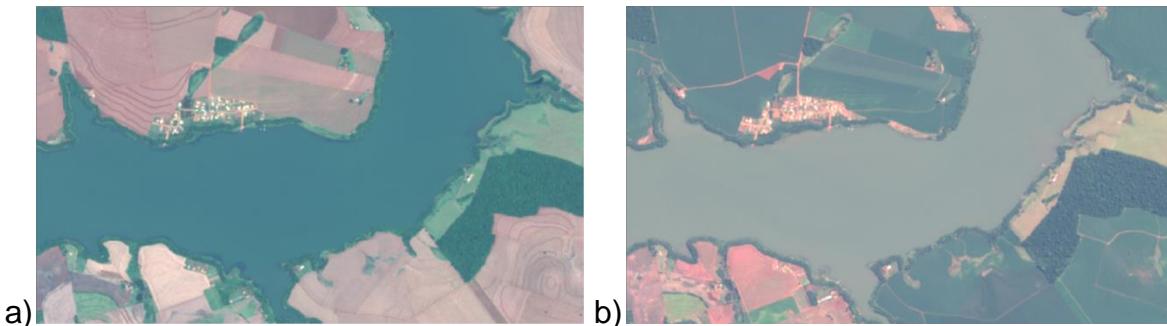
Quadro 1. Especificações das imagens do sensor SPOT 6.

Bandas espectrais/	Pancromática	0,450-0,745 μm
Intervalo do comprimento de onda	Azul	0,450-0,520 μm
	Verde	0,520-0,590 μm

	Vermelho	0,625-0,695 µm
	Infravermelho próximo	0,760-0,890 µm
Resolução Radiométrica	12 bits	
Resolução Espacial	Pancromática	2 m
	Multiespectral	6 m

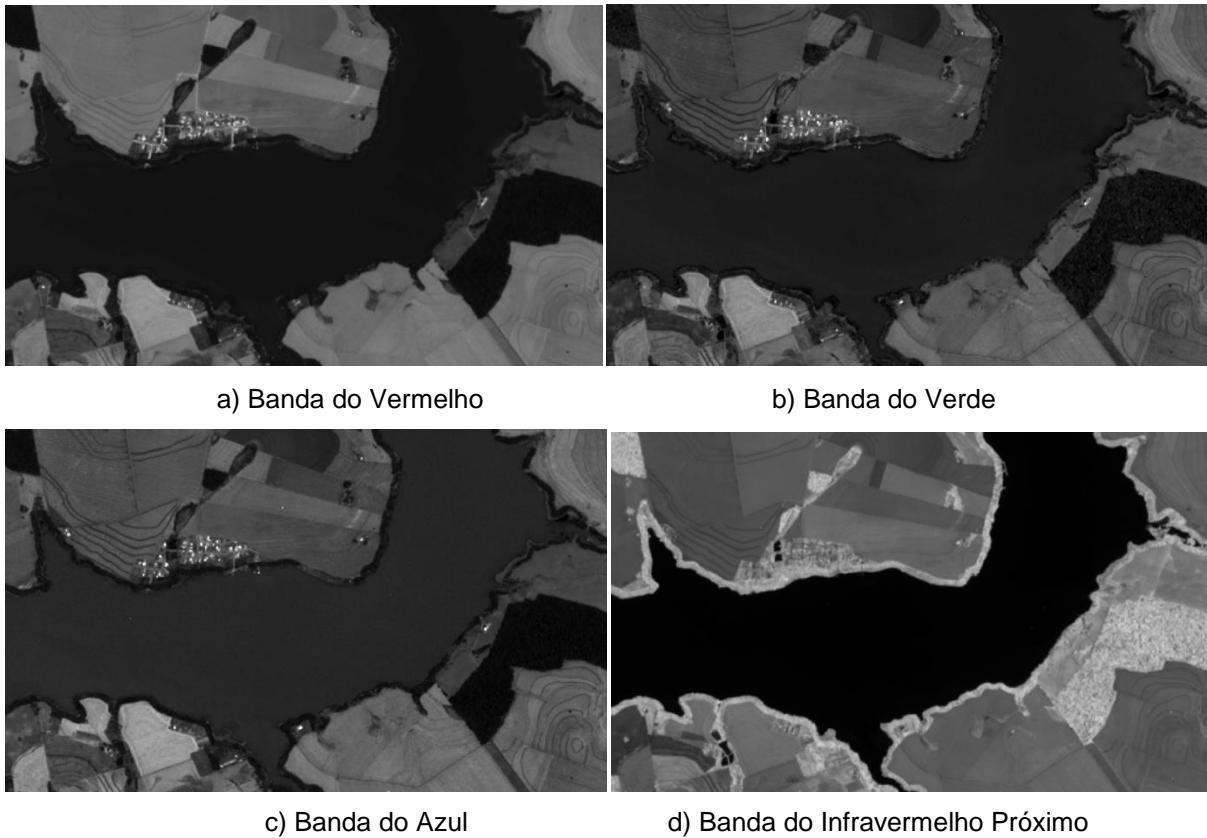
As imagens utilizadas foram adquiridas em 5/11/2012 e 29/04/2013, como mostrado nas Figuras 2.a e 2.b.

Figura 2. Recorte do reservatório de Canoas I, composições coloridas (R, G, B), nas datas 5/11/2012 (a) e 29/04/2013 (b).



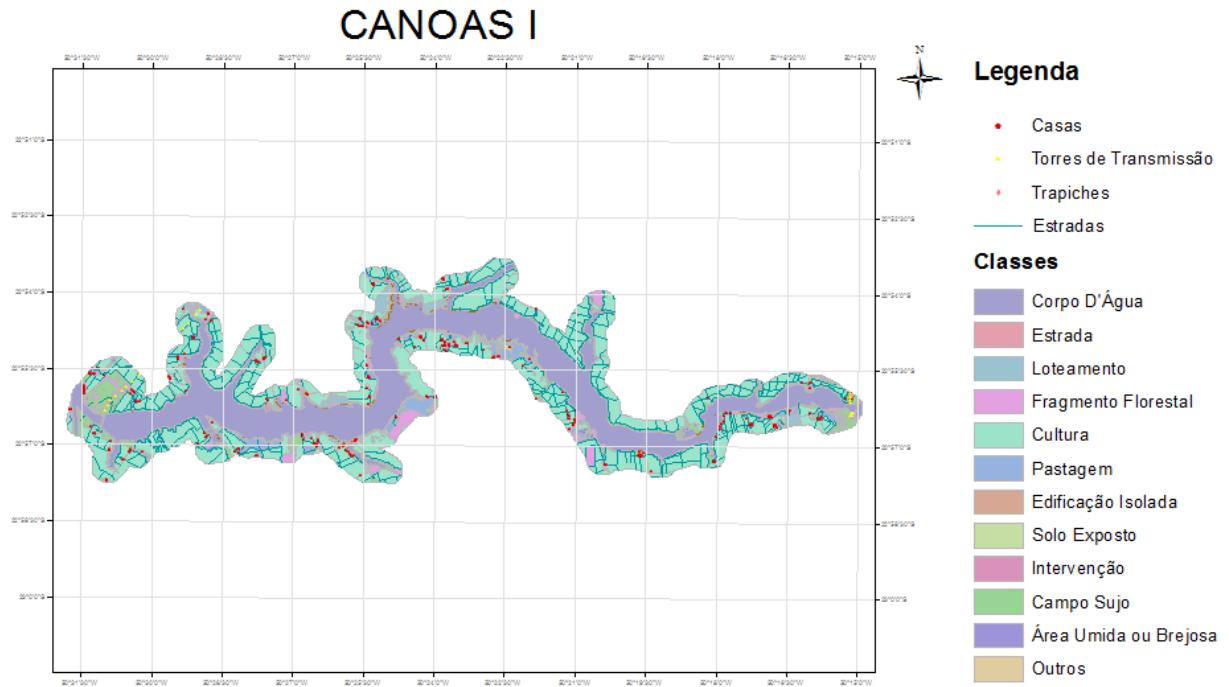
Para cada uma das datas estão disponíveis imagens em quatro (4) bandas multiespectrais, como mostra a Figura 3, sendo as Bandas 1, 2, 3 e 4, associadas às bandas do Vermelho, Verde, Azul e Infravermelho Próximo, respectivamente.

Figura 3. Recorte das imagens do sensor SPOT-6 do reservatório de Canoas I, representando as 4 bandas multiespectrais em 05/11/2012.



Além das imagens, a empresa Duke Energy também disponibilizou um mapa do uso do solo (elaborado em 15/08/2014), em arquivo no formato *shapefile*, como mostra a Figura 4. Este mapa é útil para a análise da qualidade, servindo também como uma referência para a separação das diferentes classes de cobertura do solo. Esta separação pode ser feita a partir de máscaras definidas a partir de arquivos *shapefile*, que contém algumas classes que não são de interesse para o processamento.

Figura 4. Mapa do uso do Solo de Canoas I.



No que concerne aos softwares utilizados pode-se mencionar:

- Matlab (*MATrix LABoratory*) para a implementação e testes iniciais dos algoritmos de detecção de mudança;
- ENVI 5.0, para realizar a visualização e manipulação das imagens, o refinamento do registro das ortoimagens (4 bandas nas diferentes épocas);
- ArcGis 10.0 para elaboração da verdade terrestre e manipulação dos dados vetoriais no controle de qualidade;
- Python 2.7 para a codificação dos algoritmos de detecção de mudanças selecionados;
- PostgreSql 9.4 para gerenciar o banco de dados;
- PostGis 2.2.4 para a manipulação dos dados georreferenciados; e
- Biblioteca Gdal utilizada para facilitar a codificação, usando métodos prontos/testados.

Para selecionar algumas áreas testes, onde há uma maior concentração de intervenções, utilizou-se da interpretação visual, realizada a partir das imagens ortorretificadas do sensor WordView II, com resolução espacial de 2 m nas quatro bandas multiespectral e 0,50 m na banda pancromática, adquiridas em 11/09/2013.

As imagens de alta resolução espacial foram utilizadas apenas como auxílio para a visualização dos dados e interpretação dos mesmos. Este reconhecimento de intervenções realizado via interpretação visual, assim como o refinamento do registro geométrico das ortoimagens, por exemplo, foram realizados com o auxílio do ENVI 5.0. Para a obtenção da referência terrestre utilizou-se do software ArcGis 10.0, sendo feita a vetorização de áreas escolhidas, tomando como base tanto dados obtidos em campo, quanto imagens de alta resolução espacial. Também utilizou-se o software ArcGis 10.0 para a manipulação dos dados, em formato *shapefile*, do Mapa do Uso do solo.

Para a redução da área de análise, concentrando o processamento apenas na área de interesse da empresa Duke Energy, foi utilizado um arquivo em formato *shapefile*, como mostrado na Figura 5, contendo os limites da área de estudo.

Figura 5. Imagem obtida pelo sensor SPOT-6 (data 05/11/2012) do reservatório Canoas I mostrando o limite da área de estudo.



Após o desenvolvimento dos algoritmos em linguagem Matlab, todos os códigos foram traduzidos para a linguagem Python, pela simplicidade/portabilidade e para facilitar a comunicação com o banco de dados. Esta tradução foi realizada pelos estagiários da ciência da computação da FCT/Unesp, Thaís C. Dias e Wilson Estécio M. Júnior. Uma vez que este trabalho se enquadra dentro de um projeto maior de P&D da Aneel, alguns detalhes relativos ao desenvolvimento do banco de dados, por exemplo, encontra-se disponível em Dias et. al. (2015).

3.3 Método RCEN modificado

Esta subseção apresenta a ideia geral do método proposto neste projeto. Este método baseia-se na técnica de detecção RCEN, que faz a transformação de rotação em torno de um eixo, que representa a relação entre a resposta espectral dos pixels que não sofreram alteração, em duas datas, como descrito na Seção 2.5.2.1. Como mencionado na fundamentação, o método original foi proposto por Maldonado et al. (2007). Na aplicação do método original as seguintes premissas são válidas:

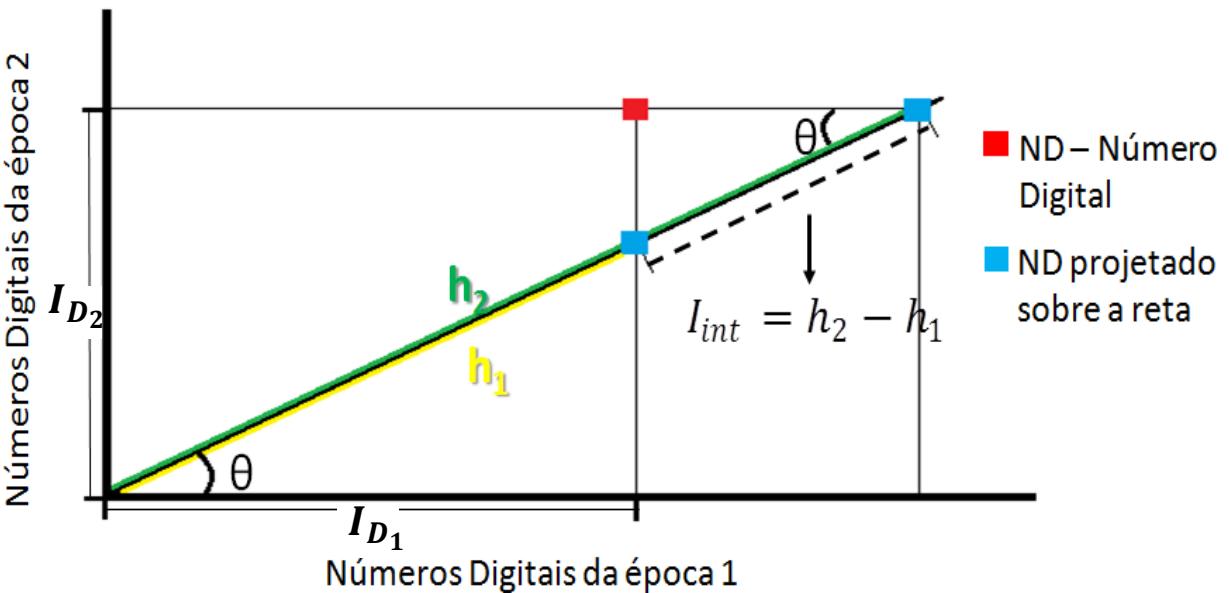
- A maioria dos pixels de duas imagens numa banda espectral de uma mesma região não se altera num curto período de tempo, principalmente em regiões monitoradas;
- O eixo de não mudança forma um ângulo θ que indica a posição relativa de não-mudança;
- O eixo de não-mudança é obtido por regressão linear dos valores radiométricos amostrados em locais de **não mudança**;
- Bandas espectrais adequadas devem ser escolhidas de acordo com o alvo de interesse;
- A compatibilidade radiométrica entre as bandas envolvidas é garantida;
- Robustez do método para comparar dados de diferentes sensores.

Como destacado anteriormente, um dos pressupostos considerado por Maldonado et al. (2007) ao aplicar o método, foi de que o eixo de não mudança é obtido a partir da informação em regiões onde não ocorreram mudança. Assim, se assumirmos que o nível de mudanças não é o que predomina ao comparar imagens de duas épocas, considera-se que o eixo de não mudança pode ser estimado a partir da imagem como um todo, ou seja, sem que seja feita uma pré-seleção de locais de não mudança.

Desta forma, passa-se a descrever o método de detecção denominado RCEN modificado. O ângulo de rotação θ (determinado pelo eixo de não mudança) é obtido pela aplicação de uma regressão linear nos valores de ND (Número Digital) de bandas espectrais correspondentes, sendo que pequenas variações na largura

de banda ou na sua sensibilidade podem ser assimiladas pela transformação aplicada. Deste modo, a partir de duas imagens (de duas épocas) de uma determinada banda, tem-se a Figura 6, que mostra alguns elementos essenciais para o desenvolvimento da equação que será desenvolvida.

Figura 6. Representação gráfica da linha de não mudança e do valor de I_{INT} .



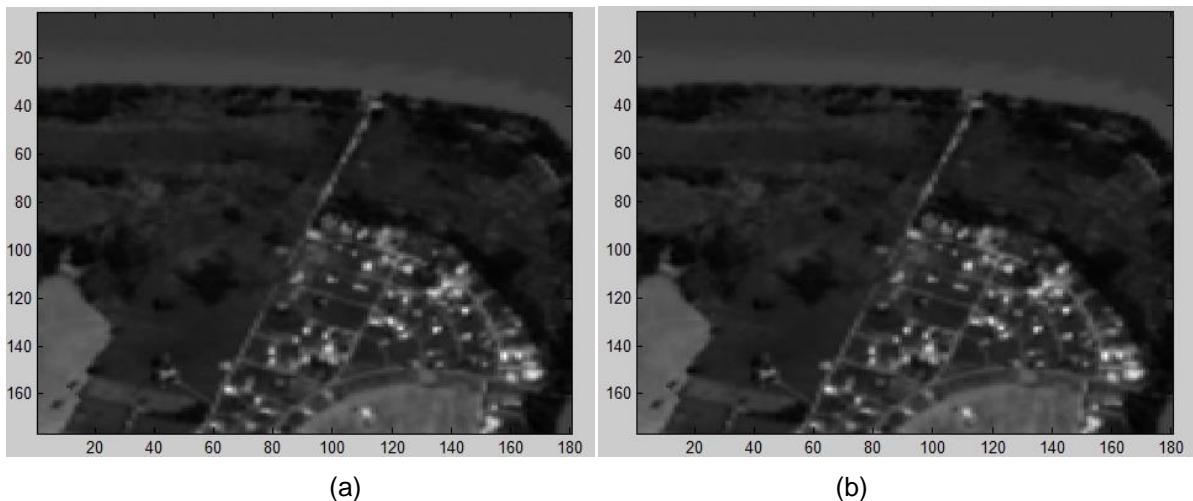
Considerando um determinado pixel com valores de I_{D1} e I_{D2} , nas duas épocas, respectivamente, caso eles estejam sobre a reta de coeficiente angular $\tan(\theta)$ significa que este pixel não apresentou mudanças. Caso este pixel esteja disposto como na Figura 6 (ponto em vermelho), a distância entre as projeções (em azul na figura) será um indicador de que este pixel sofreu mudanças entre as épocas analisadas. Assim, o valor de I_{int} poderá ser estimado pela diferença de distância $h_2 - h_1$. Deste modo, aplicando as funções trigonométricas adequadas a cada um dos triângulos pode-se determinar os valores de h_1 e h_2 em função dos valores de θ , I_{D1} , I_{D2} , bem como de b (coeficiente linear da reta de não mudança), ou seja:

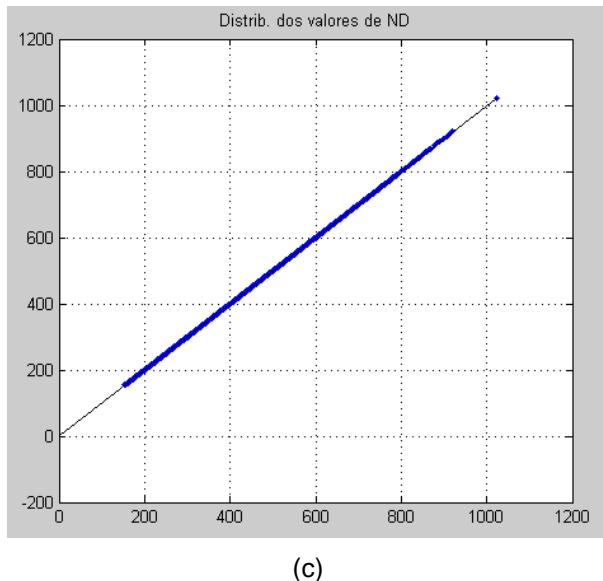
$$I_{INT} = (\cos \theta)^{-1} * I_{D1} - (\operatorname{sen} \theta)^{-1} * (I_{D2} - b). \quad (9)$$

A inserção do coeficiente linear é justificada pelo fato de que, segundo a Figura 6, a reta esta passando pela origem, ou seja, representando um caso ideal. Caso a reta não esteja passando pela origem é necessário que a mesma seja transladada para a origem, por meio do coeficiente linear. O resultado da operação acima produz a imagem intermediária (I_{int}), que tem relação com as mudanças ocorridas, ou seja, quanto maior for o valor resultante, maior será a mudança ocorrida. Pode-se notar na Figura 6 que os pontos a serem analisados (em vermelho no exemplo mostrado) podem estar acima ou abaixo da reta de coeficiente angular $\tan(\theta)$, o que resulta em valores positivos e negativos para I_{INT} .

Na sequência são ilustradas duas situações que permitem entender melhor o que foi apresentado em relação ao eixo de não mudança. Caso os valores de NDs das duas datas estejam sobre a reta de não mudança, a diferença resultante será nula, tendo-se uma situação ideal como mostrado na Figura 7.

Figura 7. Situação simulada onde não há mudança entre as datas, em (a) Imagem na época 1, em (b) Imagem na época 2 e em (c) Eixo de não mudança, situação ideal.



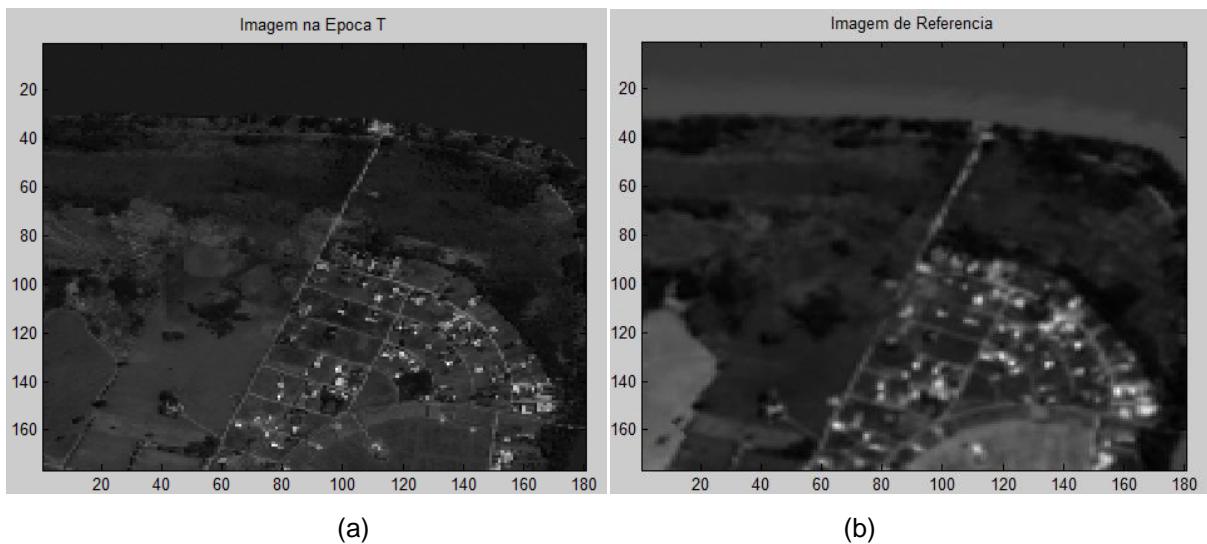


(c)

Nesta figura pode-se perceber que considerando uma situação hipotética onde não há mudanças entre as épocas, os NDs ficam sobre a reta, sem que haja uma dispersão. Neste exemplo utilizou-se o mesmo segmento de imagem nas duas épocas, apenas para efeito de simular uma situação ideal de não mudança.

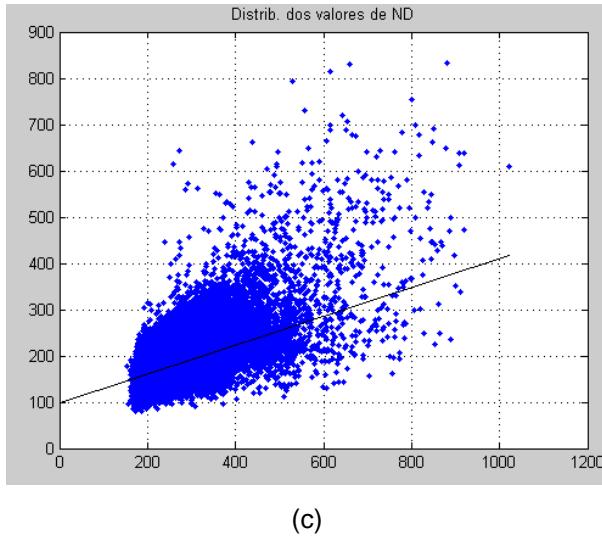
Quando se coloca um segmento de imagem diferente da época 1 (ver Figura 8), pode-se perceber a dispersão dos dados.

Figura 8. Situação simulada onde há mudança entre as datas, em (a) Imagem na época 1, em (b) Imagem na época 2 e em (c) Eixo de não mudança, situação real.



(a)

(b)



Com base nos valores intermediários calculados para cada banda espectral utilizada (nas duas datas), pela Equação 9, pode ser calculado o valor que deve indicar possíveis alterações. Na Equação 10 tem-se a imagem com o índice de alteração $I_{detecção}$ calculado a partir de quatro bandas multiespectrais:

$$I_{detecção} = I_{INT,B1} + I_{INT,B2} + I_{INT,B3} + I_{INT,B4} \quad (10)$$

sendo $I_{INT,Bi}$, com $i=1, 2, 3$ e 4 , os valores intermediários para quatro bandas. No presente caso estas bandas podem ser as 4 bandas multiespectrais do sensor SPOT-6.

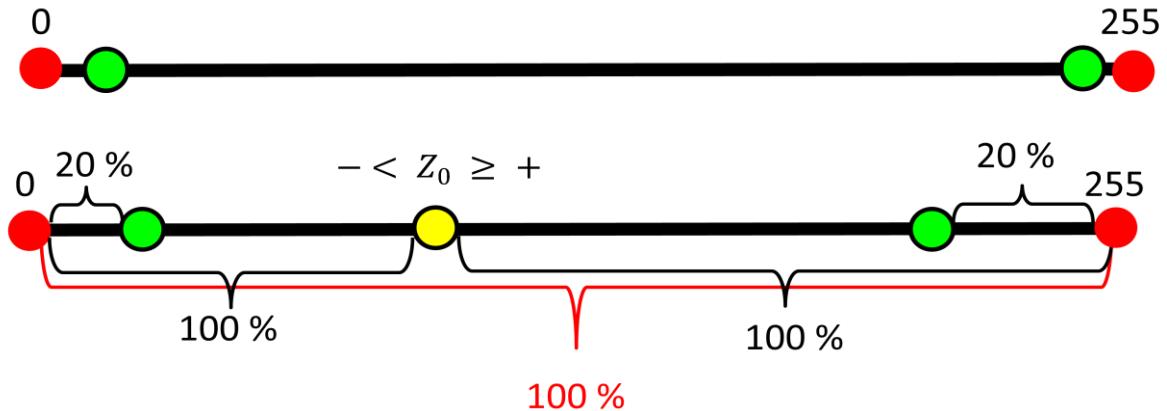
3.4 Seleção das mudanças mais significativas

Pode-se observar que ao usar a Equação 9 o resultado desta operação serão números reais, que podem ser tanto positivos quanto negativos. Como consequência, o resultado ao combinar as bandas (após Equação 10), também serão valores reais. Deste modo, para a visualização das mudanças mais significativas, tanto as que correspondem a novos objetos/feições quanto a objetos/feições que deixaram de existir, podem ser aplicados limiares para realçar as alterações detectadas. Inicialmente normalizam-se os dados da imagem $I_{detecção}$, que são números reais, para o intervalo $[0; 255]$. Após este passo é determinado, na escala com intervalo 0 - 255, o valor que corresponde ao ponto de não mudança, por

meio da Equação 11. Este ponto que corresponde ao valor nulo (ou ponto de não mudança) é chamando Z_0 (Figura 9).

Deste modo, ao observar a Figura 9 com mais cuidado percebe-se que ao mostrar todos os pontos acima do valor Z_0 , corresponderá a mostrar todos os pixels com mudanças de sinal positivo. De modo similar pode-se pensar para as mudanças com sinal negativo. Assim, caso seja de interesse detectar as mudanças mais significativas, por exemplo, as 20% maiores (como indicado a título de exemplo nesta figura) deve-se adotar um limiar (L_{PERC}) e determinar os limiares acima do Z_0 , e abaixo de Z_0 , que correspondem às L_{PERC} (%) maiores e menores mudanças, respectivamente. Estes valores podem ser determinados pelas Equações 12.

Figura 9. Ilustração do mapeamento do valor de Z_0 .



$$Z_0 = \left(\frac{255}{\max - \min} \right) * (- \min) \quad (11)$$

sendo: Z_0 o valor equivalente ao ND igual 0 na Equação 10. Os valores \min e \max , são os valores mínimos e máximos da $I_{detecção}$, respectivamente, e os valores L_{SUP} e L_{INF} os limiares superior e inferior obtidos por:

$$\begin{aligned} L_{SUP} &= 255 - \left((255 - Z_0) \left(\frac{L_{PERC}}{100} \right) \right) \\ L_{INF} &= Z_0 \left(\frac{L_{PERC}}{100} \right) \end{aligned} \quad (12)$$

sendo L_{PERC} o valor percentual utilizado.

Como pode-se perceber na Figura 9, o percentual não é calculado utilizando toda a reta e sim somente a parte correspondente à distância entre o valor Z_0 e 255, para limiares superiores e entre 0 e o valor Z_0 , para limiares inferiores. Isso permite identificar mudanças que estão acima e abaixo do eixo de não mudança na Figura 6.

3.5 Estudos preliminares e fluxograma do método proposto

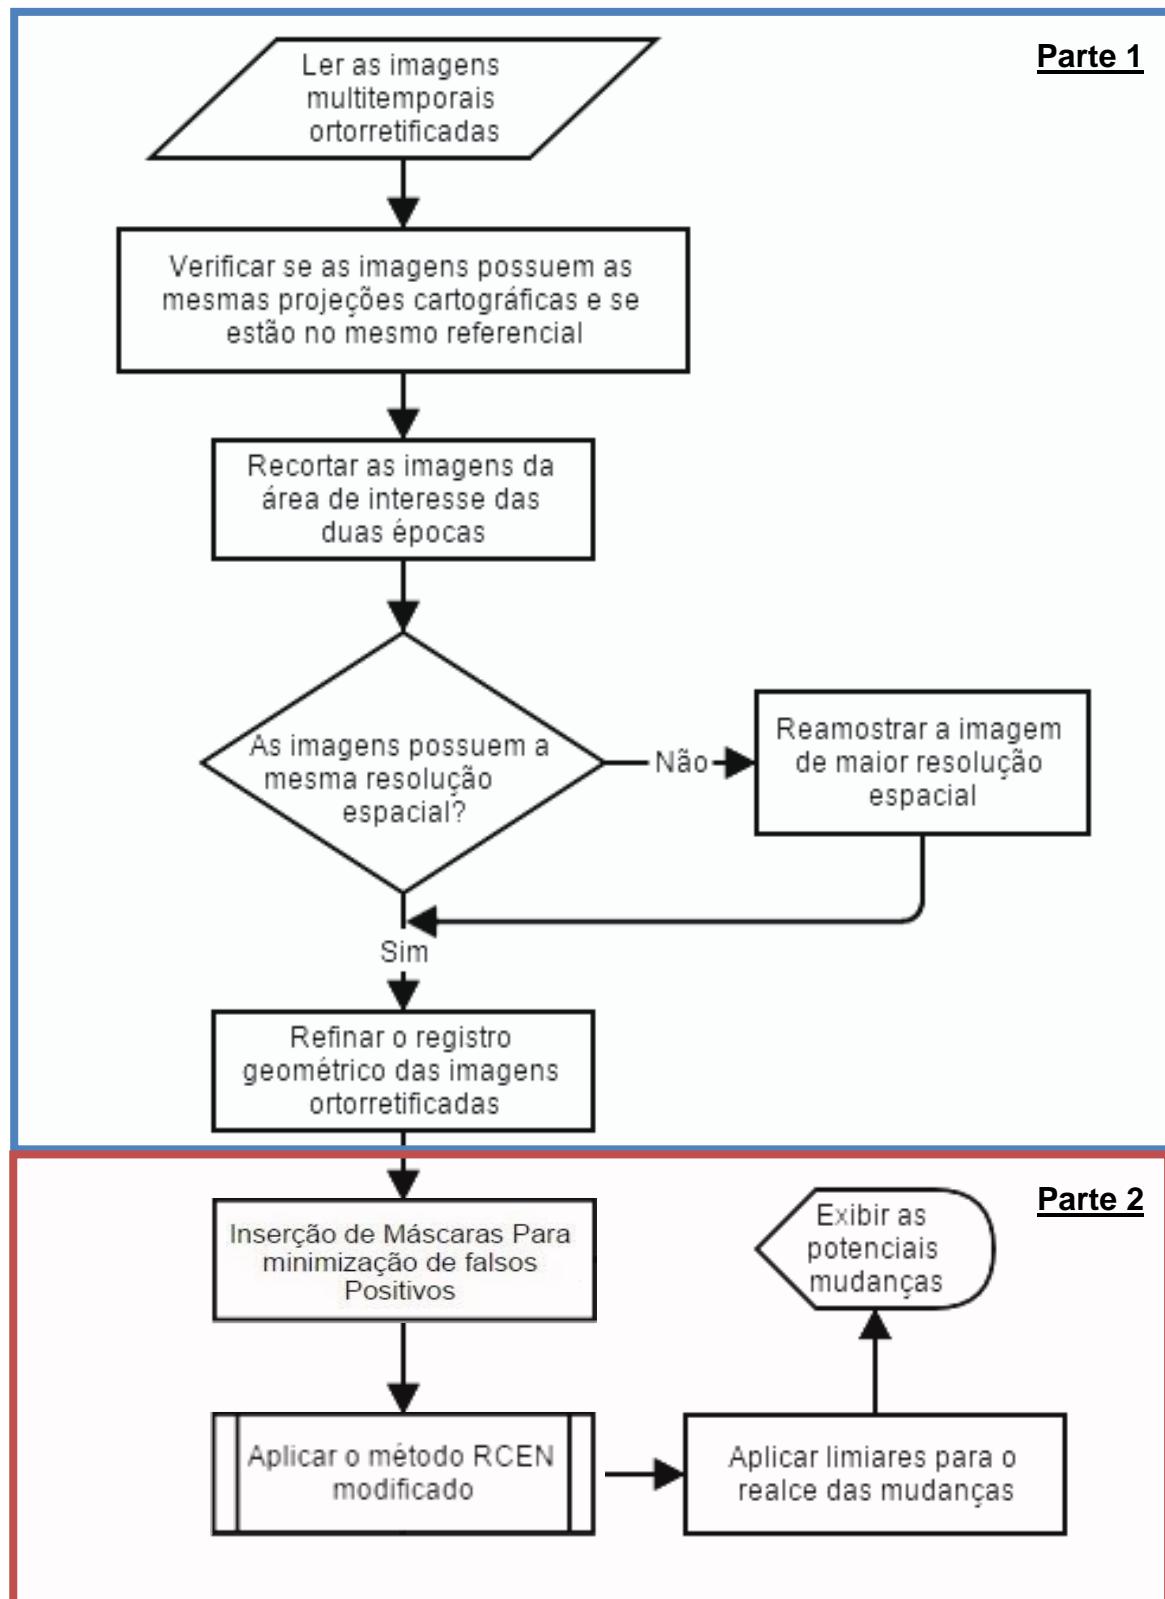
A proposta metodológica deste trabalho consiste em estudar os possíveis métodos de detecção de mudanças no entorno de reservatórios, a partir de uma série temporal de imagens orbitais e, com base neste estudo, fazer a seleção de um método (ou combinação deles) de modo a utilizar com dados reais de alguns dos reservatórios da empresa Duke Energy Brasil.

Como experimentos preliminares foram testados dois métodos de detecção de mudanças, de modo a compará-los e chegar a uma conclusão sobre qual dos métodos apresenta uma maior eficiência na detecção de mudanças, de modo automático. Os resultados preliminares apresentados em Imai et. al. (2015), mostraram que o algoritmo baseado no método RCEN modificado tem potencial para produzir informações adequadas para a análise automática de detecção de alterações, principalmente em comparação com o método de diferença de NDVI, onde o mesmo apresentou-se como sendo sensível a diferença sazonal entre as imagens. No método RCEN modificado a imagem de detecção final apresenta a contribuição das mudanças obtidas ao comparar uma mesma banda espectral, em diferentes datas, bem como outros conjuntos de bandas espectrais, dependendo do sensor utilizado. Esse resultado mostrou que o algoritmo tem comportamento robusto para o caso de imagens de períodos sazonais distintos e indica que as imagens intermediárias podem ser estudadas separadamente (usando distintas bandas), onde se notou que a banda 3 do sensor SPOT-6 é bem sensível a áreas que foram removidas, como, por exemplo, áreas com casas ou construções que estavam em situações ilegais e foram removidas de um ano para outro. Percebeu-se que a banda 1 do sensor SPOT-6, é sensível às construções que foram feitas entre as datas analisadas.

Outros métodos de detecção de mudanças, citados na Seção 2.5, foram analisados, como, por exemplo, o método de subtração de imagens, que trata-se de um método simples, porém inviável para uma detecção automática de mudanças, de modo que o mesmo possui uma grande sensibilidade ao fator sazonal. Portanto concluiu-se que para a detecção automática de alterações, estes métodos não seriam viáveis, pois a ideia é que o usuário tenha o mínimo de interferência e dentre os métodos estudados o método RCEN modificado apresentou resultados promissores.

Na sequência (Figura 10) é apresentado o fluxograma do método proposto.

Figura 10. Fluxograma do método proposto para a detecção de mudanças a partir de imagens.



O fluxograma é dividido em duas partes (1 e 2), onde a primeira parte é de responsabilidade do usuário. Nesta etapa as seguintes atividades devem ser realizadas:

- Verificar se as imagens das duas épocas em datas diferentes estão ortorretificadas;
- Verificar se as imagens, juntamente com a área de interesse, estão na mesma projeção cartográfica e no mesmo referencial;
- Verificar se as imagens possuem o mesmo tamanho do pixel, ou seja, se possuem GSDs (*Ground Sample Distance*) iguais. Esta etapa é de suma importância, pois a comparação é realizada pixel a pixel; e
- Refinar o registro geométrico ou verificar se o registro geométrico está correto.

Na próxima etapa (Parte 2) deve ser realizada a aplicação de máscaras, visando eliminar áreas que não são de interesse dos usuários, e que se mantidas no processamento geram um aumento nas detecções de mudanças que não são de interesse, prejudicando a análise. Exemplo: áreas de cultura no entorno do reservatório e fora da área de interesse. Após realizar as operações descritas anteriormente, deve-se aplicar a técnica de detecção de mudanças apresentada na Seção 3.3, sendo esta parte automatizada, não necessitando da interferência do usuário. Logo em seguida, realiza-se a validação do algoritmo, analisando os parâmetros de qualidade descritos na Seção 2.6. Os parâmetros são analisados para cada limiar de 5 a 95%, em intervalos de 5%, totalizando 19 limiares. Os limiares são calculados como descrito na Seção 3.4, onde destacam-se as feições mais relevantes para o usuário. O processamento das imagens para os diferentes limiares justifica-se, uma vez que a ideia é determinar, por meio de dados experimentais, qual o limiar mais adequado para a detecção de determinado tipo de alvo.

Destaca-se que a etapa de refinamento do registro geométrico das bandas foi realizada com o software ENVI 5.0.

4 EXPERIMENTOS E DISCUSSÃO DOS RESULTADOS

Neste capítulo são apresentados os experimentos realizados, os resultados obtidos bem com a discussão dos mesmos.

4.1 Descrição dos experimentos

Uma vez definido o método a ser testado foram realizados alguns experimentos visando avaliar os diferentes aspectos, como descrito na sequência:

a) Experimentos preliminares:

Nestes experimentos o procedimento proposto no fluxograma da Figura 10 foi aplicado ao conjunto de bandas (Vermelho, Verde, Azul e Infravermelho Próximo) do sensor SPOT 6;

b) Análise da obtenção do coeficiente angular:

Nestes experimentos procura-se avaliar o efeito do uso de pontos de não mudança, ou de toda a imagem, nos resultados;

c) Efeito da correção atmosférica na detecção de mudanças:

Estes experimentos são realizados com o propósito de verificar a influência da correção atmosférica na detecção de mudanças;

d) Efeito da exclusão de áreas que não são de interesse na minimização de falsos positivos:

Estes experimentos são destinados a avaliar os efeitos da exclusão de algumas áreas, que não são de interesse, na redução do número de falsos positivos no método proposto;

e) Influência das bandas multiespectrais na detecção de mudanças:

Uma vez que no método proposto é prevista a combinação das bandas, é possível que sejam consideradas diferentes combinações destas bandas, visando verificar quais delas são mais adequadas a alguns objetos de interesse. Deste modo, nesta seção são avaliadas a contribuição de cada uma destas bandas, individualmente, com base nos indicadores de qualidade,

antes de realizar as combinações. Estas análises são apresentadas para cinco áreas testes, com características diferentes.

f) Efeito da combinação das bandas:

Com base nos resultados da análise da ponderação das bandas são realizados testes efetuando algumas combinações de bandas, visando indicar as bandas mais adequadas e os limiares sugeridos em cada caso.

4.2 Experimentos preliminares

Como brevemente descrito, nesta seção são apresentados os resultados preliminares obtidos ao aplicar o método proposto ao conjunto de imagens do reservatório de Canoas I. Nas Figuras 11 e 12 são mostradas as combinações coloridas, nas duas datas e na Figura 13 a imagem $I_{detecção}$ obtida.

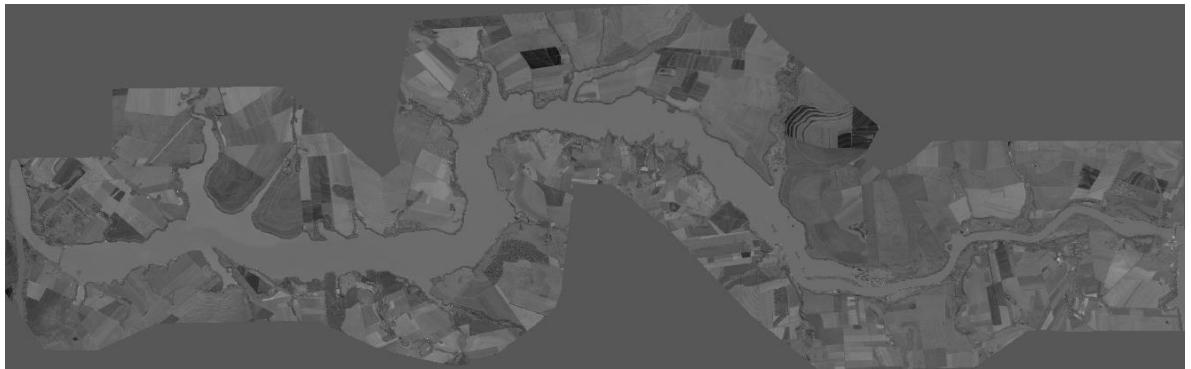
Figura 11. Imagem do reservatório de Canoas I, do sensor SPOT-6, com a combinação colorida (R, G e B), para a data de 05/11/2012.



Figura 12. Imagem do reservatório de Canoas I, do sensor SPOT-6, com a combinação colorida (R, G e B), para a data de 29/04/2013.



Figura 13. Imagem $I_{detecção}$.



Para a obtenção da imagem $I_{detecção}$ (Figura 13), foram geradas imagens intermediárias (I_{INT}) para cada banda multiespectral. Nas Figuras 14, 15, 16 e 17 são mostradas as imagens intermediárias resultantes da aplicação da Equação 9 a cada uma das bandas espectrais.

Figura 14. $I_{INT\ B1}$, Banda Intermediária do Vermelho, do sensor SPOT-6.

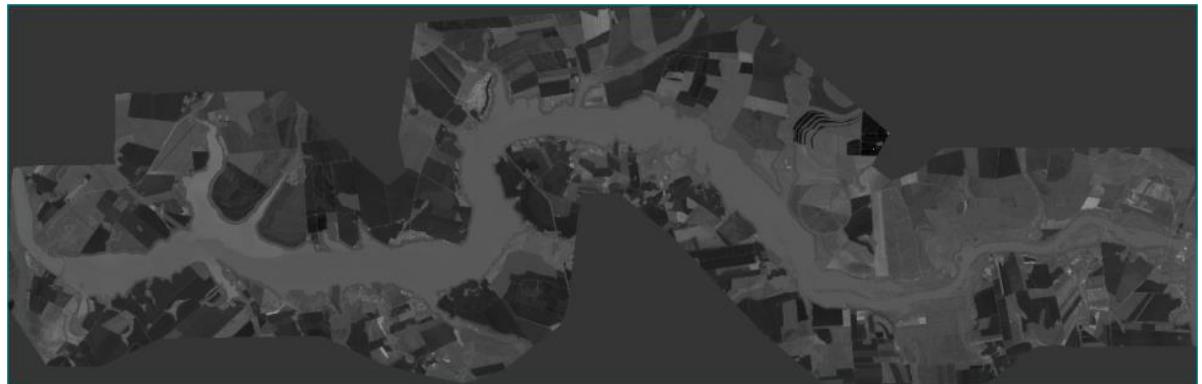


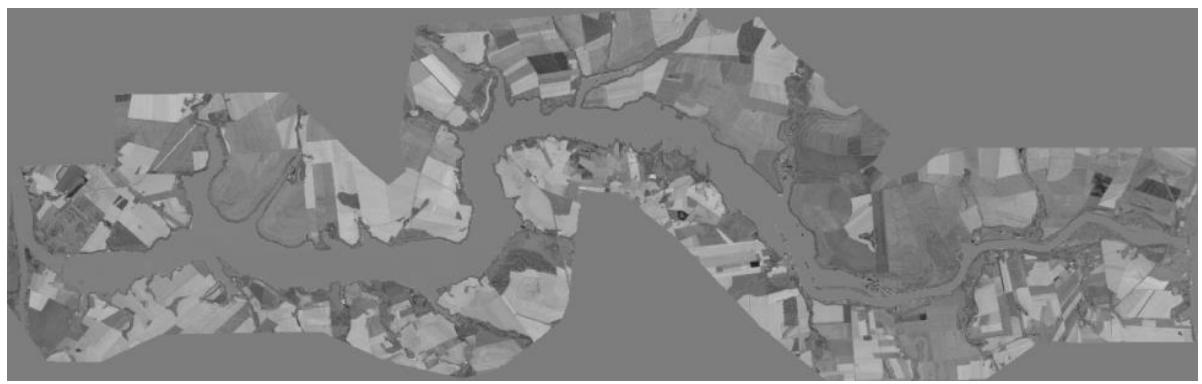
Figura 15. $I_{INT\ B2}$, Banda Intermediária do Verde, do sensor SPOT-6.



Figura 16. $I_{INT\ B3}$, Banda Intermediária do Azul, do sensor SPOT-6.



Figura 17. $I_{INT\ B4}$, Banda Intermediária do Infravermelho Próximo, do sensor SPOT-6.



Na Figura 18 estão destacadas as modificações indicadas pelo algoritmo RCEN modificado, com um limiar de 75%. Nesta figura, e nas demais, as regiões dentro da área de interesse (limitadas pela linha amarela) marcadas em branco correspondem ao limiar superior e as destacadas da cor preta o limiar inferior.

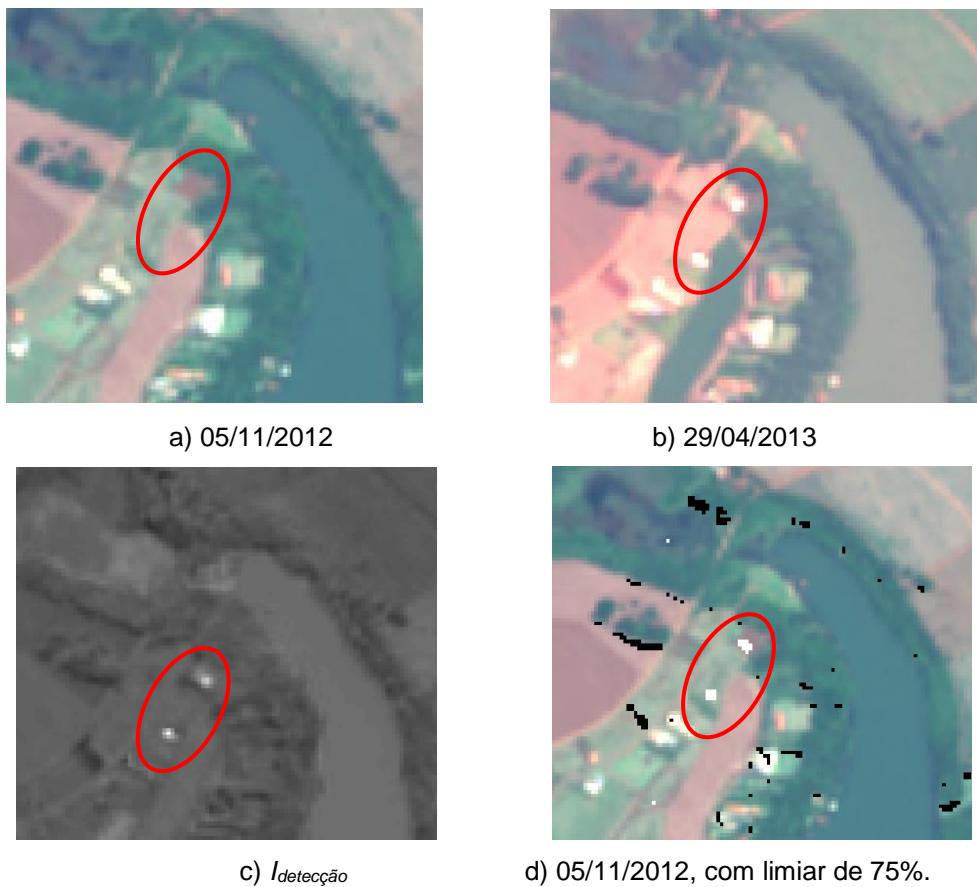
Figura 18. Imagem do reservatório de Canoas I, para a data de 05/11/2012, com a representação do limite da área de interesse e as detecções realçadas.



Como na Figura 18 a visualização dos resultados é feita para uma região extensa do reservatório, serão mostradas na sequência algumas áreas em separado, que permitirá uma análise visual mais detalhada.

Na área 1, representada na Figura 19, pode-se observar algumas regiões em separado (em vermelho), que contém duas casas que foram construídas entre as épocas analisadas. Na época 1 estas casas não existiam e foram construídas antes da época 2, assim sendo estas modificações teriam que apresentar uma cor mais clara (na imagem de detecção). Considerando o intervalo [0; 255], estas modificações estariam mais próximas dos valores de 255, como pode ser observado nas Figuras 19.c e 19.d.

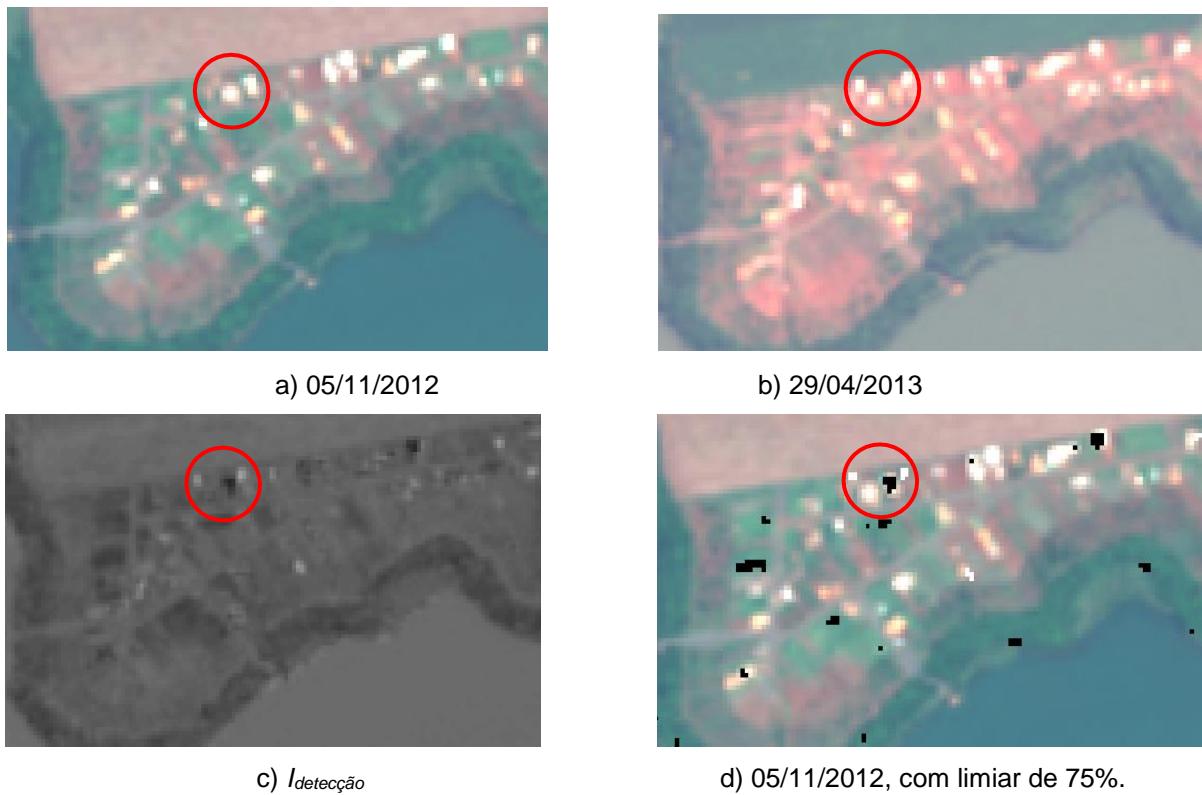
Figura 19. Área teste 1, com destaque para a construção de duas casas.



Na área 2 (Figura 20), pode-se ver algumas modificações destacadas (em vermelho). Na época 1 algumas casas não existiam e foram registradas na época 2. Do mesmo modo que na área 1, estas modificações teriam que apresentar uma cor mais clara, considerando o intervalo [0; 255] e o limiar adotado. Já no caso da casa que foi removida de uma época para outra, o comportamento é ao contrário, e esta

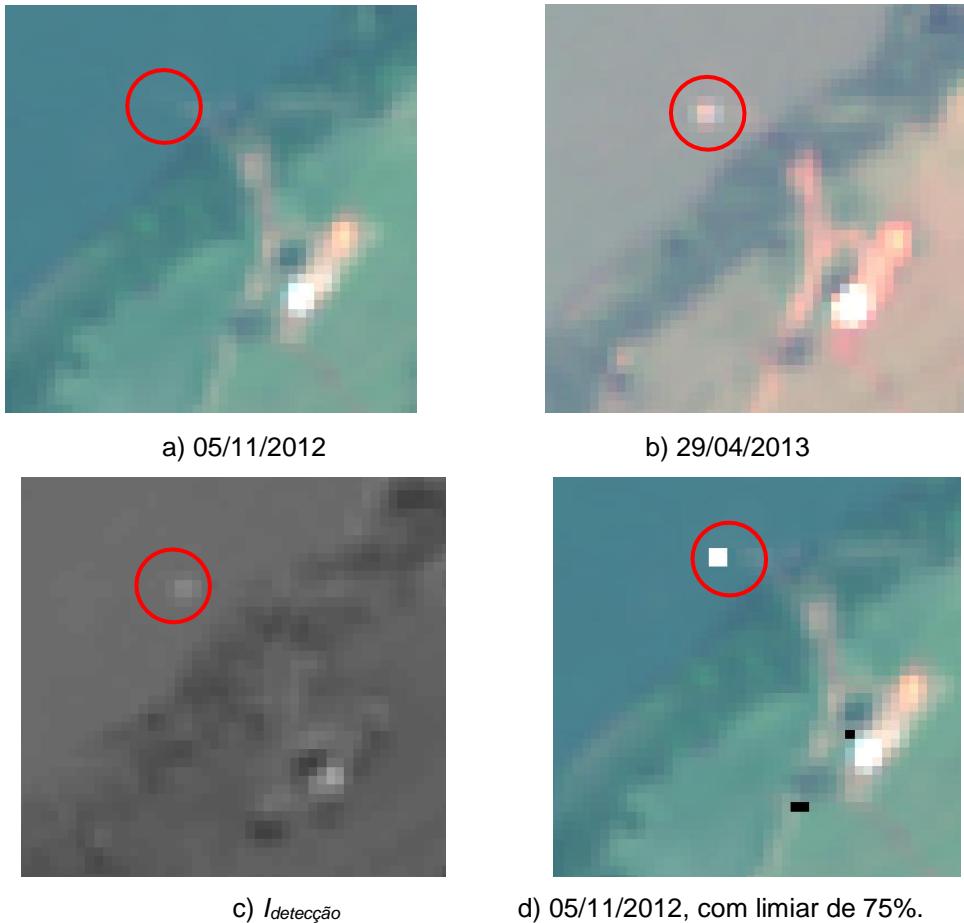
modificação teria que apresentar uma cor mais escura. Ambas as ocorrências podem ser observadas na Figura 20.d.

Figura 20. Área teste 2, com destaque para a remoção de uma casa.



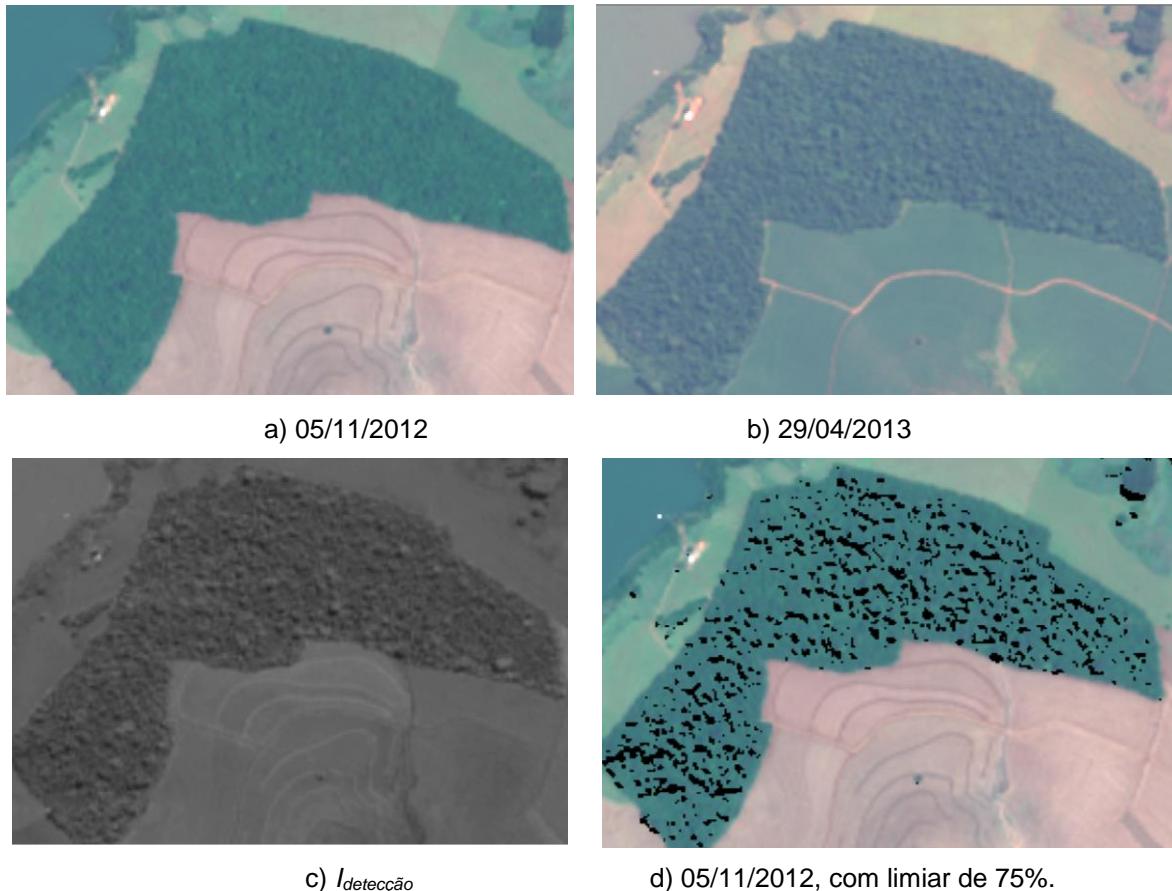
Na área 3, representada pela Figura 21, pode-se ver uma modificação em destaque sobre a lâmina d'água, que corresponde a um tanque rede, intervenção muito encontrada sobre o rio. Como dito anteriormente, esta alteração estaria representado pela cor branca, pois corresponde a uma feição ou objeto que foi construída de uma época para outra. Na Figura 21.d. pode-se notar que a alteração foi detectada.

Figura 21. Área teste 3, com destaque para a construção de um tanque rede.



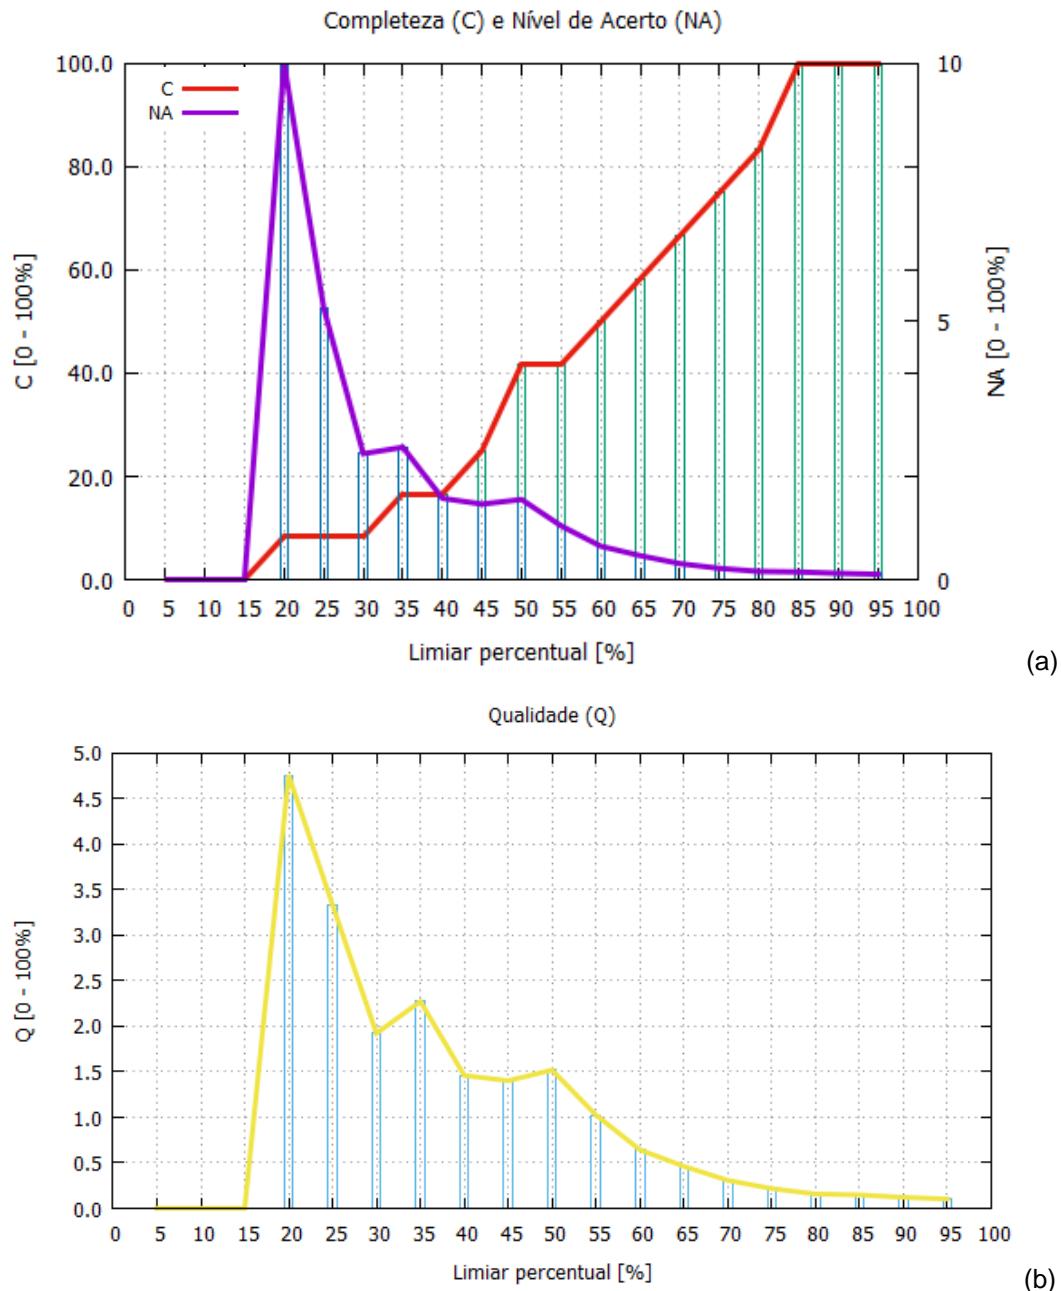
A última área teste, de número 4, é mostrada na Figura 22. As modificações representam as sombras que foram detectadas pelo algoritmo. Este tipo de detecção na realidade é um problema para a validação do algoritmo, pois embora as mesmas se apresentem como modificações nas imagens, elas não são modificações de interesse para o usuário.

Figura 22. Área teste 4 com destaque para a detecção de sombras em uma mata natural.



Assim, tais modificações acabam por prejudicar os resultados da avaliação quantitativa do algoritmo, como pode-se perceber nos gráficos das Figuras 23 e 24, onde são mostrados os indicadores de completeza, nível de acerto e qualidade para os diferentes limiares, para toda área de estudo.

Figura 23. Parâmetros de qualidade para o reservatório de Canoas I, sendo em (a) Comparação entre a completeza e o nível de acerto e (b) qualidade.



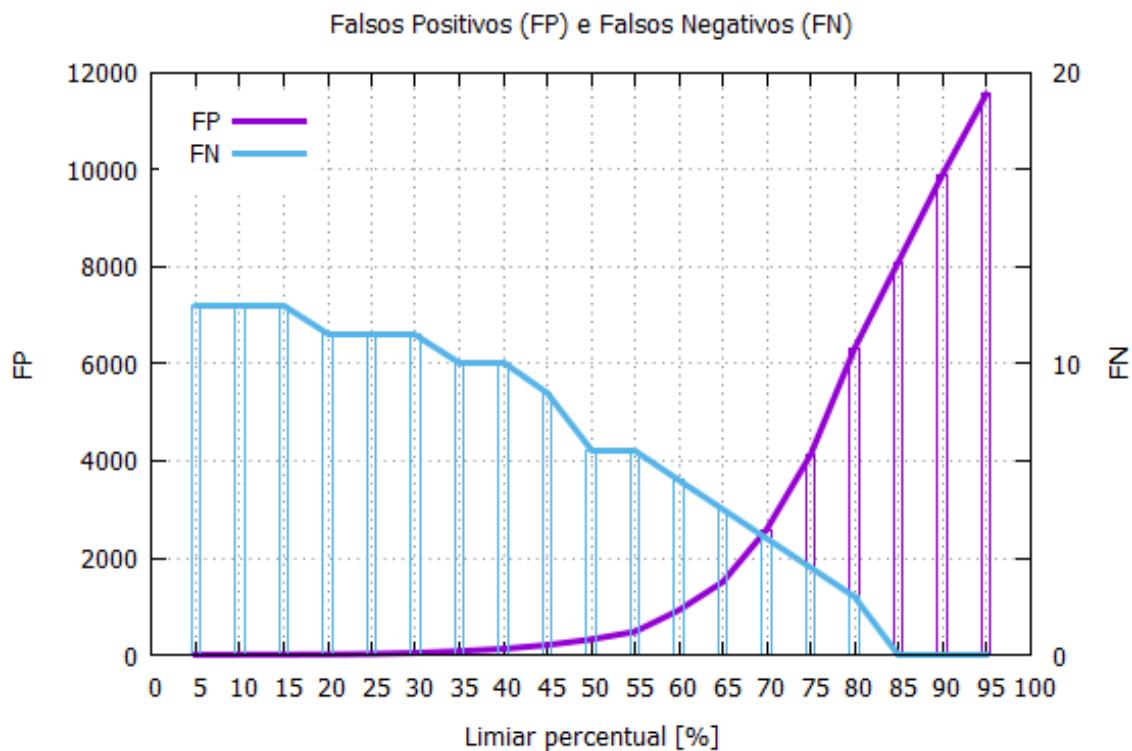
A completeza pode ser considerada boa, a partir do limiar de 75%, onde este indicador atingiu valores superiores a 70%. Estes valores indicam que o algoritmo RCEN modificado é eficaz na detecção de mudanças, dependendo do limiar considerado.

Já o nível de acerto, não apresentou bons resultados, não ultrapassando os 14%. Isto é justificado pelo fato de que o algoritmo está encontrando muitas alterações e muitas destas alterações não são alterações de interesse para o

usuário, como sombras, por exemplo. O nível de acerto é um parâmetro que é calculado pela razão entre o número de detecções coincidentes aos polígonos de referência e o número total de alterações, ou seja, quanto maior for este número de alterações encontradas mas que não sejam coincidentes com os polígonos de referência, isto é, quanto maior forem os falsos positivos, menor será o nível de acerto. Comparando o nível de acerto com a completeza, percebe-se uma disparidade, o que é justificado pelo fato da completeza não ser afetada pela quantidade de falsos positivos (ver Figura 24).

O parâmetro qualidade (Figura 23.b) é calculado com base nos dois indicadores anteriores. Como o nível de acerto resulta em valores baixos, pela quantidade elevada de falsos positivos, consequentemente o parâmetro qualidade será baixo.

Figura 24. Gráfico com a comparação entre os Falsos Positivos e os Falsos Negativos.



Pode-se perceber pela Figura 24, que a quantidade de falsos negativos tende a diminuir quando se aumenta a porcentagem dos limiares para a detecção e o número de falsos positivos a crescer. Considerando que o propósito é determinar as modificações ocorridas concluiu-se que uma preocupação é o número de falsos

negativos, pois ele representa as modificações que existem, mas o algoritmo não detectou. Pode-se perceber que, com base nestes experimentos, a quantidade de falsos negativos é baixa a partir de um limiar de 75%. Porém, é possível de diminuir ainda mais, com estudos mais detalhados em que as bandas possam ser combinadas. Os falsos positivos não são tão preocupantes quanto os falsos negativos, pois podem ser eliminados pelo usuário por uma rápida análise visual. Porém, este alto valor dos falsos positivos inviabiliza os estudos utilizando os indicadores completeza, nível de acerto e qualidade, visando a escolha ou indicação de um limiar fixo para a detecção das alterações.

Sendo assim, experimentos adicionais foram executados para atenuar a quantidade de falsos positivos, assim como tentar melhorar também a quantidade de falsos negativos, para que se possa analisar quantitativamente os resultados e poder adotar um limiar fixo para as alterações.

4.3 Análise da obtenção do coeficiente angular

Nos experimentos apresentados na seção anterior o coeficiente angular foi calculado utilizando os valores de todos os NDs de cada banda multiespectral. Foi possível perceber que o algoritmo conseguiu detectar mudanças de interesse, mas também mudanças que não são de interesse do usuário. Visando reduzir a detecção de mudanças que não são de interesse, pode-se aplicar o procedimento a uma região limitada, que pode ser definida por um *buffer* envolvendo apenas esta região. Na Figura 25 é mostrada uma das imagens de entrada, juntamente com um *buffer* delimitando a área de interesse, podendo-se aplicar o mesmo procedimento apenas nesta região.

Figura 25. Imagem do reservatório de Canoas I, do sensor SPOT-6, com a combinação colorida (R, G e B), para a data de 05/11/2012, sendo mostrado em amarelo os limites da área de interesse.



Como mencionado, o coeficiente angular foi calculado a partir da Equação 3, utilizando todos os valores de ND das imagens. Visando ver o efeito do uso dos ND's de todas as imagens, os ND's apenas nos pontos de não mudança e os ND's na região de interesse, as seguintes comparações foram realizadas:

- Utilizando os ND's de toda imagem (Figuras 11 e 12);
- Utilizando os ND's apenas de não mudança (Figura 26); e
- Utilizando os ND's apenas da área de interesse (Figura 25).

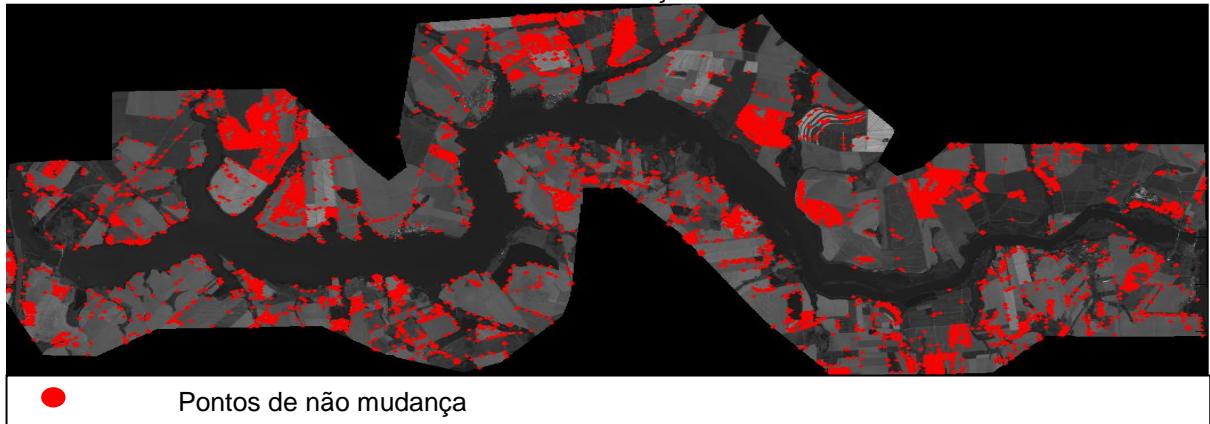
Para a extração dos pontos, utilizou-se da reta de não mudança gerada através da regressão linear. O método baseia-se em aplicar a Equação 13 para extrair os pontos de não mudança, ou seja:

$$Y_{D2(i,j)} = \text{coef}_{ANG} * I_{D1(i,j)} + \text{coef}_{LIN} \quad (13)$$

sendo: Y_{D2} o valor de ND do pixel (i,j) calculado para época 2; coef_{ANG} e coef_{LIN} os coeficientes angular e linear, respectivamente, calculados através de uma regressão linear e I_{D1} os ND's correspondentes aos mesmos pixels para a época 1.

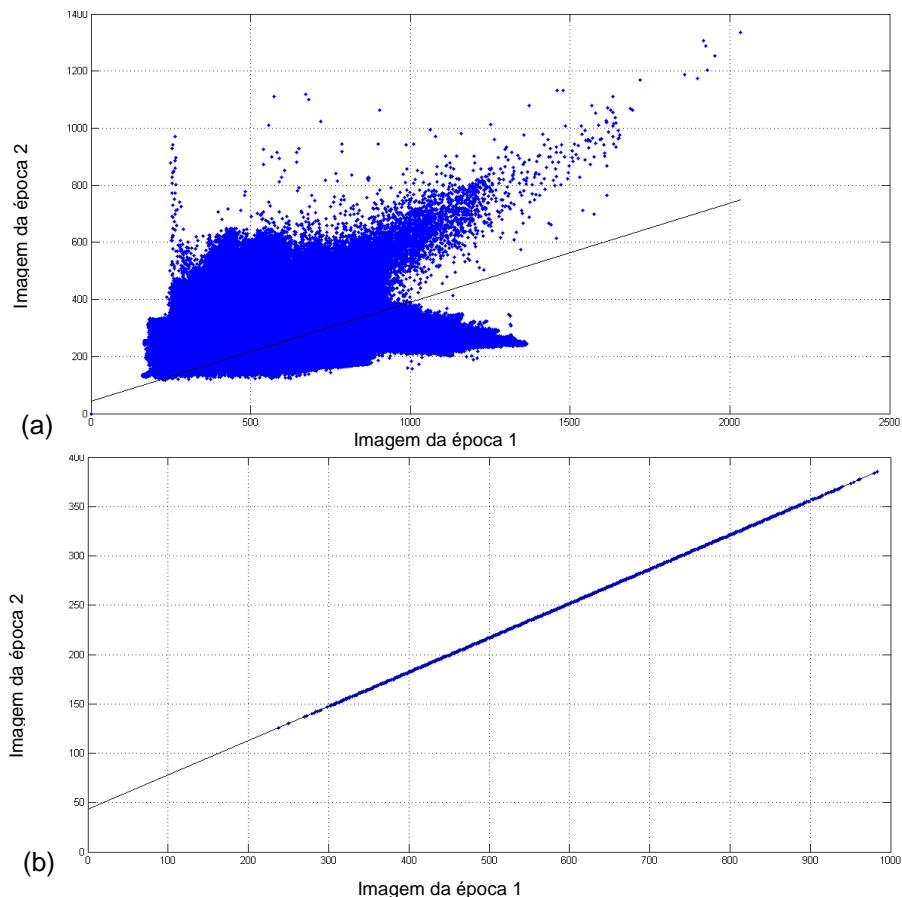
Como Y_{D2} é calculado pixel a pixel, após o cálculo o valor é comparado com o ND da I_{D1} , na mesma posição de coluna e linha de Y_{D2} . Assim se este valor for igual em Y_{D2} e I_{D1} , o valor de coluna e linha é armazenado em um vetor representando os pixels de não mudança. Na Figura 26 é mostrado em vermelho os pixels correspondentes às regiões de não mudança.

Figura 26. Banda do Vermelho do sensor Spot-6 em 05/11/2012, com destaque para os pontos de não mudança.



Ao total foram gerados 9621 pontos, utilizando a Banda do Vermelho do sensor SPOT-6, em ambas as épocas. Para verificar se os pontos estavam corretos, comparou-se os dois gráficos de dispersão (Figuras 27.a e 27.b).

Figura 27. Distribuição dos valores de ND, em a) ND's de toda imagem, em b) ND's dos pontos de não mudança.



A partir disso foram calculados os dois coeficientes angular, como pode

ser visto no Quadro 2.

Quadro 2. Cálculo dos coeficientes angular, aplicado aos dois testes (a) e (b).

Testes	Coeficiente Angular
(a)	0,347749322
(b)	0,347757578

Como visto no Quadro 2, ao calcular o coeficiente angular utilizando todos os ND's das imagens ou utilizando somente os ND's de não mudança, percebe-se uma pequena mudança no coeficiente angular. Ao aplicar o método proposto, nestas duas situações percebeu-se que não houve diferença significativa a ponto de influenciar nos resultados da detecção de mudança. Assim, optou-se em continuar calculando o coeficiente angular utilizando todos os ND's, para otimizar o processo.

Entretanto, ao verificar a Figura 25, nota-se que as áreas em preto (área onde não tem informação) foram preenchidas com valores de ND igual a 0, representando então os pixels de *No Data*, que a rigor não devem ser utilizados no cálculo do coeficiente angular. Sendo assim resolveu-se calcular o coeficiente angular somente para região de interesse (dentro do *buffer* mostrado na Figura 5), sendo os resultados apresentados no Quadro 3.

Quadro 3. Cálculo dos coeficientes angular, aplicado aos dois testes (a) e (c).

Testes	Coeficiente Angular
(a)	0,347749322
(c)	0,812523287

Percebe-se no Quadro 3 que houve uma diferença significativa entre os dois coeficientes, sendo feita a opção de utilizar o coeficiente angular estimado ao utilizar apenas os pixels dentro da área de interesse.

4.4 Análise da influencia da correção atmosférica na detecção de mudanças

A correção atmosférica na detecção de mudanças é um passo primordial para que haja sucesso na extração das informações, pois como dito na Seção 2.3, vários fatores presentes na atmosfera pode influenciar na resposta dos alvos.

Porém, como o foco deste trabalho não é no estudo de parâmetros biogeofísicos que necessitam de grandezas radiométricas propriamente ditas (radiância e reflectância, por exemplo) optou-se por não aplicar uma correção atmosférica absoluta, mas simplesmente uma correção radiométrica relativa. Além desta justificativa deve-se considerar que a detecção de mudanças pretendida visa indicar onde houve ou não uma mudança, sem que haja informação da proporção de modificação; e também pelo fato de que neste projeto trata-se de uma detecção de mudanças de forma automatizada, isto é, que não haja interferência do usuário e que o mesmo não necessite ser especializado na área de detecção de mudanças (ou de Sensoriamento Remoto). Deste modo, a fim de avaliar os efeitos do uso ou não desta correção, alguns experimentos foram realizados.

Como mencionado, a correção atmosférica é aconselhável para minimização dos efeitos atmosféricos. Como resultado, os valores registrados na imagem são transformados em reflectância de superfície e podem ser utilizados em casos específicos onde a grandeza radiométrica pode ser relacionada com parâmetros biogeofísicos, por exemplo. No caso de detecção de mudanças, essa detecção pode ser realizada com valores de número digital (ND's) já que se trata de uma diferença de imagens em duas épocas. Visando a avaliar as interferências da atmosfera na detecção de mudanças, e verificar o seu efeito, foi realizado um teste de correção atmosférica empírica, ou seja, considerando apenas as informações da própria cena, ou seja, usando o método o *Dark Object Subtraction* (DOS), como descrito na Seção 2.3.

O modelo de correção atmosférica absoluta DOS utiliza os pixels que teoricamente teriam valor nulo, ou seja, que não refletiriam radiação, absorvendo-a totalmente. Sendo assim, foram analisados os histogramas gerados por cada banda multiespectral para cada época (Figuras 28 e 29), sendo observados os valores mínimos das imagens em que a curva espectral muda de comportamento, onde percebe-se uma mudança significativa no histograma e, consequentemente, uma quantidade representativa de pixels que representem um alvo escuro. Os pixels com valores menores a estes, sem uma mudança significativa, podem ser considerados como ruídos.

Figura 28. Histogramas das quatro bandas multiespectral do sensor SPOT-6, do reservatório de Canoas I, na data de 05/11/2012.

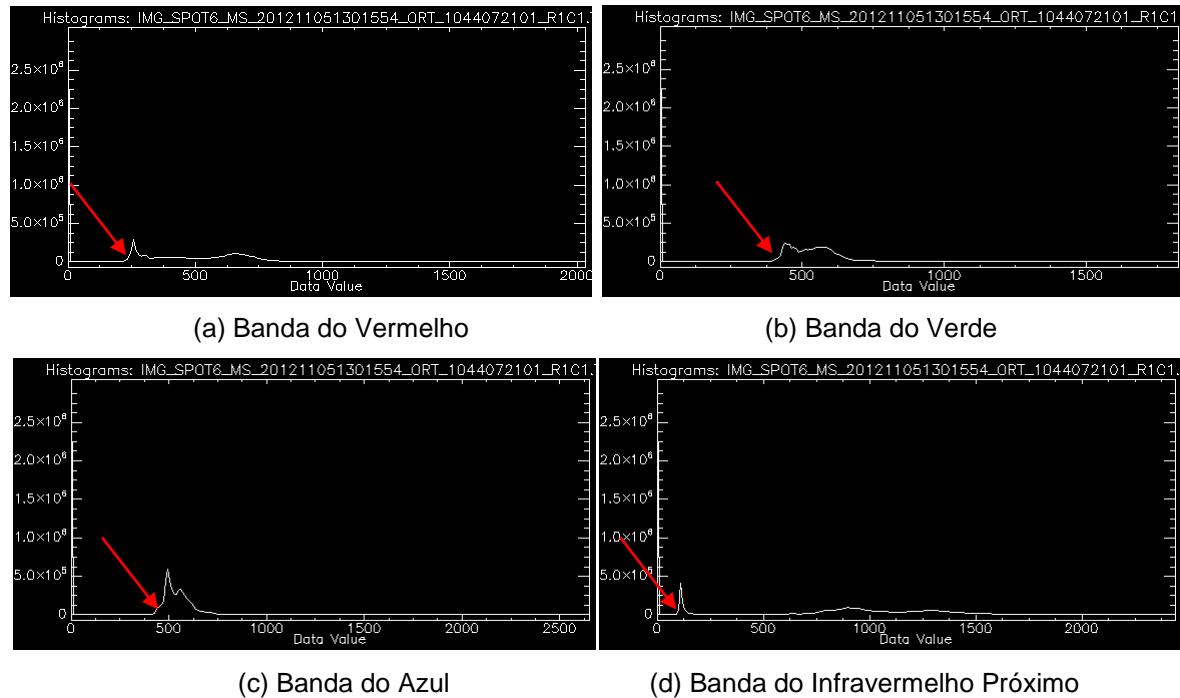
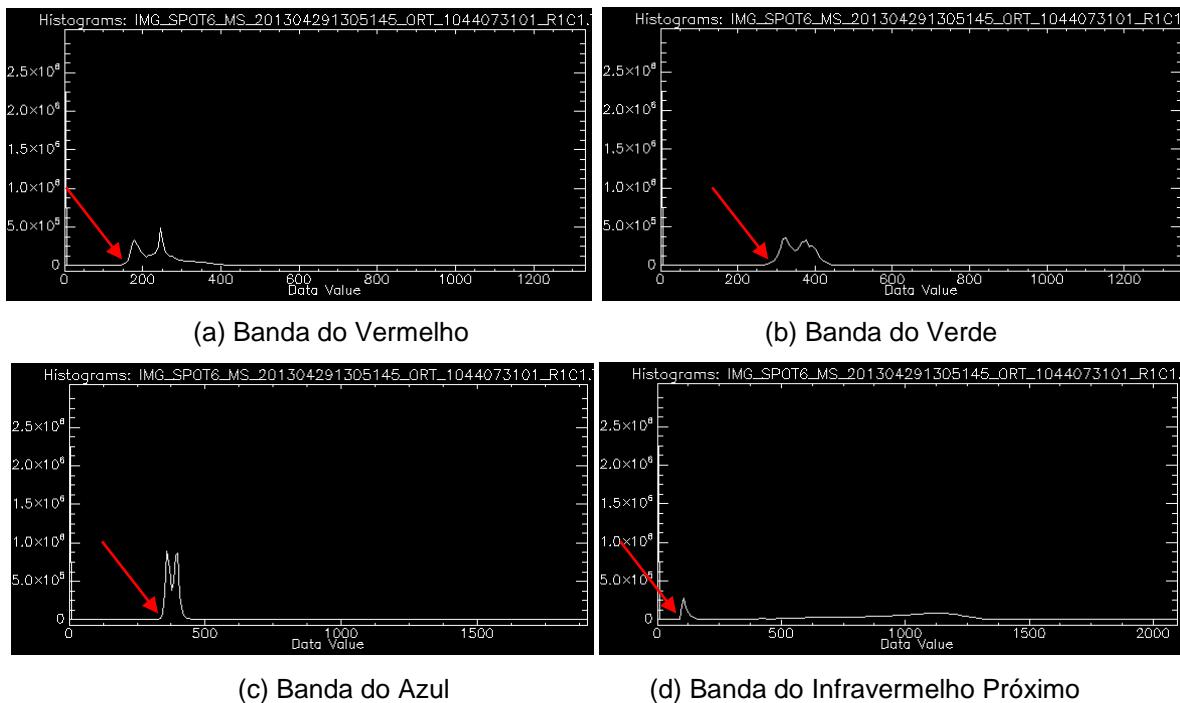


Figura 29. Histogramas das quatro bandas multiespectral do sensor SPOT-6, do reservatório de Canoas I, na data de 29/04/2013.



No Quadro 4 são mostrados os valores que foram extraídos dos

histogramas das imagens referidas, para cada banda multiespectral e nas duas épocas.

Quadro 4. Valores mínimos extraídos dos histogramas gerados para cada banda multiespectral.

Bandas	05/11/2012	29/11/2013
	$V_{mín_{Bi}}$	$V_{mín_{Bi}}$
Vermelho	224	156
Verde	408	194
Azul	429	344
Infravermelho Próximo	100	90

A partir dos valores mostrados no Quadro 4 e com os valores dos ND's das imagens, ao invés dos valores de reflectância, como sugerido pelo método original proposto (CHAVEZ, 1988) foi feita a correção por meio do uso da Equação 14. Deste modo, foram geradas as imagens atmosfericamente corrigidas, a partir da aplicação do método DOS, ou seja, obtendo imagens nas quais os valores dos pixels apresentem menor influência do espalhamento atmosférico (efeito aditivo).

$$I_{corr} = I_{D_i} - V_{mín_{Bi}} \quad (14)$$

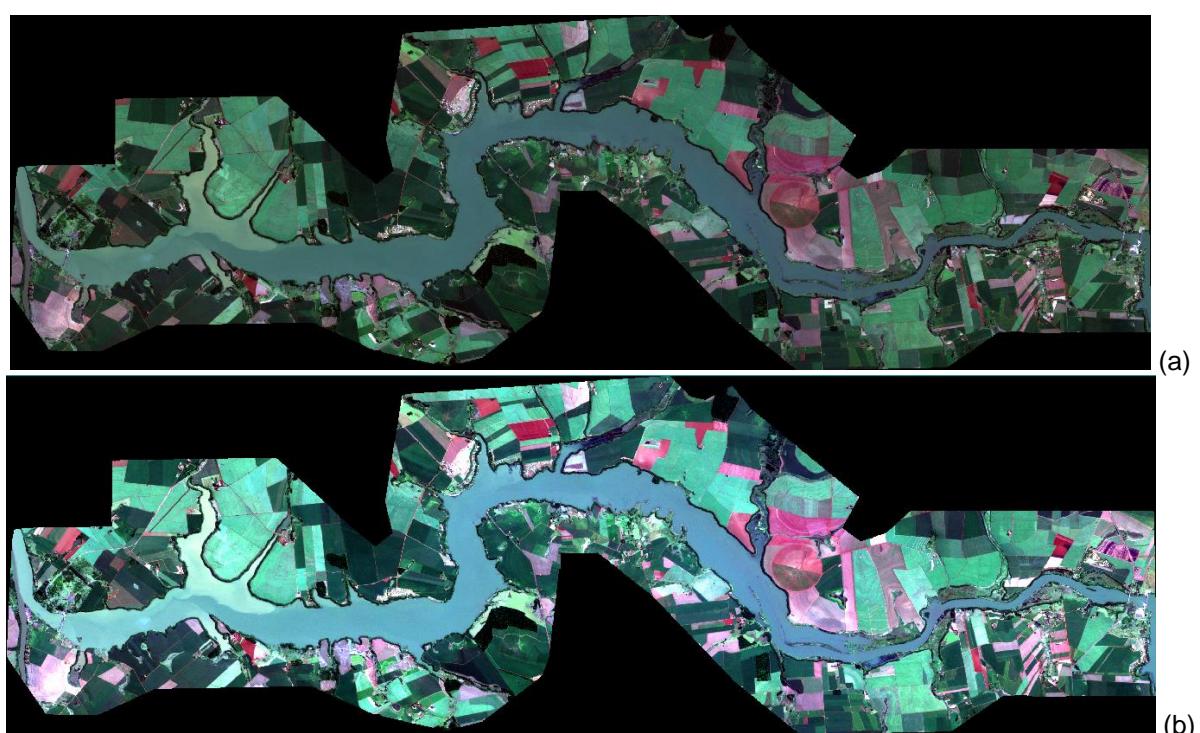
sendo: I_{corr} a imagem corrigida atmosfericamente, I_D a imagem na época i , o $V_{mín_B}$ os valores extraídos dos histogramas, onde $i = 1$ e 2 .

Nas Figuras 30 e 31, verifica-se a diferença visual entre as imagens originais e as imagens corrigidas atmosfericamente por este procedimento.

Figura 30. Correção atmosférica, em (a) a Imagem original e em (b) Imagem corrigida atmosféricamente pelo método DOS, ambas imagens do sensor SPOT-6, reservatório de Canoas I, na data de 05/11/2012.



Figura 31. Correção atmosférica, em (a) a Imagem original e em (b) Imagem corrigida atmosféricamente pelo método DOS, ambas imagens do sensor SPOT-6, reservatório de Canoas I, na data de 29/04/2013.



Após a aplicação da correção pelo método DOS às imagens, o procedimento de detecção de mudança foi realizado com estas imagens, podendo-se ver o efeito do seu uso nos indicadores de qualidade completeza, nível de acerto e qualidade, como mostrado nas Figuras 32 e 33.

Figura 32. Comparação dos parâmetros de qualidade em áreas, com e sem aplicação da correção atmosférica.

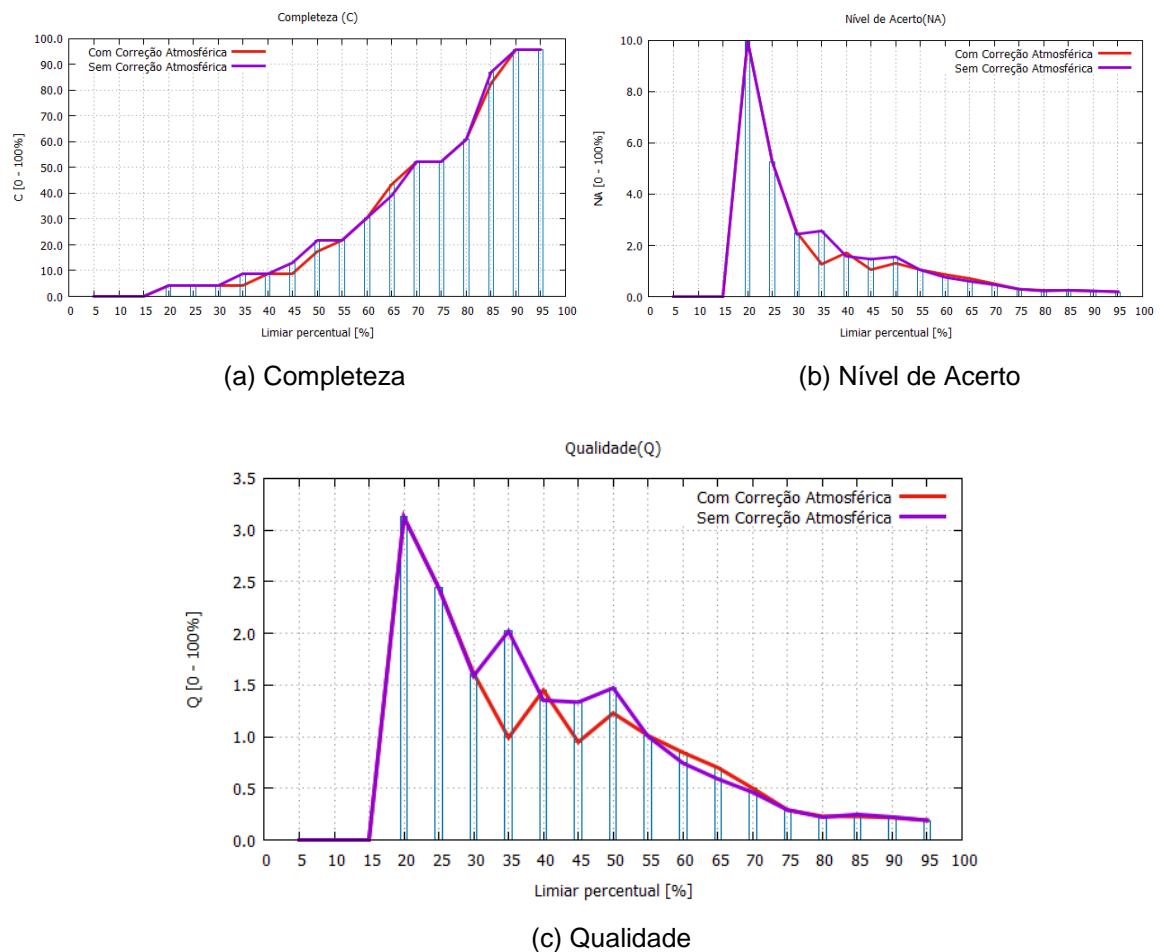
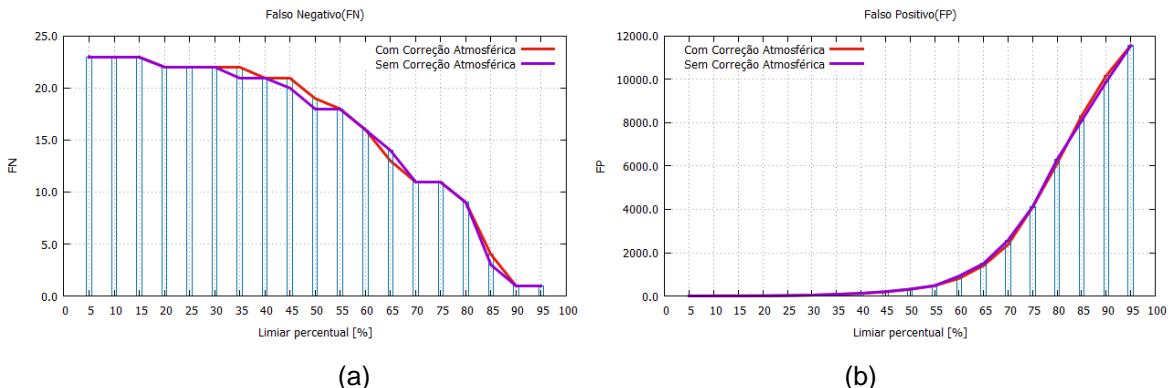


Figura 33. Comparação dos valores de (a) Falso Positivo e (b) Falso Negativo para imagens com e sem correção atmosférica.



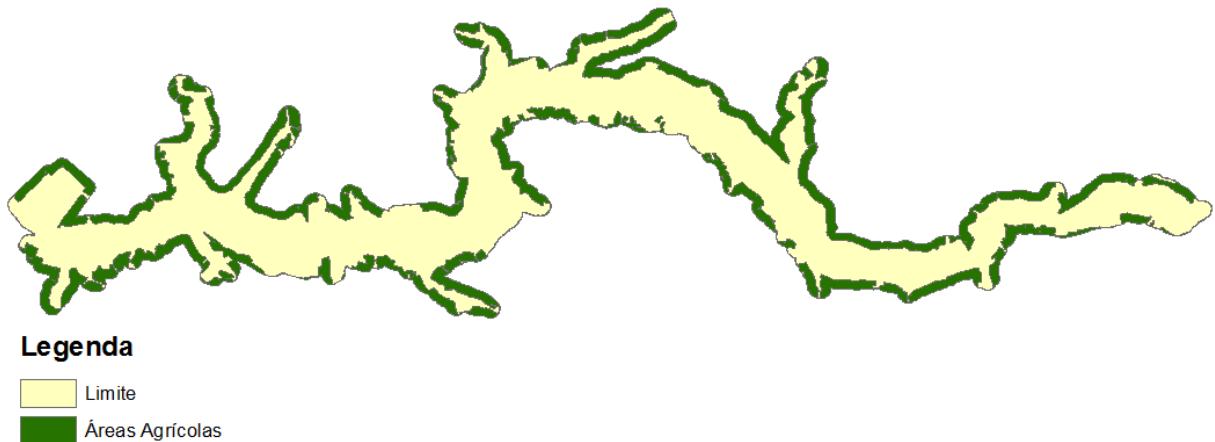
Ao analisar os resultados gerados pelos gráficos nas Figuras 32 e 33, verifica-se que a correção atmosférica, embora visualmente apresente uma grande diferença, não interferiu de modo significativo no resultado da detecção de mudanças, tornando a aplicação da correção atmosférica dispensável para os propósitos do projeto. No gráfico da Figura 32.a, por exemplo, a maior diferença foi da ordem de 4%, o que indica que o efeito da correção não é significativo. Deve-se notar também que em alguns casos a completeza é reduzida, sendo relevante lembrar que a correção atmosférica aplicada foi não rigorosa. No caso da correção rigorosa seria necessário utilizar, além dos metadados das imagens, observações de campo, não disponíveis no presente caso.

4.5 Inserção de máscaras para minimização de falsos positivos

Ao analisar os resultados gerados pela técnica RCEN modificada, verificou-se que houve uma grande detecção de modificações nas áreas agrícolas ao redor dos reservatórios, devido ao processo de cultivo. Embora estas diferenças sejam bem perceptíveis visualmente, para fins de resultados do projeto de P&D em parceria com a empresa Duke Energy estas áreas são irrelevantes para a detecção de mudanças, pois são áreas controladas e onde não há presença de intervenções irregulares. Sendo assim, para a minimização da quantidade de detecções e melhora nos resultados da validação do algoritmo, aplicou-se uma máscara nas imagens, excluindo estas áreas agrícolas da análise. As informações que permitem

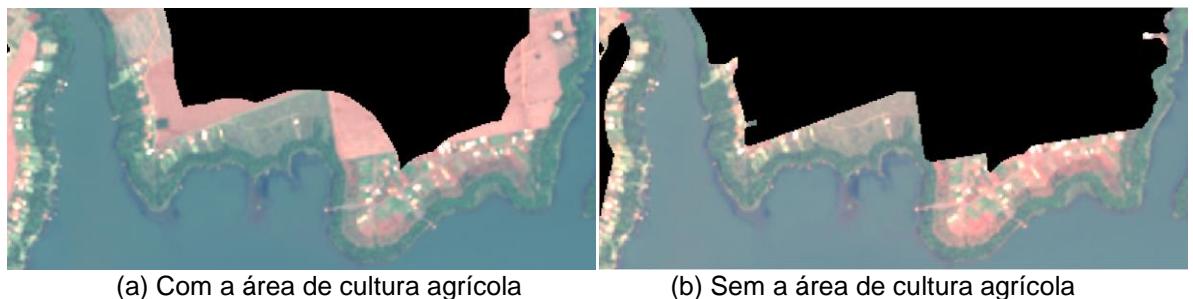
definir esta máscara provêm do Mapa do Uso do Solo, no formato *shapefile*. Deste modo, além da análise ocorrer dentro da região de interesse (*buffer original*), as áreas agrícolas são excluídas da análise. A Figura 34 mostra a área de trabalho (limite), excluídas as áreas de uso agrícola.

Figura 34. Figura representativa da intersecção da área de interesse e da área agrícola.



Após restringir a área de interesse a partir da aplicação da máscara mencionada, executou-se novamente o algoritmo e comparou-se os resultados. Para este teste utilizou-se de uma pequena área para facilitar a visualização dos resultados, Figura 35.

Figura 35. Recorte da imagem do sensor SPOT-6, do reservatório de Canoas I, na data de 05/11/2012.



Os resultados do algoritmo, sem e com a inclusão das áreas agrícolas podem ser vistos nos gráficos das Figura 36 e 37.

Figura 36. Comparação entre as áreas com cultura e sem cultura para os parâmetros de qualidade, (a) Completeza; (b) Nível de Acerto e (c) Qualidade.

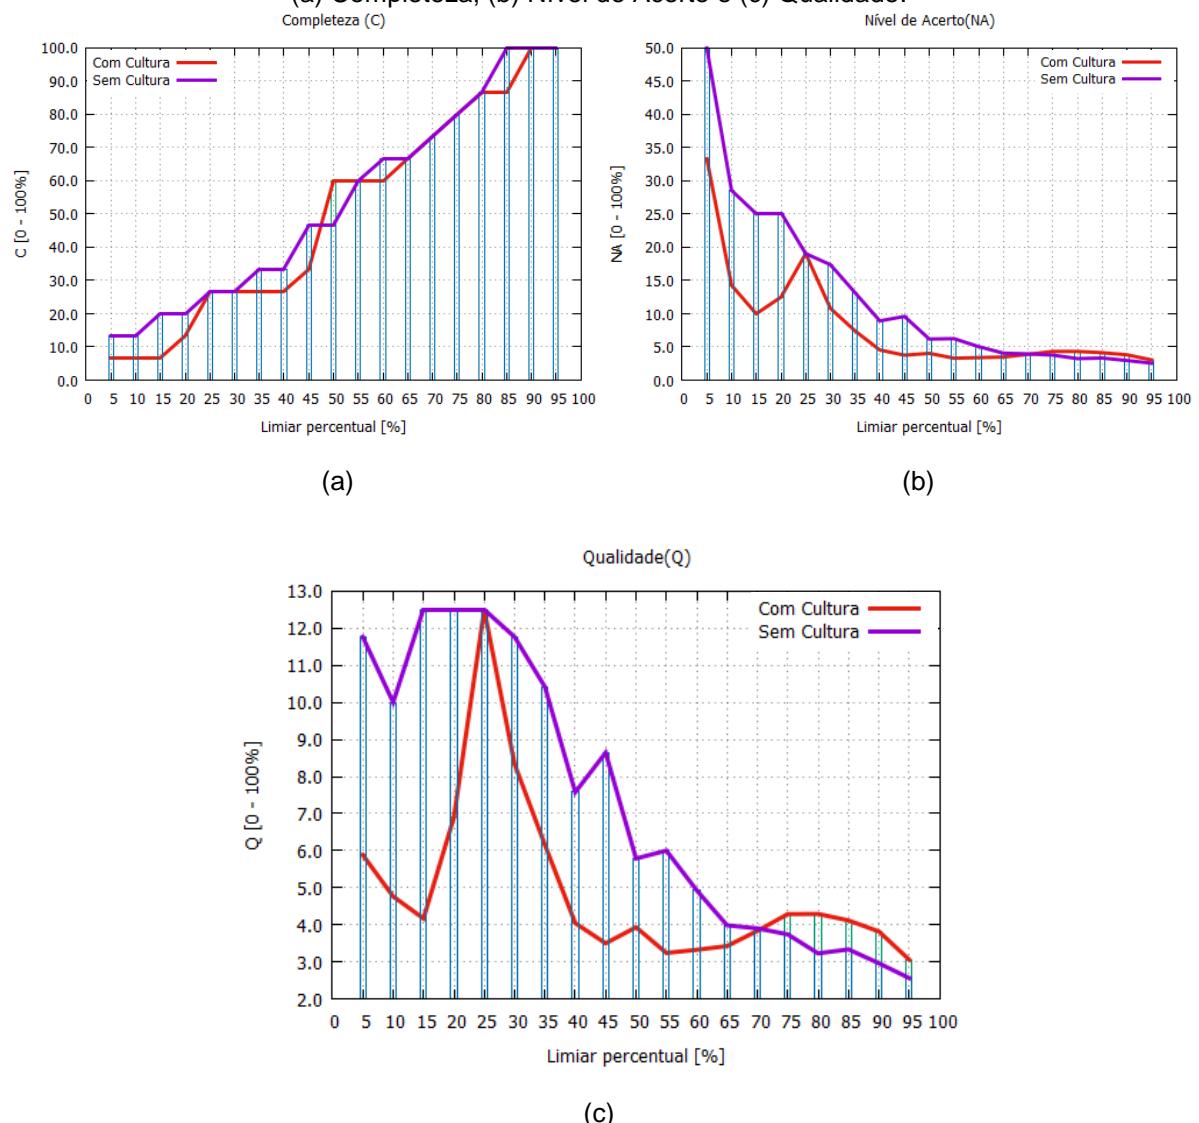
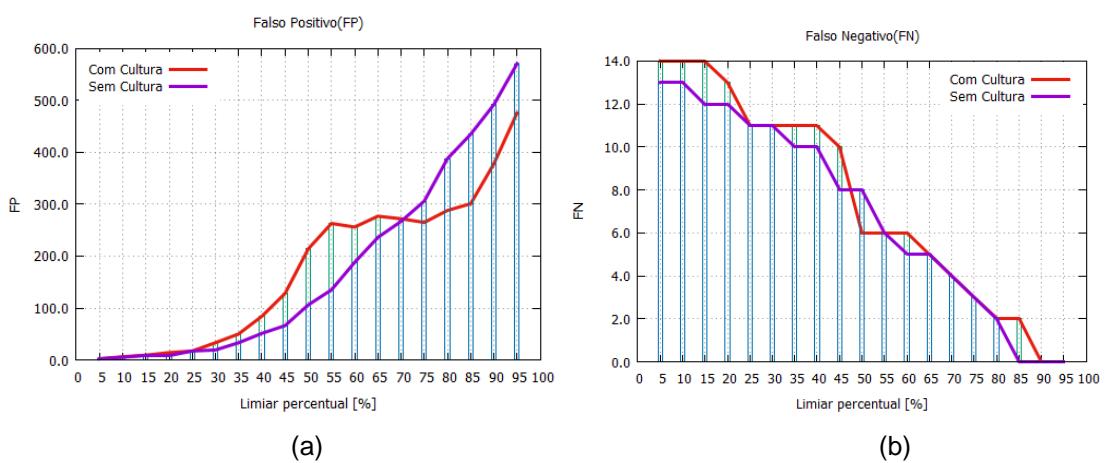


Figura 37. Comparação entre os valores de Falso Positivo (a) e Falso Negativo (b) para as áreas com e sem cultura.



Pode-se perceber nos gráficos das Figuras 36 e 37, que houve, em geral, uma melhora nos parâmetros de qualidade ao excluir as áreas de cultura. Menciona-se em geral, pois este comportamento não foi igual para todos os limiares. Nota-se claramente que a completeza e o nível de acerto aumentaram para a maior parte dos limiares, percebendo-se um aumento significativo do nível de acerto para alguns limiares. Isto ocorre pelo fato de que ao aumentar a porcentagem, aumenta-se o limiar de aceitação para as detecções. Assim, uma área agrícola que com limiar 25% é detectada em vários fragmentos, ao aplicar um limiar de 80% ela será detectada como um todo, ou seja, menos fragmentada.

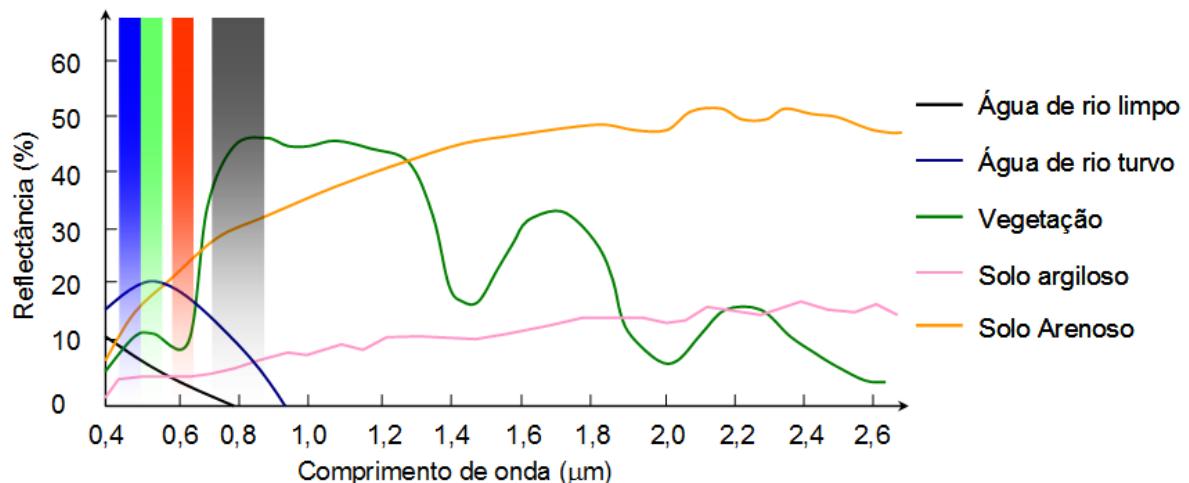
4.6 Influência das bandas multiespectrais na detecção de mudanças

Para tentar minimizar a quantidade de falsos positivos, decidiu-se analisar o comportamento de cada banda multiespectral do sensor SPOT-6 do reservatório de Canoas I separadamente. Estas bandas foram analisadas individualmente, bem como de modo combinado, com diferentes ponderações, visando verificar combinações e pesos que resultam numa maior redução de falsos positivos.

Como cada alvo sobre a superfície terrestre tem uma resposta diferente em cada banda multiespectral, como pode-se ver pela Figura 38, decidiu-se separar os experimentos em cinco áreas testes, sendo que cada área abrangeu as classes abaixo:

- I. Área teste 1 – Construção;
- II. Área teste 2 – Corpo D'Água;
- III. Área teste 3 – Sombra;
- IV. Área teste 4 – Solo exposto; e
- V. Área teste 5 – Vegetação.

Figura 38. Comportamento espectral de alguns alvos na superfície terrestre.



Fonte: Adaptado de Sausen (2010).

Estas cinco áreas testes serão apresentadas e os resultados discutidos na sequência. Para a análise dos resultados foram considerados os parâmetros de qualidade citados no item 2.6. Após os diversos processamentos e análises dos dados, os parâmetros de qualidade foram estimados considerando percentuais de 5% a 95%, em intervalos de 5 em 5%, totalizando 19 percentuais, podendo-se verificar quais as melhores bandas para determinadas classes.

Para a análise do efeito resultante da combinação das diferentes bandas multiespectrais, utilizou-se um procedimento para a ponderação, ou verificação da influência de cada banda na detecção das mudanças de interesse. Primeiramente distribuem-se as bandas em um intervalo de [1; 4], pois trata-se de imagens do sensor SPOT-6 com quatro bandas multiespectral, seguida da verificação das contribuições para os diferentes limiares. Assim, as contribuições são ordenadas de forma decrescente para cada limiar, sendo que a maior delas (1º lugar – a mais influente) recebe o peso 1; a 2ª o peso 1/2; a 3ª o peso 1/3; e a 4ª o peso 1/4; ou seja, calcula-se a contribuição de cada banda por meio da Equação 15. Analisou-se cada banda separadamente, classificando-a em uma determinada posição para cada limiar j , ou seja:

$$Peso_{Bi,i} = \sum Posição_j * \frac{1}{Posição_i} \quad (15)$$

sendo: Bi = banda utilizada; i o ID da bandas utilizadas e $j \in \{1, 2, \dots, 19\}$.

O valor final da contribuição para cada banda será calculado pelo

somatório dos pesos. Como são considerados 19 limiares, o valor máximo da ocorrência de uma dada banda será de 19, para uma determinada posição (1^a, 2^a, 3^a ou 4^a). Ao final estes valores serão normalizados em uma escala de [0; 1], onde a melhor banda irá obter o peso 1 e as outras bandas serão normalizadas em relação a esta banda.

Como um exemplo numérico que ilustra este procedimento, suponha que para uma determinada área as bandas foram distribuídas conforme o Quadro 5, para o índice de completeza.

Quadro 5. Resultados dos índices de completeza para uma determinada área, considerando os limiares de 5% a 95%.

Limiares (%)	R	G	B	NIR
5	0,2000	0,1333	0,1333	0,0000
10	0,2000	0,1333	0,1333	0,0000
15	0,2000	0,1333	0,1333	0,0000
20	0,2000	0,1333	0,1333	0,0000
25	0,2000	0,1333	0,1333	0,0000
30	0,2666	0,1333	0,2000	0,0000
35	0,2666	0,2000	0,2000	0,0000
40	0,5333	0,2666	0,2000	0,0666
45	0,6666	0,3333	0,2666	0,2000
50	0,7333	0,4666	0,2666	0,2000
55	0,8000	0,5333	0,4000	0,2000
60	0,9333	0,6000	0,5333	0,4000
65	0,9333	0,6000	0,6000	0,4666
70	0,9333	0,6666	0,6666	0,5333
75	0,9333	0,8000	0,8000	0,6000
80	1	0,8000	0,8000	0,8000
85	1	0,8666	0,8666	0,8666
90	1	1	0,8666	0,8666
95	1	1	0,9333	0,9333

Ao gerar os valores de completeza para todas as bandas multiespectrais separadamente, para uma determinada área, a banda do Vermelho ficou 19 vezes em primeiro lugar, e nenhuma vez nas outras posições, dentre as quatro bandas multiespectrais, totalizando assim 19 posições. A banda do Verde ficou 2 vezes em primeiro lugar, 16 vezes em segundo lugar, 1 vez em terceiro lugar e nenhuma vez em último lugar, totalizando assim um valor de 10,33, e assim por diante para as demais bandas. Após estas operações normalizam-se os valores finais em uma

escala [0;1], visando ter uma escala de contribuição de cada uma das bandas. Logo, os resultados baseados nestes dados hipotéticos podem ser conferidos no Quadro 6.

Quadro 6. Cálculo dos pesos.

Posição Bandas \	1º	2º	3º	4º	Fórmula	Total	[0; 1]
R	$19 * 1/1$	$0 * 1/2$	$0 * 1/3$	$0 * 1/4$	$\sum \text{Pesos}$	19,00	1
G	$2 * 1/1$	$16 * 1/2$	$1 * 1/3$	$0 * 1/4$		10,33	0,54
B	$0 * 1/1$	$14 * 1/2$	$5 * 1/3$	$0 * 1/4$		08,66	0,46
NIR	$0 * 1/1$	$4 * 1/2$	$9 * 1/3$	$6 * 1/4$		06,50	0,34

Para o caso da combinação de bandas o mesmo procedimento poderá ser adotado, com os pesos finais calculados da mesma forma. Após calcular os valores para cada parâmetro, verifica-se quais são as bandas mais influentes, para os diferentes parâmetros de qualidade.

O uso desta medida de influência é relativa, sendo justificada pela ausência ou pequena influência de *outliers*, fator este que afeta outros métodos mais comuns de análise, como média e desvio-padrão.

I. Área teste 1

A área teste I está relacionada com a classe construção, onde tem-se a presença de casas, barracões e quiosques, como mostrado na Figura 39.

Figura 39. Área teste 1, combinação colorida (RGB), do sensor SPOT-6.



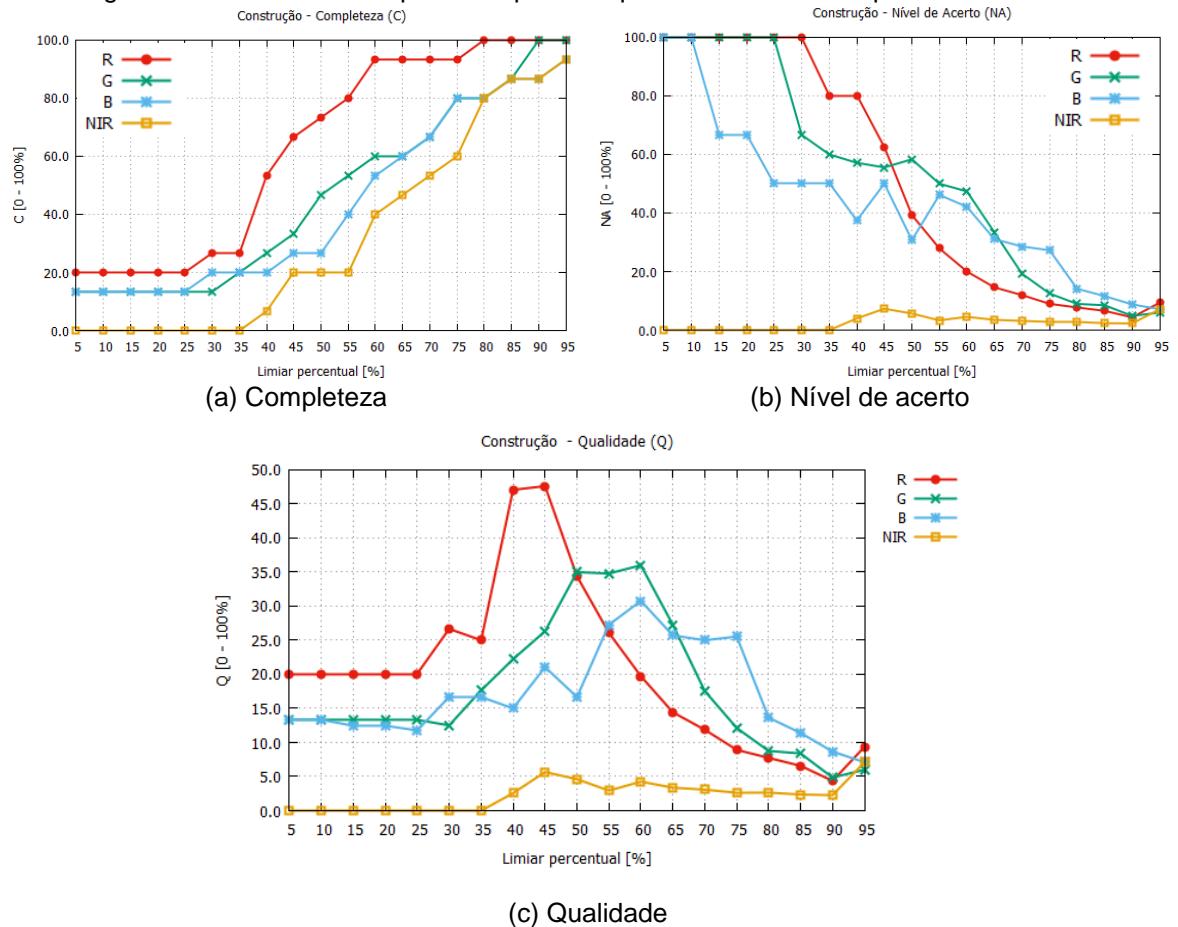
a) 05/11/2012

b) 29/04/2013

Estas construções tratam de modificações que podem causar um maior impacto sobre a borda de um reservatório, caso a mesma esteja ilegal, além de

serem intervenções bem frequentes. A preocupação na detecção deste tipo de objeto é grande, pois no caso de ocorrência de um evento como rompimento da barragem, estas edificações serão afetadas e vidas podem ser perdidas. Sendo assim, resolveu-se analisar, como estas construções se comportam em cada banda multiespectral, para assim poder tomar decisões sobre quais bandas são passíveis de serem utilizadas para realizar tais detecções. Os resultados encontram-se nas Figuras 40, 41 e 42.

Figura 40. Parâmetros de qualidade para as quatro bandas multiespectrais da área 1.



normalmente estão presentes em uma construção, como telhas de barro, zinco, concreto ou amianto, têm respostas espectrais mais sensíveis nas bandas do visível, especificamente entre os comprimentos de ondas de 0,52 a 0,69 µm, representando então o intervalo das bandas multiespectrais G e R, respectivamente, o que justifica este comportamento.

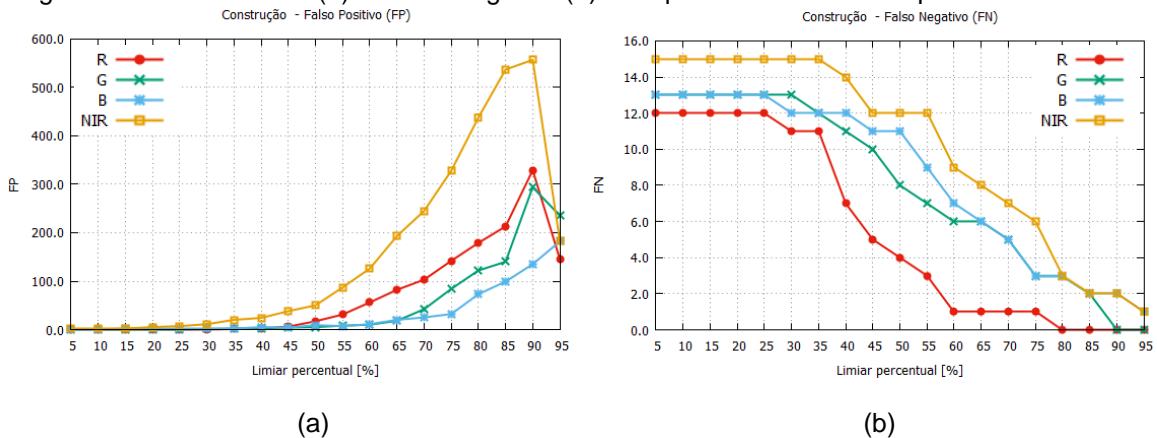
Fazendo uma análise quantitativa das quatro bandas multiespectrais para o parâmetro de completeza, percebeu-se que os pesos, no intervalo [0;1], para as bandas R, G, B e NIR, resultaram respectivamente nos valores 1; 0,54; 0,46 e 0,34. Pode-se constatar por estes valores que a banda R corresponde ao melhor resultado para a completeza.

O nível de acerto é um parâmetro que depende da quantidade total de detecções, logo, enquanto este número estiver alto, o nível de acerto continuará baixo. Ao analisar as bandas multiespectrais do sensor SPOT-6 para a classe de construção, no gráfico da Figura 40.b, percebe-se que as bandas R e G voltaram a se destacar. Porém, ao contrário da completeza, o nível de acerto para a banda NIR resultou em baixos valores, tornando a banda não recomendada para a detecção de construções.

Entretanto, considerando as duas melhores bandas para este parâmetro (bandas G e R), conclui-se que a banda G resultou nos maiores valores de nível de acerto. Em uma escala de [0;1] as bandas G, R, B e NIR contribuem com os valores de 1; 0,95; 0,88 e 0,41, respectivamente.

A qualidade é um parâmetro decisivo na escolha do limiar, uma vez que é o mesmo que transmite o quanto o algoritmo está preciso em suas detecções, pois é um parâmetro que contempla tanto a completeza quanto o nível de acerto. No entanto, como mencionado na Seção 4, a quantidade de falsos positivos ainda afeta os valores deste parâmetro, como percebe-se no gráfico da Figura 40.c. Deste modo, analisando as bandas separadamente, para o parâmetro de qualidade, a banda R resultou em um maior destaque, sendo que em uma escala de [0; 1] as bandas R, G, B e NIR, resultam nos pesos de 1; 0,85; 0,82 e 0,39, respectivamente.

Figura 41. Falso Positivo (a) e Falso Negativo (b) das quatro bandas multiespectrais da área 1.



(a)

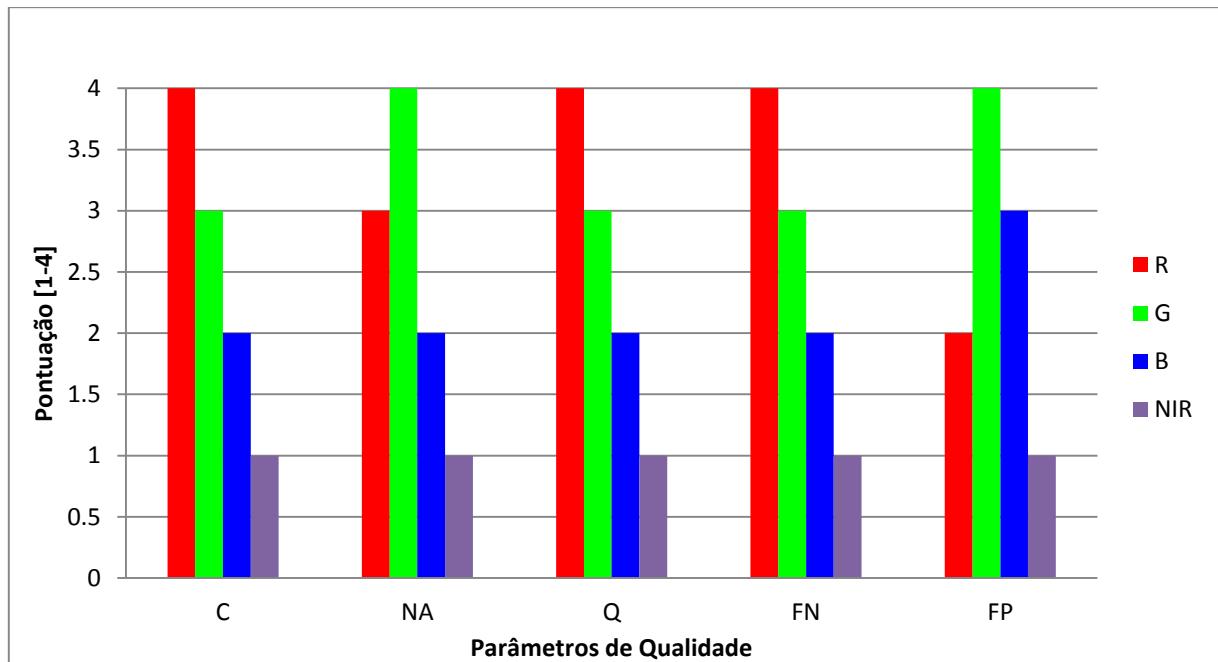
(b)

Como já mencionado, a quantidade de falsos positivos é um parâmetro importante, sendo essencial adotar estratégias que resultem na sua redução. Observando e analisando os dados contidos no gráfico da Figura 41.a, percebe-se que a banda do NIR teve uma alta sensibilidade nas detecções em geral, porém pouca sensibilidade para construções. Comparando-a com os demais parâmetros descritos anteriormente, nota-se que esta banda poderá interferir negativamente na detecção automática de mudanças, para a classe de construção. Porém, analisando as três bandas do visível, pode-se notar que a banda B obteve uma melhora nos resultados em relação aos outros parâmetros. Em uma escala de [0; 1] as bandas G, B, R e NIR, resultaram nos valores de 1; 0,97; 0,90 e 0,42, respectivamente, para este parâmetro. Por este resultado nota-se que a banda G foi a que propiciou um melhor resultado. Nota-se, neste caso em específico, que a resposta da banda B é bem próxima, indicando que tem-se uma certa ambiguidade.

O número de falsos negativos é um parâmetro preocupante, caso sejam presentes em grande quantidade, pois são os mesmos que indicam o que o algoritmo não conseguiu detectar. Observando o gráfico da Figura 41.b, para a classe construção, percebe-se que com um limiar de 80%, chega-se a zero falsos negativo utilizando a banda R. Para este parâmetro as bandas R e G resultaram nos melhores resultados, sendo que as bandas B e do NIR não chegaram a ter valores iguais a 0. Realizou-se uma análise quantitativa dos resultados, a fim de obter as bandas mais influentes, sendo que, em uma escala de [0; 1] as bandas R, G, B e NIR resultaram nos valores de pesos correspondentes a 1; 0,54; 0,46 e 0,34, respectivamente.

A partir dos valores de influência de cada banda foi gerado o gráfico da Figura 42, contabilizando para os diferentes parâmetros de qualidade os resultados das diferentes bandas. Neste gráfico a banda que resultou no melhor resultado obteve uma pontuação 4, a segunda melhor com pontuação 3, a terceira melhor com pontuação 2 e a pior dentre as quatro bandas com pontuação 1. Analisando o gráfico da Figura 42, pode-se notar que as bandas que resultaram nos melhores resultados, de um modo geral, foram às bandas R, G, B e NIR, sendo que em uma escala de [0; 1] as bandas R, G, B e NIR resultaram nos valores de 1; 0,91; 0,48 e 0,33, respectivamente.

Figura 42. Análise das quatro bandas multiespectrais da área 1, para os cinco parâmetros de qualidade.



Este tipo de análise é importante para a escolha da combinação de bandas, a fim de verificar qual banda delas resultam em melhores resultados para a detecção de alterações de forma automática para a classe construção. Eles indicam que a combinação entre as bandas R e G, surgirá efeitos positivos nos resultados, em relação às demais combinações. Como os resultados em termos de contribuição de cada banda foram analisados em uma escala entre [0;1], pode-se dizer que ao analisar os dados verificou-se que as bandas abaixo de 0,5 nesta escala interferiam negativamente nos resultados, aumentando assim os ruídos e prejudicando na

detecção. Para a classe construção as bandas B e NIR ficaram abaixo de 0,5. Entretanto a banda B resultou em um valor muito próximo a 0,5, fazendo com que seja possível utilizá-la para uma possível combinação.

Uma vez escolhidas as melhores bandas pode-se realizar a combinação entre as mesmas. Para a classe construção obteve-se as seguintes combinações: Vermelho (R) e Verde (G) – RG; Vermelho (R) e Azul(B) – RB; Vermelho (R), Verde (G) e Azul (B) – RGB.

II. Área teste 2

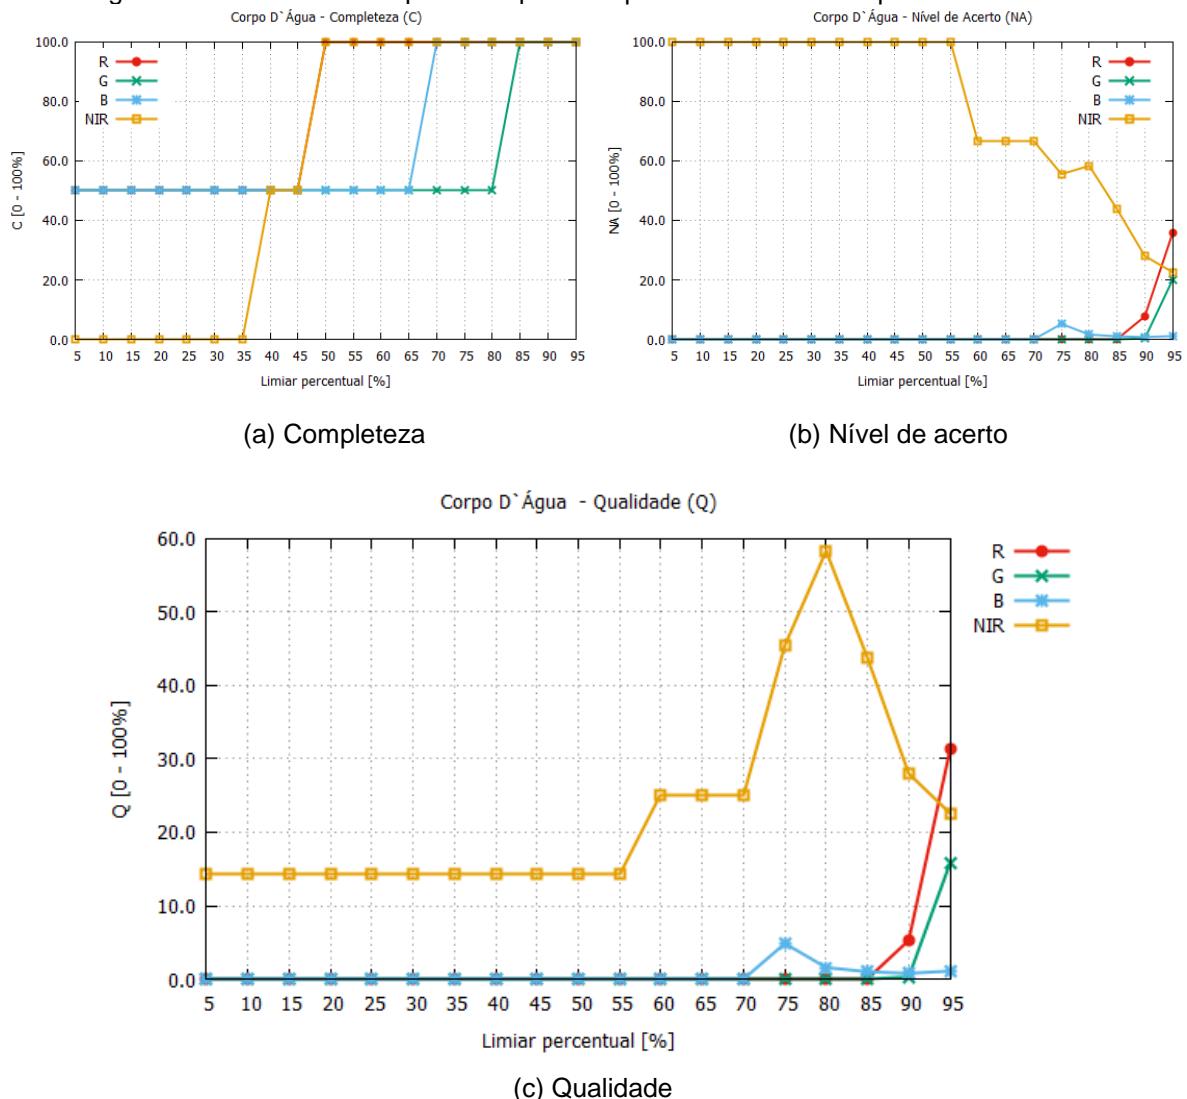
Esta área foi escolhida por conter algumas modificações dentro do corpo d'água, como pode-se verificar na Figura 43.

Figura 43. Área teste 2, combinação colorida (RGB), do sensor SPOT-6, do reservatório de Canoas_1.



Estas modificações, destacadas na Figura 43, são importantes, uma vez que podem estar associadas ao cultivo de peixes por meio de tanques redes ilegais, que podem estar prejudicando o ciclo natural da biodiversidade, por exemplo. Processamentos similares realizados na área 1, também foram realizados nesta área, sendo obtidos os resultados mostrados nas Figuras 44, 45 e 46.

Figura 44. Parâmetros de qualidade para as quatro bandas multiespectrais da área 2.



Os corpos d'água absorvem muita energia na banda do Infravermelho Próximo e ficam escuros nas imagens desta banda, permitindo o mapeamento da rede de drenagem e delineamento de corpos d'água, ou seja, são bem sensíveis na detecção sob os corpos d'água, permitindo a visualização de áreas ocupadas com macrófitas aquáticas (ex: aguapé). Como esta banda não permite uma grande penetração nos corpos d'água, isto faz com que o aparecimento de intervenções sob o corpo d'água, como tanques redes, por exemplo, sejam detectadas de forma mais precisa nesta banda.

Sendo assim, analisando o gráfico da Figura 44.a, percebe-se que para o parâmetro completeza, a banda do NIR do sensor SPOT-6 resultou em um melhor comportamento para esta classe, seguido então das bandas B, R e G. Em função da

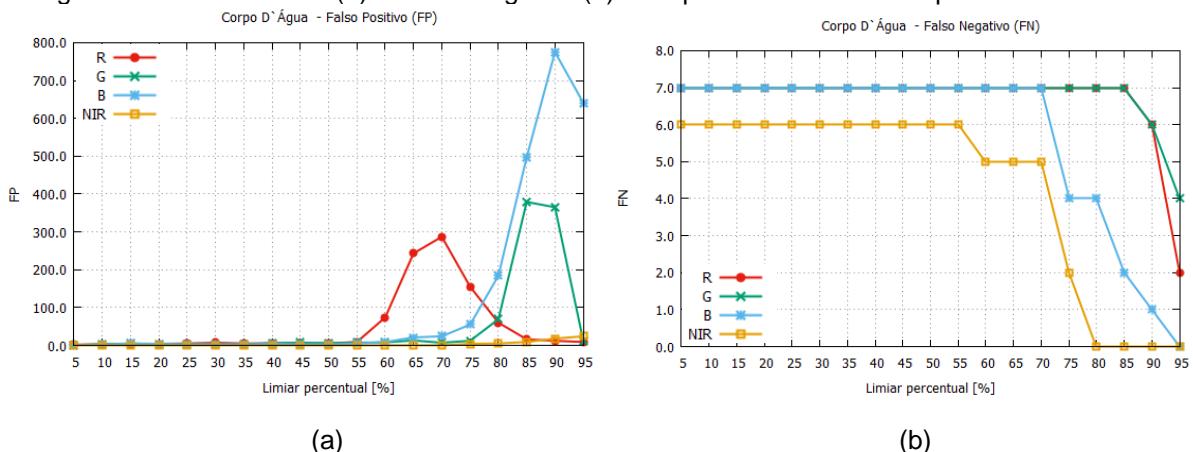
análise feita no parágrafo anterior, o resultado obtido foi esperado, uma vez que a banda G apresenta grande sensibilidade à presença de sedimentos em suspensão e boa penetração em corpos d'água, fazendo com que haja muitas detecções. Fazendo uma análise quantitativa das quatro bandas multiespectrais, para o parâmetro de completeza, e admitindo que a banda NIR foi a que gerou o melhor resultado, em uma escala de [0; 1], as bandas NIR, B, R e G, contribuem com os valores 1; 0,53; 0,47 e 0,46, respectivamente.

No que concerne a Figura 44.b, percebe-se claramente a disparidade da banda NIR em relação às demais bandas, onde os comportamentos foram parecidos. Deste modo, conclui-se que em termos de nível de acerto e em uma escala de [0;1] as bandas NIR, R, B e G, resultam nos valores 1; 0,51; 0,49 e 0,46, respectivamente.

Analizando a qualidade, Figura 44.c, pode-se confirmar a superioridade da banda NIR em relação às demais. De modo similar aos demais indicadores as contribuições das bandas NIR, R, B e G, correspondem aos valores 1; 0,51; 0,49 e 0,46, respectivamente.

Os gráficos da Figura 45 mostram os falsos positivos e falsos negativos. Observando os dados contidos no gráfico da Figura 45.a, percebe-se que a banda B teve uma alta sensibilidade nas detecções em geral, pelo fato de, assim como a banda G, possuir uma grande penetração em corpos d'água. Via de regra, os falsos positivos, assim como os falsos negativos, são analisados de forma contrária aos demais, uma vez que quanto menor for o seu valor, melhor será o resultado. Então analisando quantitativamente os dados em uma escala de [0; 1] as bandas NIR, B, R e G, resultam nos valores 1; 0,43; 0,43 e 0,41, respectivamente, para este parâmetro. Observou-se que a banda B apresentou altos valores apenas após o limiar de 80%.

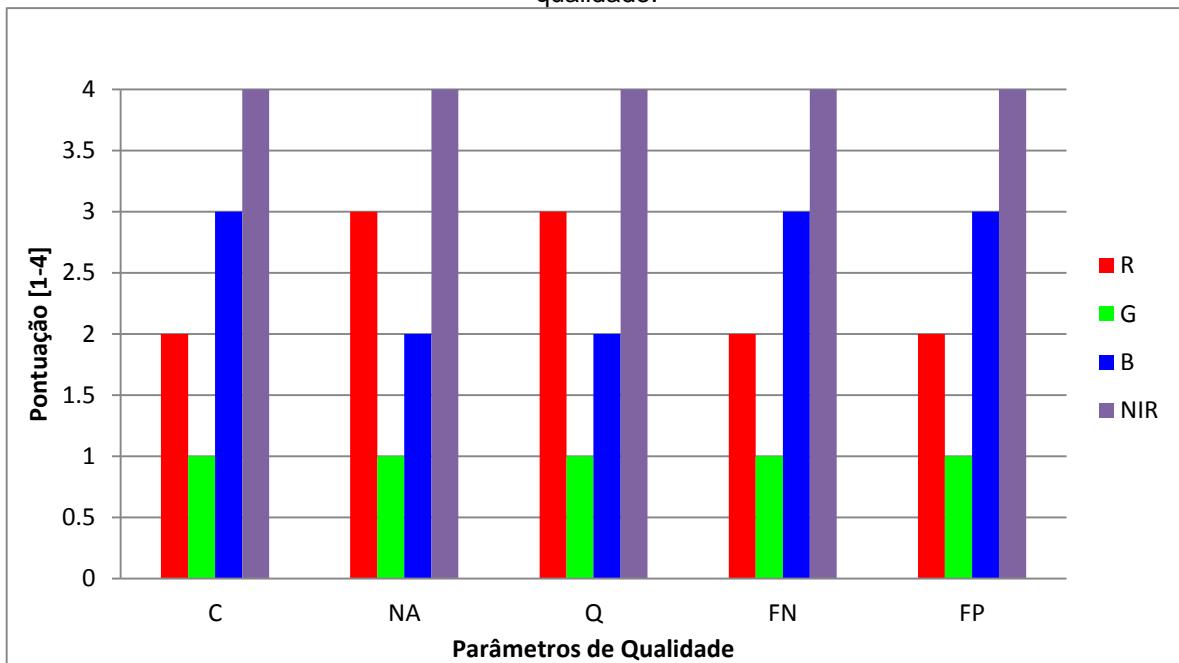
Figura 45. Falso Positivo (a) e Falso Negativo (b) das quatro bandas multiespectrais da área 2.



Em relação aos falsos negativos, Figura 45.b, somente as bandas NIR e a banda B apresentaram valores nulos. No entanto, a banda NIR se destacou em relação as demais bandas, uma vez que as bandas NIR, B, R e G, resultaram nos valores de 1; 0,52; 0,46 e 0,45, respectivamente.

Analizando o gráfico da Figura 46, pode-se notar que as bandas que resultaram nos melhores resultados, de um modo geral, foram as bandas NIR, B, R e G, sendo que em uma escala de [0; 1] as contribuições correspondem aos valores 1; 0,43; 0,40 e 0,25, respectivamente. Pode-se notar que a maior contribuição é da banda NIR, seguido das bandas B e R, com contribuições similares.

Figura 46. Análise das quatro bandas multiespectrais da área 2, para os cinco parâmetros de qualidade.



Como nenhuma das bandas do visível resultaram em valores acima de 0,5 ou próximos a ele, conclui-se que para a análise de detecção de mudanças sob o corpo d'água, a banda NIR é a mais recomendada. Porém, para fins de comparação com uma combinação de bandas, para a classe corpo d'água, as seguintes combinações serão analisadas: Azul (B) e Infravermelho Próximo (NIR) – BNIR; Vermelho (R) e Infravermelho Próximo (NIR) – RNIR; Azul (B), Vermelho (R) e Infravermelho Próximo (NIR) – RBNIR.

III. Área teste 3

Esta área teste é composta por segmento de imagem no qual predomina a presença de mata, reflorestamento, e vegetação. No caso de regiões com vegetação mais densa, quando a luz solar atinge as copas das árvores pode-se perceber que as árvores mais altas vão projetar suas sombras nas copas das árvores mais baixas. Na Figura 47 tem-se a imagem de uma mata natural onde percebe-se a presença de sombras associadas a uma cor mais escura, uma vez que nos locais onde há sombra, a incidência de luz é mais baixa, consequentemente, pouca energia chegará aos sensores dos satélites. Apesar das sombras serem úteis

na identificação de determinados alvos, como prédios ou certos tipo de árvores, quando realiza-se uma interpretação visual ou um processamento de imagens de satélite, como no caso de detecção de mudanças, elas podem ser prejudiciais, aumentando muito as detecções que são irrelevantes, contribuindo para o aumento dos falsos positivos.

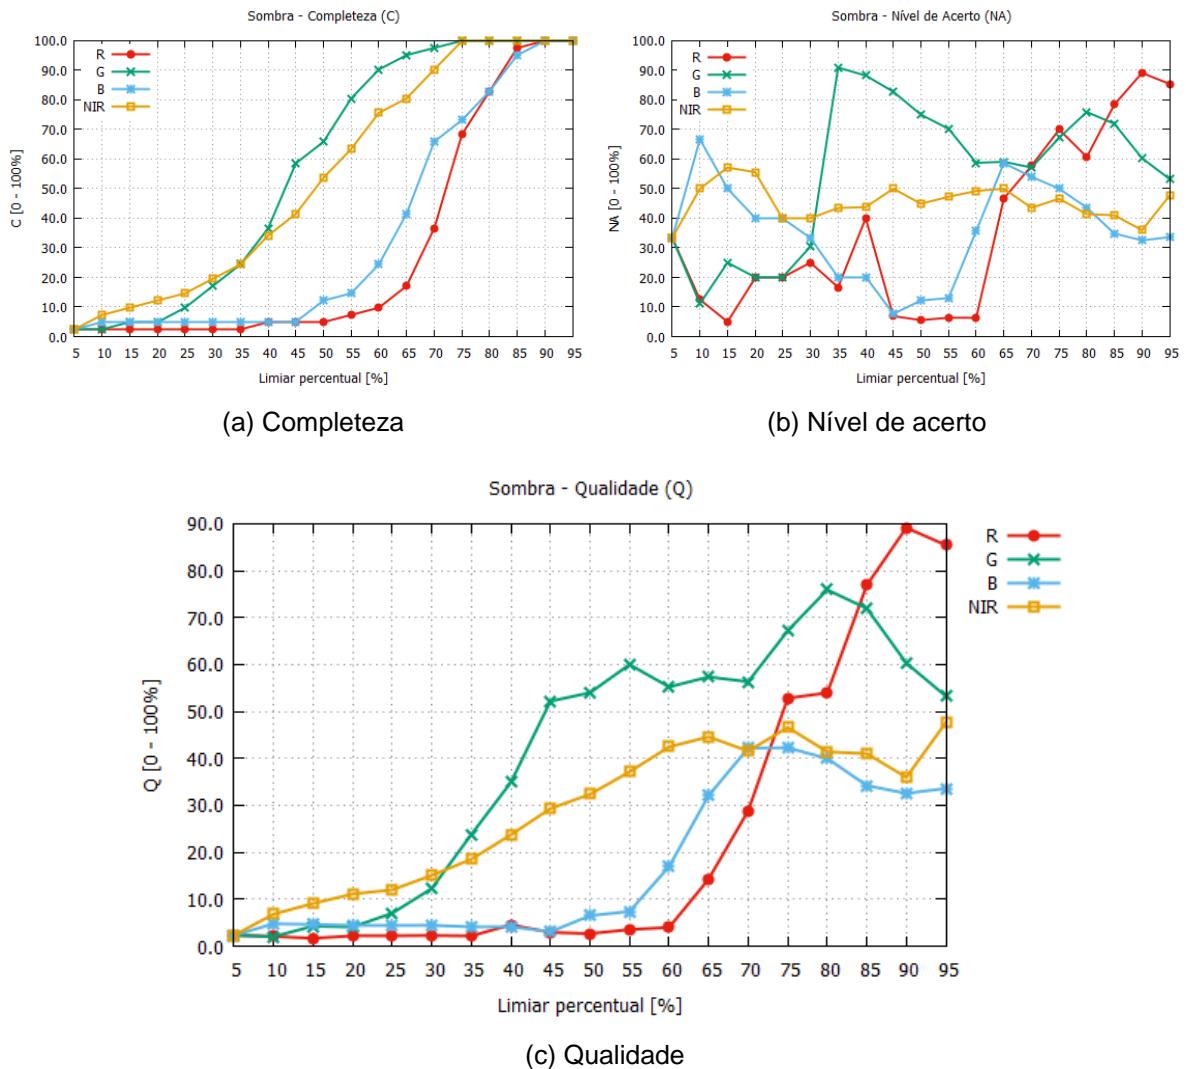
Escolheu-se a área teste 3 justamente por esta razão. Ela corresponde a uma área de reflorestamento onde fica notável a presença das sombras nas árvores, como visto na Figura 47.

Figura 47. Área teste 3, combinação colorida (RGB), do sensor SPOT-6, para o reservatório de Canoas I.



A maioria dos falsos positivos encontrados nos testes trata-se da presença de sombras, principalmente em vegetação, e como a área de interesse se localiza no em torno de reservatórios, a grande quantidade de vegetação e consequentemente de sombras é inevitável. Portanto, o estudo da influência de cada banda na detecção de mudanças, visando minimizar a detecção das sombras é de suma importância para o decorrer das atividades. Os resultados encontram-se nas Figuras 48, 49 e 50.

Figura 48. Parâmetros de qualidade para as quatro bandas multiespectrais da área 3.



A análise da classe sombra será realizada de modo diferente ao das demais classes, pois pretende-se analisar qual banda será menos sensível à detecção de sombras. Analisando o gráfico da Figura 48.a, percebe-se que para o parâmetro completeza, a banda NIR do sensor SPOT-6, bem com a banda G teve um melhor comportamento para a classe de sombras, seguido então das bandas do B e R. Este efeito é esperado uma vez que regiões afetadas por sombras possuem um comportamento espectral próximo ao representado por corpos d'água, como visto no estudo da área 2. Entretanto, como realizou-se a análise de forma que pretende-se ter uma baixa detecção de sombras, a pior banda do resultado torna-se a melhor para o propósito. Fazendo uma análise quantitativa das quatro bandas multiespectrais para o parâmetro de completeza, e admitindo que a banda R obteve

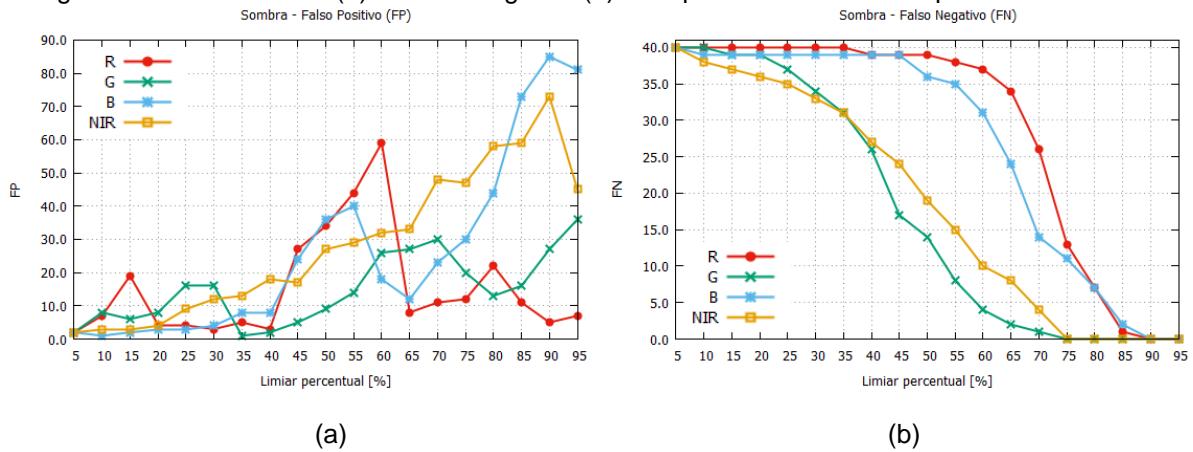
um melhor resultado, em uma escala de [0; 1], as bandas R, B, G e NIR possuem as contribuições 1; 0,70; 0,49 e 0,47, respectivamente. Pode-se notar que as bandas G e NIR apresentam neste caso valores próximos, indicando grande ambiguidade.

Em relação a Figura 48.b, percebe-se que o nível de acerto foi maior para a banda G, sendo que a banda R resultou em maiores valores somente após o limiar de 65%. Entretanto, comparando e analisando quantitativamente as bandas para este parâmetro, conclui-se que as bandas R, B, NIR e G, contribuem, respectivamente, nas seguintes proporções: 1; 0,79; 0,68 e 0,57.

No que se refere ao indicador qualidade, Figura 48.c, pode-se confirmar a superioridade das bandas do Vermelho e Azul em relação as demais, uma vez que as bandas R, B, Infravermelho NIR e G, contribuíram respectivamente nas seguintes proporções: 1; 0,77; 0,44 e 0,40.

Na Figura 49 são mostrados os números de falsos positivos e falsos negativos, para esta área.

Figura 49. Falso Positivo (a) e Falso Negativo (b) das quatro bandas multiespectrais da área 3.



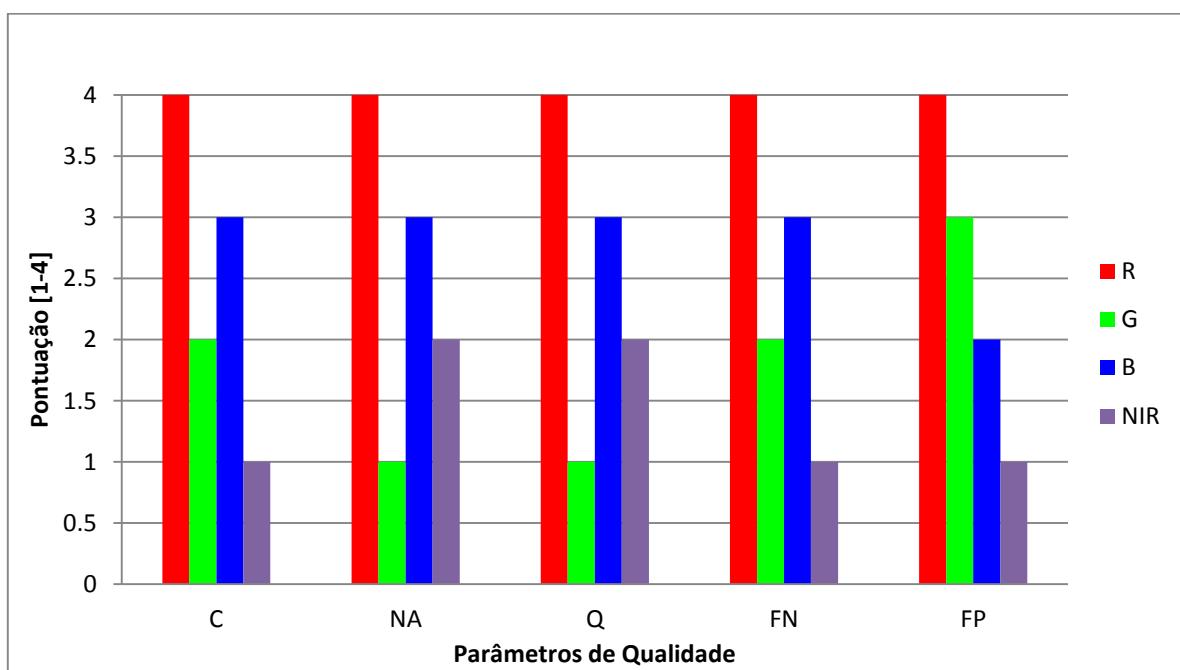
Neste caso, deve-se destacar que o que interessa é obter um número menor de falsos positivos e também falsos negativos. Desta forma, observando e analisando os dados contidos no gráfico da Figura 49.a, percebe-se que a banda G, que resultou em altos valores para os outros parâmetros de qualidade até o momento, obteve um baixo valor de falsos positivos, concluindo que esta banda detecta poucas alterações na vegetação e é sensível na detecção de sombras. Então, analisando quantitativamente os dados em uma escala de [0; 1] as bandas R, G, B e NIR, resultam nos seguintes valores de contribuição: 1; 0,95; 0,87 e 0,62,

respectivamente, para este parâmetro. Observou-se que a banda B apresentou altos valores apenas após o limiar de 65%.

Por fim, em relação aos falsos negativos percebe-se pela Figura 49.b que todas as bandas apresentaram valores nulos para um limiar de 95%. Porém, como no caso de sombras o interesse é detectar o mínimo possível, analisou-se as bandas menos sensíveis às sombras, ou seja, aquelas que apresentaram um maior número de falso negativo. Realizando-se uma análise quantitativa dos resultados de cada banda, no intervalo [0; 1] as bandas R, B, G e NIR, correspondem aos pesos 1; 0,70; 0,49 e 0,47, respectivamente.

Ao final dessas análises, pode-se concluir observando o gráfico da Figura 50, que as bandas que resultaram nos melhores resultados de um modo geral, foram as bandas R, B, G e NIR, sendo que em uma escala de [0; 1] estas bandas resultam nos valores de 1; 0,46; 0,33 e 0,15, respectivamente. Observando estas contribuições, pode-se dizer que provavelmente a combinação entre a banda R e B poderá gerar melhores resultados, mas as combinações entre as outras bandas não surgirão muitos efeitos positivos, pelo fato da diferença entre as bandas G e NIR para a banda R ser grande.

Figura 50. Análise das quatro bandas multiespectrais da área 3, para os cinco parâmetros de qualidade



Como as bandas do visível tiveram um melhor comportamento em relação a detecção de sombras, para este trabalho, conclui-se que para a análise de detecção de mudanças em relação a sombras, a banda NIR não é recomendada. Logo, para fins de comparação com uma combinação de bandas, para a classe de sombras obteve-se as seguintes combinações: Vermelho (R) e Azul (B) – RB; Vermelho (R) e Verde (G) – RG; Vermelho (R), Verde (G) e Azul (B) – RGB.

IV. Área teste 4

A detecção de solo exposto é importante pelo fato de que normalmente antes de uma construção, o proprietário limpa seu terreno, deixando assim o solo exposto. Assim, a detecção de solo exposto em uma área onde haja somente vegetação densa, pode ser um indício de desmatamento para a construção de uma casa ou barracão, ou até mesmo o aparecimento de estradas em área ilegais, podendo ser associado a uma possível atividade irregular. A área 4 foi escolhida por apresentar alvos com esta característica, ou seja, com solos expostos, como mostra a Figura 51.

Figura 51. Área teste 4, combinação colorida (RGB), do sensor SPOT-6, para o reservatório de Canoas_I.



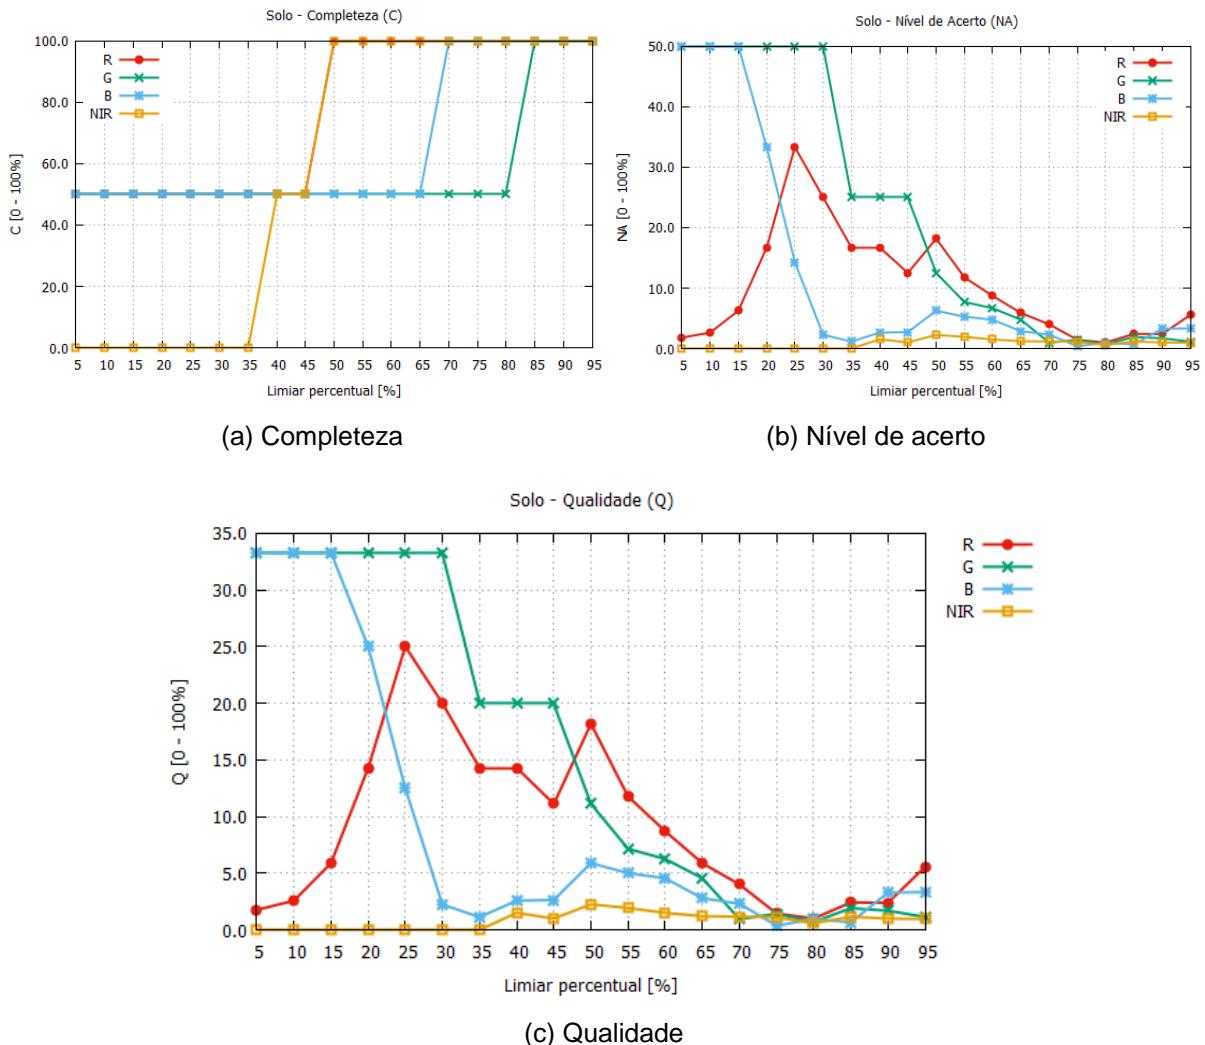
a) 05/11/2012

b) 29/04/2013

A maioria dos solos expostos, ou seja, aqueles solos que não contém nenhum tipo de vegetação ou tratamento sobre o mesmo, geralmente são solos que estão sendo preparados para cultivos. Porém, em algumas regiões estes solos aparecem como áreas a serem loteadas, isto é, áreas que possivelmente haverá algum tipo de construção sob as mesmas. Realizou-se as análises considerando os

solos que apareceram em outra época, ou seja, onde houve a remoção da vegetação. Os resultados encontram-se nas Figuras 52, 53 e 54.

Figura 52. Parâmetros de qualidade para as quatro bandas multiespectrais da área 4.



Para analisar o comportamento do algoritmo para a detecção de solo exposto, novamente observou-se o melhor comportamento, ou seja, as bandas que resultaram nos melhores resultados para os limiares de 5 a 95%. Analisando o gráfico da Figura 52.a, percebe-se que para o parâmetro completeza, todas as bandas atingiram o valor máximo, indicando que toda a referência terrestre foi detectada pelo algoritmo para esta classe, após determinado limiar. Entretanto, realizando-se uma análise quantitativa das quatro bandas multiespectrais para o parâmetro de completeza, conclui-se que a banda R resultou em um melhor resultado. Em uma escala de [0; 1], as bandas R, B, NIR e G, contribuem com os

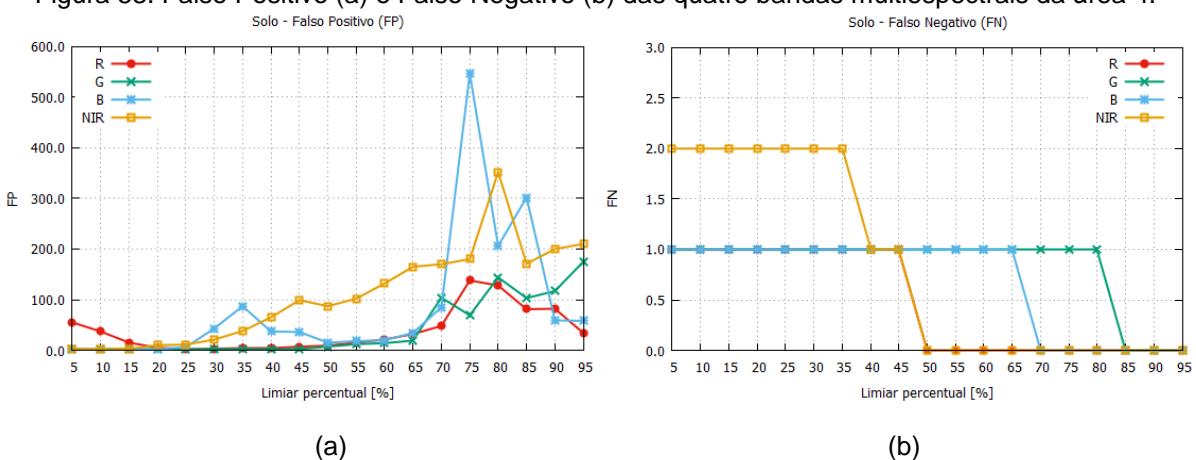
pesos 1; 0,95; 0,64 e 0,60, respectivamente.

Em relação ao indicador nível de acerto (ver Figura 52.b), percebe-se que este indicador, ao contrário da completeza, não resultou em altos níveis de porcentagem, chegando ao valor máximo de 50% apenas. Porém, nota-se o baixo nível de acerto para a banda NIR e a queda da banda B após o limiar de 20%. Entretanto, comparando e analisando quantitativamente as bandas para este parâmetro, conclui-se que a banda R teve o melhor desempenho, para o parâmetro de nível de acerto, sendo que em uma escala de [0;1] as bandas R, G, B e NIR, contribuem respectivamente nas seguintes proporções: 1; 0,96; 0,75 e 0,38.

Em relação ao parâmetro qualidade, Figura 52.c, pode-se confirmar que a banda NIR não tem uma boa resposta para a classe solo exposto, sendo inferior às bandas do visível. Deste modo, analisando as bandas separadamente, para o parâmetro de qualidade, a banda R resulta em uma maior contribuição, sendo que em uma escala de [0; 1] as bandas R, G, B e NIR, resultaram nos valores de 1; 0,98; 0,70 e 0,37, respectivamente.

Desta forma, observando e analisando os dados contidos no gráfico da Figura 53.a, percebe-se que a banda G resulta em baixos valores de falsos positivos, seguido da banda R. Sendo assim, analisando quantitativamente os dados em uma escala de [0; 1] as bandas G, R, B e NIR resultam, respectivamente, nos seguintes pesos: 1; 0,68; 0,58 e 0,36, para este parâmetro.

Figura 53. Falso Positivo (a) e Falso Negativo (b) das quatro bandas multiespectrais da área 4.

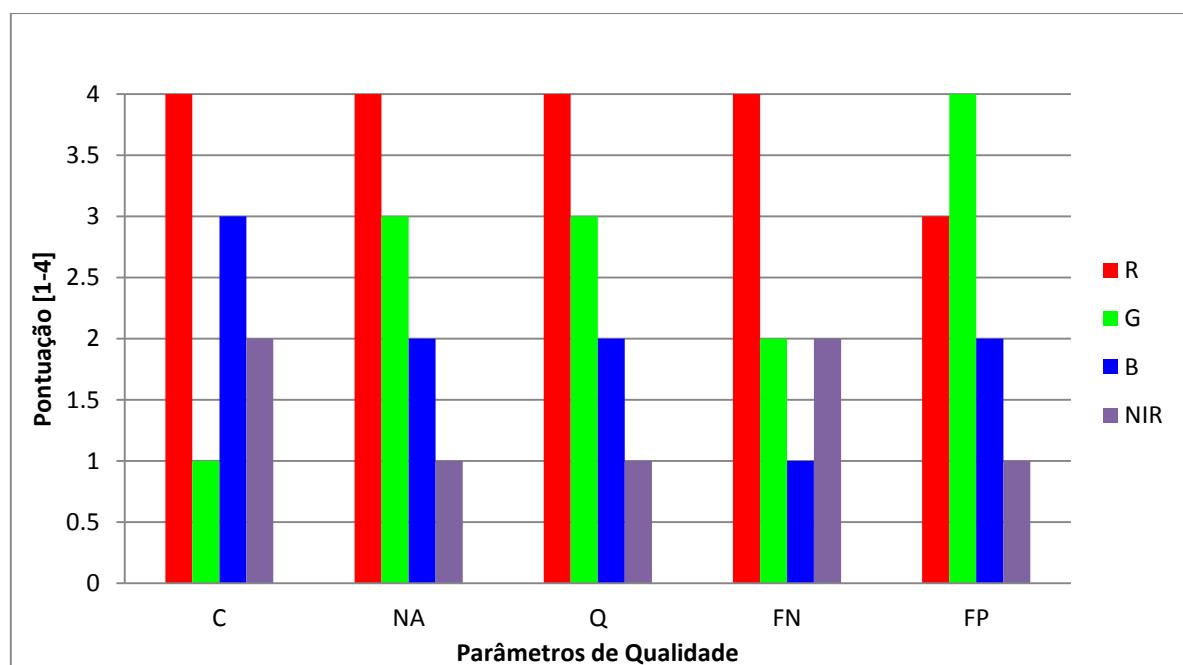


No que concerne aos falsos negativos (ver Figura 53.b), houve um empate em relação as bandas G e do NIR, para este parâmetro, como sendo as

piores bandas para detecção de solo exposto. Realizando-se uma análise quantitativa dos resultados de cada banda em uma escala de [0; 1] as bandas R, B, G e NIR, resultaram nos valores de 1; 0,89; 0,81 e 0,81, respectivamente. Pode-se observar que neste caso existe uma grande ambiguidade entre as bandas, uma vez que as contribuições são todas acima de 0,80.

Em uma abordagem final para esta classe, pode-se concluir ao observar o gráfico da Figura 54, que as bandas correspondentes aos melhores resultados, de um modo geral, foram as bandas R, G, B e NIR, sendo que em uma escala de [0; 1] as bandas contribuem com as proporções 1; 0,57; 0,44 e 0,31, respectivamente. Estes valores indicam uma grande diferença entre a banda R e B, indicando que provavelmente a banda R continuará a se destacar em relação a esta combinação. Em se tratando de uma possível combinação entre as bandas R e G, poderá haver melhores resultados.

Figura 54. Análise das quatro bandas multiespectrais da área 4, para os cinco parâmetros de qualidade



Com base nestes resultados, pode-se dizer que as bandas do visível novamente resultaram em um melhor comportamento, desta vez em relação à detecção de solo exposto. Conclui-se que para a análise de detecção de mudanças em relação à remoção da vegetação, a banda NIR não será utilizada. Logo, para fins

de comparação com uma combinação de bandas, para a classe de solo exposto, as seguintes combinações serão analisadas: Vermelho (R) e Azul (B) – RB; Vermelho (R) e Verde (G) – RG; Vermelho (R), Verde (G) e Azul (B) – RGB.

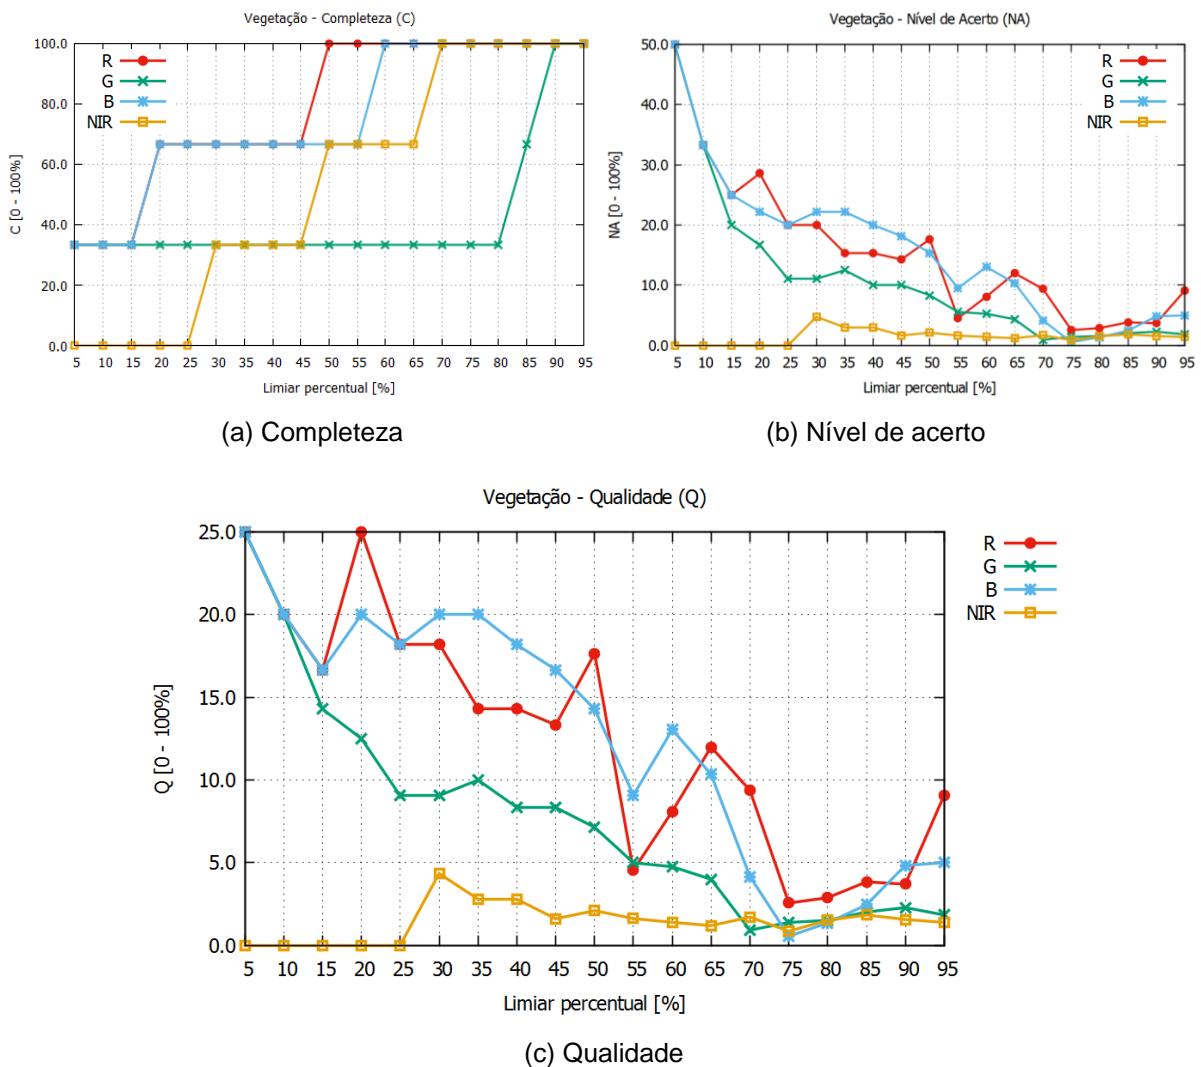
V. Área teste 5

Para a última área teste analisada, utilizou-se a mesma Figura 51, pois nesta mesma figura percebe-se a presença tanto de solo exposto, quanto de vegetação.

Como citado na Seção 4.3, as áreas de cultivo agrícola não irão fazer parte dos cálculos, por se tratar de áreas regularizadas pela empresa Duke Energy. Sendo assim, as modificações presentes dentro destas áreas são irrelevantes para o projeto e são eliminadas da análise a partir do uso das máscaras. No entanto, com o propósito de abranger as modificações de uma forma geral, estudou-se também o comportamento das áreas de cultivo, que pode ser de interesse em outras regiões e não somente em áreas de entorno de reservatórios. Os resultados encontram-se nas Figuras 55, 56 e 57.

Assim como as demais classes, menos a classe de sombras, para a vegetação analisou-se os melhores resultados para os parâmetros de qualidade. Analisou-se esta classe observando a vegetação que se regenerou, que geralmente é presente quando há alguma plantação ou o crescimento de pastagem, por exemplo. Em ambos os casos não haverá intervenção irregular que poderá ser prejudicial ao projeto. No entanto, é importante verificar o comportamento do método RCEN modificado nesta situação, pensando no seu uso em diferentes aplicações. A vegetação verde apresenta grande absorção na banda R, ficando escura, permitindo um bom contraste entre as áreas ocupadas com vegetação (ex. campo, serrado, floresta e áreas de plantio).

Figura 55. Parâmetros de qualidade para as quatro bandas multiespectrais da área 5.



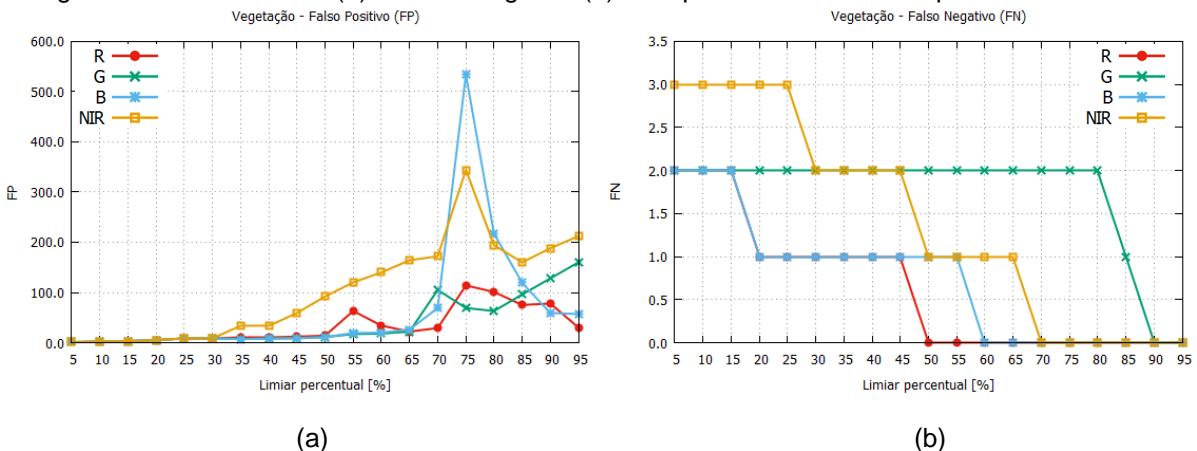
Fazendo então uma análise quantitativa das quatro bandas multiespectrais, para o parâmetro de completeza (Figura 55.a), observou-se que a banda R resultou num melhor resultado, chegando ao valor máximo de completeza para um limiar de 50%, significando que todas as alterações referenciadas foram detectadas. As contribuições das bandas R, B, NIR e G, respectivamente, resultam nos valores de 1; 0,95; 0,64 e 0,60.

Ao observar a Figura 55.b, percebe-se que o nível de acerto não ultrapassou o valor de 50%, concluindo que para esta classe o nível de acerto em geral foi baixo. Entretanto, comparando e analisando quantitativamente as bandas para este parâmetro, conclui-se que a banda R, seguida da B, foram as que mais contribuíram, sendo obtidos os pesos 1; 0,94; 0,54 e 0,36, para as bandas R, B, G e

NIR, respectivamente.

Analizando a qualidade para a classe de vegetação, Figura 55.c, pode-se perceber que as bandas B e R atingiram os maiores valores, porém de um modo geral a qualidade para esta classe não foi boa, atingindo somente os 25%, devido aos baixos níveis de acerto. Em termos de contribuição relativa, a bandas R e B se destacaram, resultando nos pesos 1; 0,94; 0,55 e 0,38, respectivamente para as bandas R, B, G e NIR.

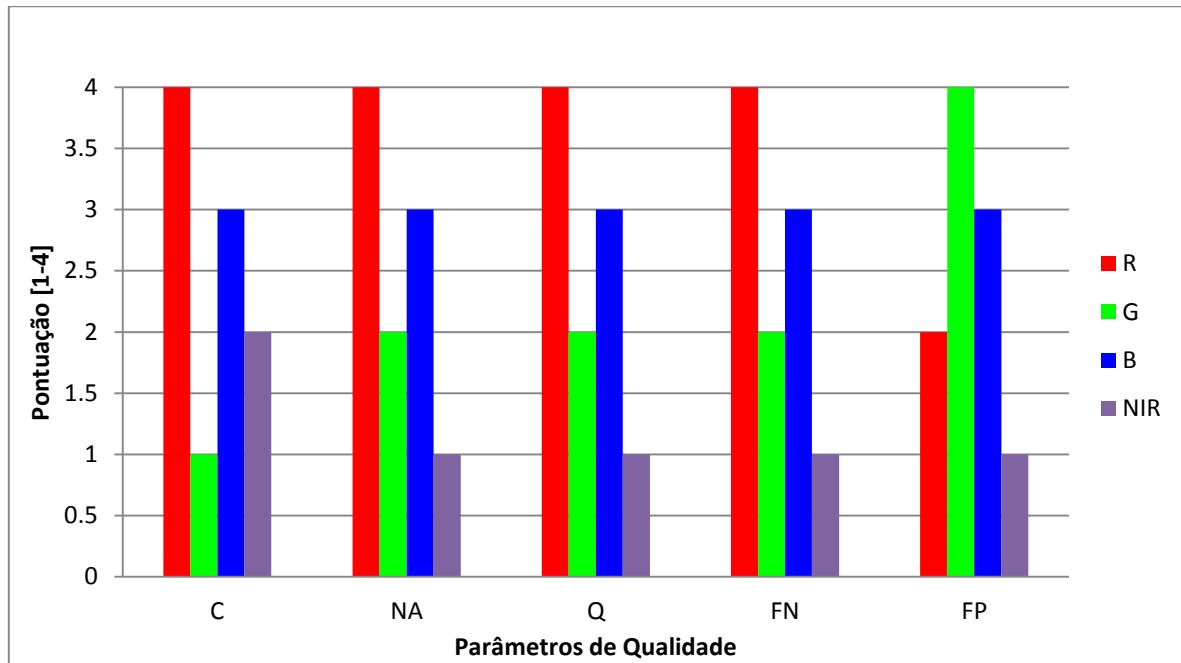
Figura 56. Falso Positivo (a) e Falso Negativo (b) das quatro bandas multiespectrais da área 5.



Por fim em relação aos falsos negativos, Figura 56.b, todas as bandas apresentaram valores nulos para um limiar de 90%, porém há um destaque maior para a banda R que atingiu o valor zero para falso negativo com um limiar de 50%. Realizando-se uma análise quantitativa dos resultados de cada banda em uma escala de [0;1] as bandas R, B, G e NIR, resultaram nos valores de 1; 0,95; 0,56 e 0,53, respectivamente.

A quantidade de falsos positivos para esta classe se mostrou bastante elevada (Figura 56.a), principalmente na banda B, com um limiar de 75%. Porém, de forma geral a banda NIR apresentou-se como sendo a pior banda para esta classe, em relação a quantidade de falsos positivos. Desta forma, observando e analisando os dados contidos no gráfico da Figura 56.a, percebe-se que a banda G resultou em um baixo valor de falsos positivos, juntamente com a banda R. Via de regra, como os falsos positivos são analisados de forma a diminuir a quantidade de detecção, quanto menor for o valor, melhor será o resultado. Em termos de contribuições relativas, em uma escala de [0;1], as bandas G, B, R e NIR contribuem respectivamente com os seguintes pesos: 1; 0,89; 0,87 e 0,61, para este parâmetro.

57. Análise das quatro bandas multiespectrais da área 5, para os cinco parâmetros de qualidade



Pode-se concluir ao observar o gráfico da Figura 57 que as bandas que resultaram nos melhores resultados de um modo geral, para a classe de vegetação, foram as bandas R, B, G e NIR, sendo que em uma escala de [0;1] as bandas contribuem com os pesos de 1; 0,58; 0,52 e 0,31, respectivamente. Estes valores indicam que a diferença entre as bandas B e G são pequenas, em comparação com a influência da banda R. Porém, como a banda R destacou-se em relação às demais, em especial à segunda melhor banda (B), acredita-se que a combinação entre as bandas não irá melhorar os resultados e a banda R continuará a se destacar.

Novamente, percebe-se que as bandas do visível tiveram um melhor resultado em relação a banda NIR para esta classe. Logo, para fins de comparação com uma combinação de bandas, para a classe de vegetação, as seguintes combinações são sugeridas: Vermelho (R) e Azul (B) – RB; Vermelho (R) e Verde (G) – RG; Vermelho (R), Verde (G) e Azul (B) – RGB.

4.7 Efeito da combinação de bandas

Após a análise quantitativa do comportamento das 5 classes estudadas,

para cada banda em separado, resolveu-se então aplicar a combinação de algumas bandas, a fim de buscar melhorar os resultados, ou até mesmo verificar se a combinação de bandas será necessária ou não.

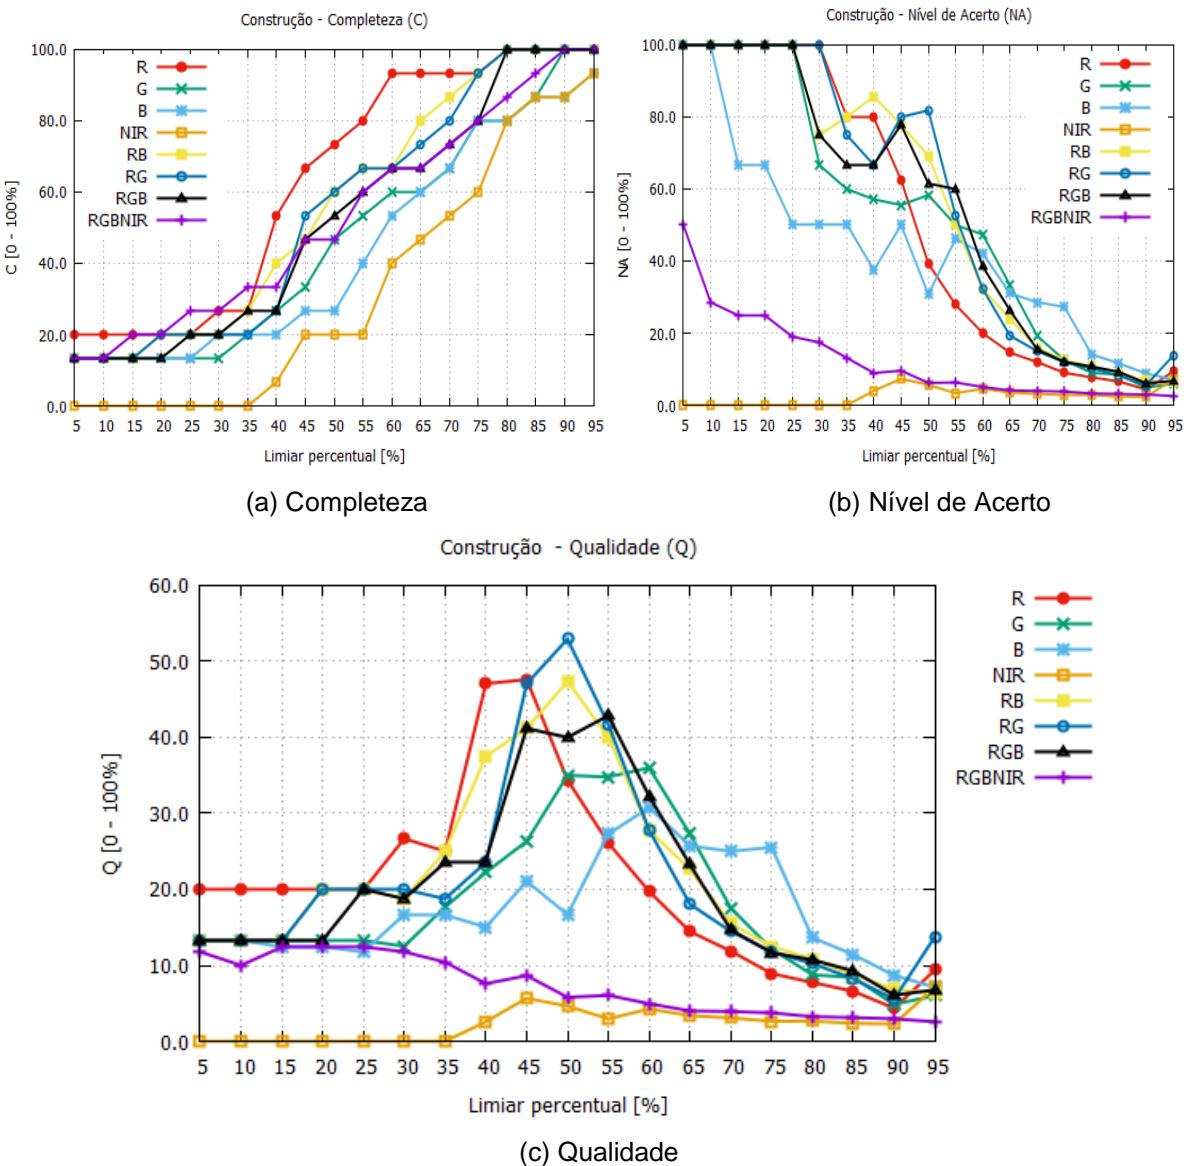
Sendo assim, foram realizados testes sobre as mesmas áreas testes já utilizadas na Seção 4.6. A análise dos resultados é apresentada na sequência, para cada uma das áreas.

I. Área teste 1

Com base nos resultados apresentados referente a área teste 1 (Seção 4.6.(I)), decidiu-se empregar a combinação das três melhores bandas, ou seja, Vermelho e Azul (RB), Vermelho e Verde (RG), Vermelho, Verde e Azul (RGB) e Vermelho, Verde, Azul e Infravermelho Próximo (RGBNIR). A Figura 58 apresenta os parâmetros de qualidade completeza (a), nível de acerto (b) e qualidade (c) gerados a partir de algumas combinações das bandas.

Vale ressaltar, que a banda R conforme apresentado na Seção 4.6.(I), foi a melhor banda para esta classe, tendo em vista que o alvo detectado apresenta grande reflectância nesta região do espectro.

Figura 58. Parâmetros de qualidade empregando a combinação de bandas para área 1.



Portanto, nota-se, com base na Figura 58.a, que a completeza resultante da combinação da banda R com as bandas remanescentes, resultaram em uma melhor performance para a detecção de construções. Deste modo, considerando a banda R, combinada com as demais bandas, obtém-se a combinação com maior completeza, RGBNIR; seguida das combinações RB, RG, RGB, resultando nos pesos 0,66; 0,65; 0,61 e 0,57; respectivamente, em uma escala de [0;1]. Além disso, é possível observar, que a completeza destas combinações apresenta comportamento similar utilizando limiares de 40 a 60%.

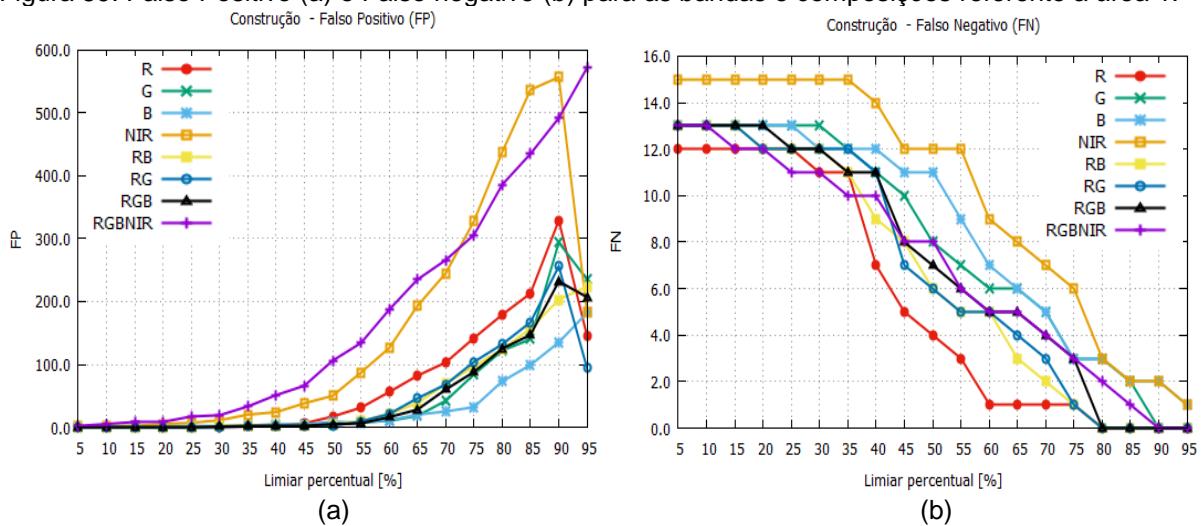
Analizando a Figura 58.b, bem como os pesos associados às diferentes

combinações, que resultaram nos valores de peso de 1; 0,98; 0,94; 0,90; 0,86; 0,83; 0,35 e 0,29, respectivamente, para as classes RG, RB, B, RGB, G, R, RGBNIR e NIR, nota-se que a combinação R e G, seguida da R e B e da banda B, foram as melhores. No entanto, ao contrário da completeza, o nível de acerto da combinação RGBNIR resultou nos menores valores, tornando esta combinação inviável para a detecção de construções. Vale ressaltar que as principais bandas e combinações, referentes ao nível de acerto, resultaram em valores similares, principalmente ao empregar o limiar maior que 65%.

De modo geral, analisando o parâmetro qualidade (Figura 58.c), nota-se que as bandas e composições que resultaram em maior desempenho na detecção das construções ocorreram quando empregados os limiares de 40 à 55%. No entanto, realizando uma análise mais minuciosa tem-se que, das bandas isoladas, a banda R resultou na maior qualidade. Deste modo, atribuindo a esta banda o valor 1, obtém-se os valores 0,86; 0,84; 0,83; 0,77; 0,68; 0,34 e 0,29, para as combinações RB, B, RG, RGB, G, RGBNIR e NIR, respectivamente.

A Figura 59 apresenta os falsos positivos (a) e falsos negativos (b), para as diferentes combinações no experimento 1. Deste modo, conforme os resultados indicados na Figura 59.a, nota-se que a banda NIR e a composição RBGNIR se apresentaram com maior sensibilidade nas detecções em geral, principalmente nos limiares superiores a 40%. Porém, tais detecções apresentam baixos níveis de completeza e nível de acerto, como descritos anteriormente, o que torna a banda NIR e composições que a empregam, não adequada para a detecção automática de mudanças concernentes à construção.

Figura 59. Falso Positivo (a) e Falso negativo (b) para as bandas e composições referente a área 1.

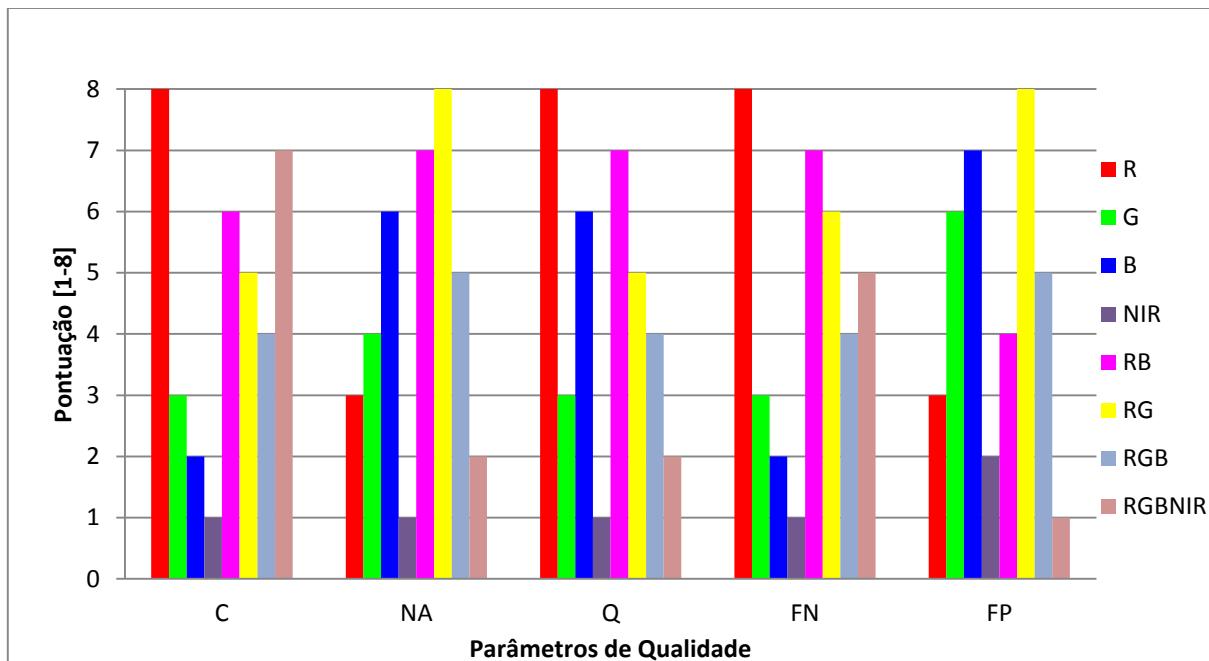


No entanto, considerando o espectro visível, pode-se verificar que a composição RG foi a que apresentou o menor índice de falsos positivos. Sendo assim, para uma melhor análise e comparação dos resultados entre as bandas remanescente, em uma escala [0;1] a combinação RG obteve o valor 1, sendo para as demais combinações (B, G, RGB, RB, R, NIR e RGBNIR) os valores de 0,97; 0,96; 0,96; 0,93; 0,80; 0,36 e 0,30, respectivamente.

Por outro lado, a banda R, apresenta o menor valor de falsos negativos (Figura 59.b), principalmente entre os limiares 35 à 75%, seguido das composições e bandas que apresentaram maior eficiência, RB, RG, RGBNIR, RGB, G, B e NIR, atingindo valores em escala 0,68; 0,65; 0,65; 0,56; 0,43; 0,37 e 0,29, respectivamente.

Por fim, a Figura 60 apresenta um resultado geral dos parâmetros e índices avaliados anteriormente. Como é possível notar, as bandas que apresentaram maior desempenho quanto a detecção de construção, foi a banda R, seguida das composição RG, RB, banda B, RGBNIR, RGB, G e NIR, que apresentam nesta ordem de escala de melhoria os pesos os valores 1; 0,85; 0,61; 0,44; 0,35; 0,33 e 0,31.

Figura 60. Análise das quatro bandas multiespectrais e da combinação de bandas da área 1, para os cinco parâmetros de qualidade.



Pode-se então concluir-se que para a detecção de construções de forma automática, recomenda-se a utilização da banda R com um limiar de 40%.

II. Área teste 2

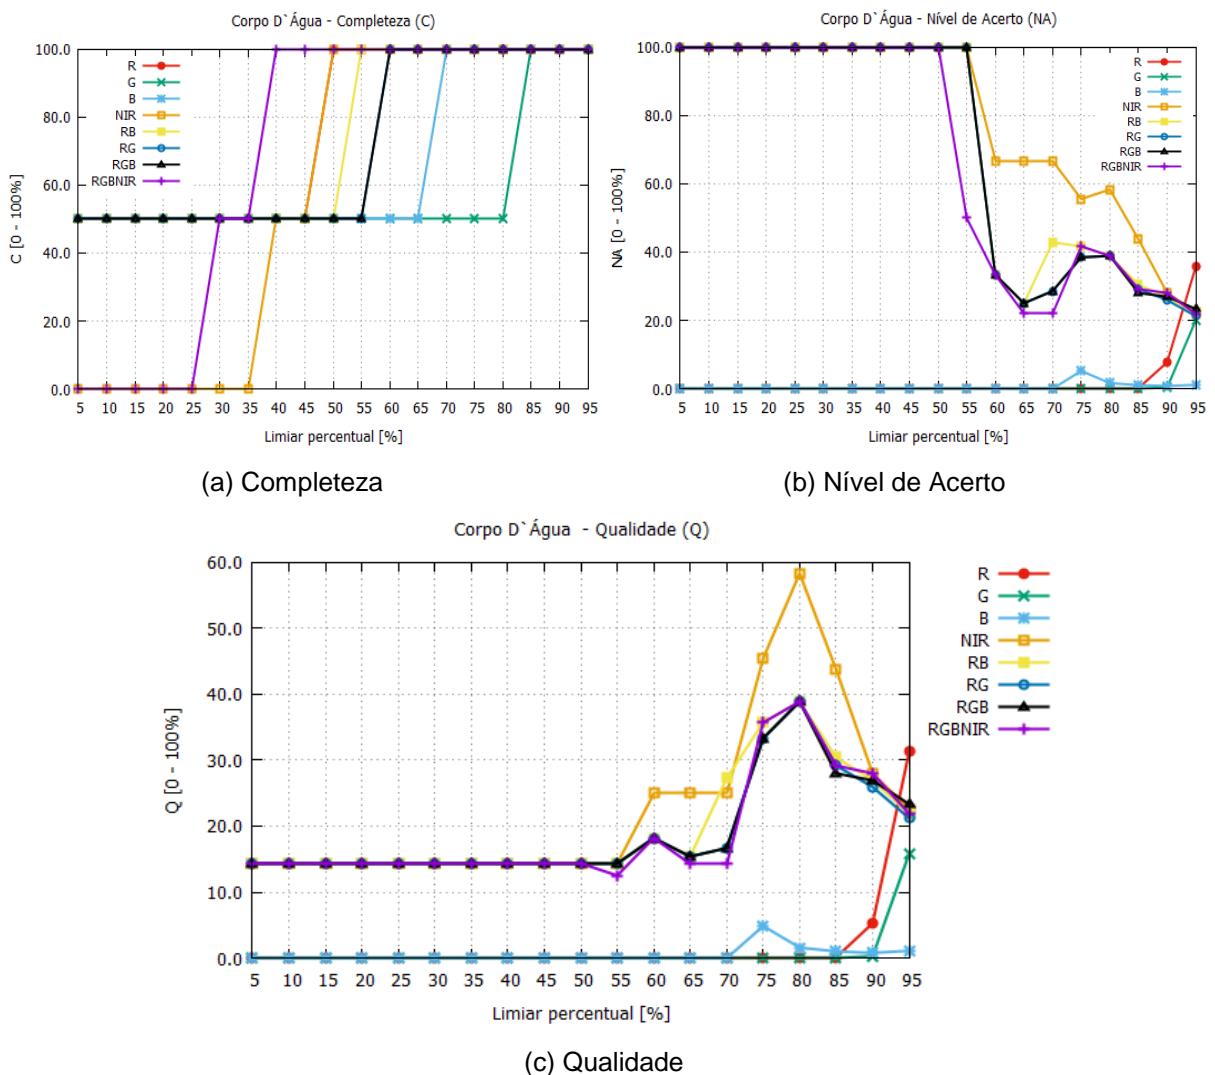
A Figura 61, apresenta os gráficos dos parâmetros de completeza (a), nível de acerto (b), e de qualidade (c) gerados resultantes das combinações das três primeiras bandas, sendo elas, Azul e Infravermelho Próximo (BNIR), Vermelho e Infravermelho Próximo (RNIR), Vermelho, Azul e Infravermelho Próximo (RBNIR) e Vermelho, Verde, Azul e Infravermelho Próximo (RGBNIR), aplicadas na área teste 2, a partir dos resultados da Seção 4.6.(II).

Vale ressaltar que a banda NIR apresentou o melhor desempenho para esta classe (conforme Seção 4.6.(II)), tendo em vista que o alvo de interesse absorve toda radiação acima de um comprimento de onda de 0,7 µm, permitindo deste modo, delinear os corpos d'água, bem como a identificação das macrófitas aquáticas. Com base na Figura 61.a, nota-se que as maiores completezas para a área 2 (corpos d'água) são obtidas ao considerar a inclusão da banda NIR junto com

as demais bandas.

Deste modo, considerando as composições a partir da banda NIR, tem-se na ordem de maior desempenho, as composições, BNIR, NIR, RNIR, RBNIR, RGBNIR, com pesos de 1; 0,97; 0,97; 0,97 e 0,97, respectivamente. Já no que diz respeito às bandas do visível, a banda que resultou na maior completeza foi a B, seguida da R e G, de modo que suas contribuições são proporcionais a 0,52; 0,46; e 0,45; respectivamente. É importante destacar que as bandas B e G apresentam grande penetração em corpos d'água. No entanto, a banda G permite análises em termos de qualidade da água, ou seja, apresenta sensibilidade à presença de sedimentos em suspensão. Deste modo, tais bandas complementam a eficácia da banda NIR em detectar mudanças em corpos d'água.

Figura 61. Parâmetros de qualidade empregando a combinação de bandas para área 2.

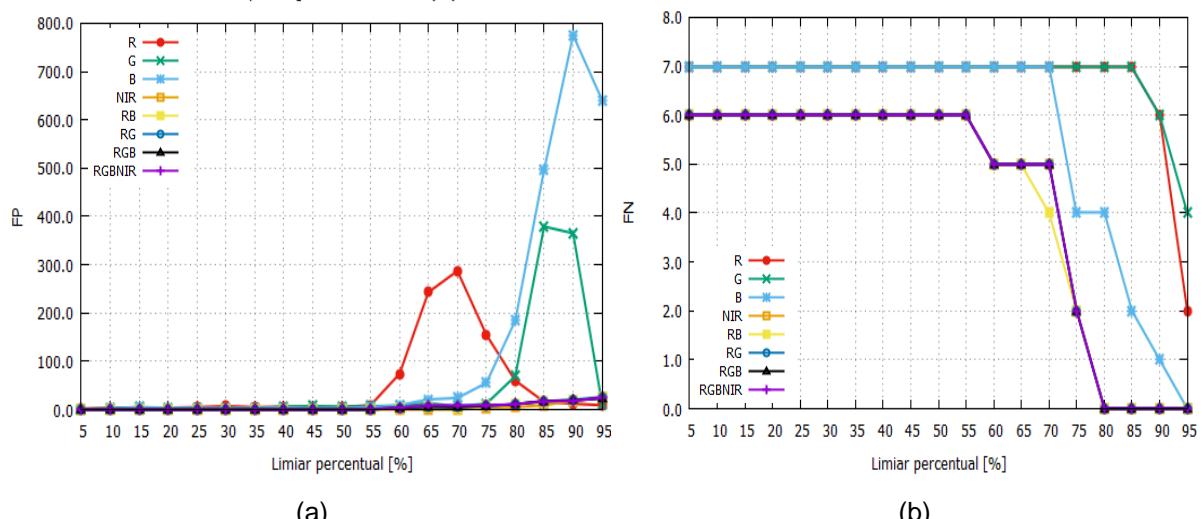


Observando os níveis de acerto (Figura 61.b), verifica-se que a banda NIR apresentou o maior valor, seguida das seguintes composições: BNIR, RGBNIR, RBNIR, RNIR e das bandas R, B e G. Deste modo, considerando uma escala no intervalo [0;1], obteve-se os valores de 1; 0,81; 0,80; 0,78; 0,76; 0,43; 0,39 e 0,38, respectivamente. Destaca-se o baixo nível de acerto para as bandas do visível, com valores menores que 40%.

Analizando o parâmetro qualidade (Figura 61.c), nota-se que as bandas e composições tiveram maior performance na detecção das alterações sob os corpos d'água ao empregar os limiares de 60 à 90%, sendo que o máximo de qualidade foi obtido com limiar de 80%. No entanto, realizando uma análise mais minuciosa tem-se que a banda NIR resultou na maior qualidade. Deste modo, atribuindo a esta o valor 1, obtém-se 0,86; 0,81; 0,79; 0,79; 0,45; 0,41 e 0,40, para as combinações BNIR, RBNIR, RNIR, RGBNIR, R, B e G, respectivamente, ou seja, há uma redução na qualidade em aproximadamente 50% ao empregar as bandas do visível. A partir destes valores pode-se notar que a contribuição de algumas combinações são muito similares, como por exemplo RBNIR, RNIR e RGBNIR.

A Figura 62 apresenta os falsos positivos (a) e falsos negativos (b) concernentes as detecções de alterações nos corpos d'água da área teste 2.

Figura 62. Falso Positivo (a) e Falso negativo(b) para as bandas e composições referente a área 2.
Corpo D' Água - Falso Positivo (FP)



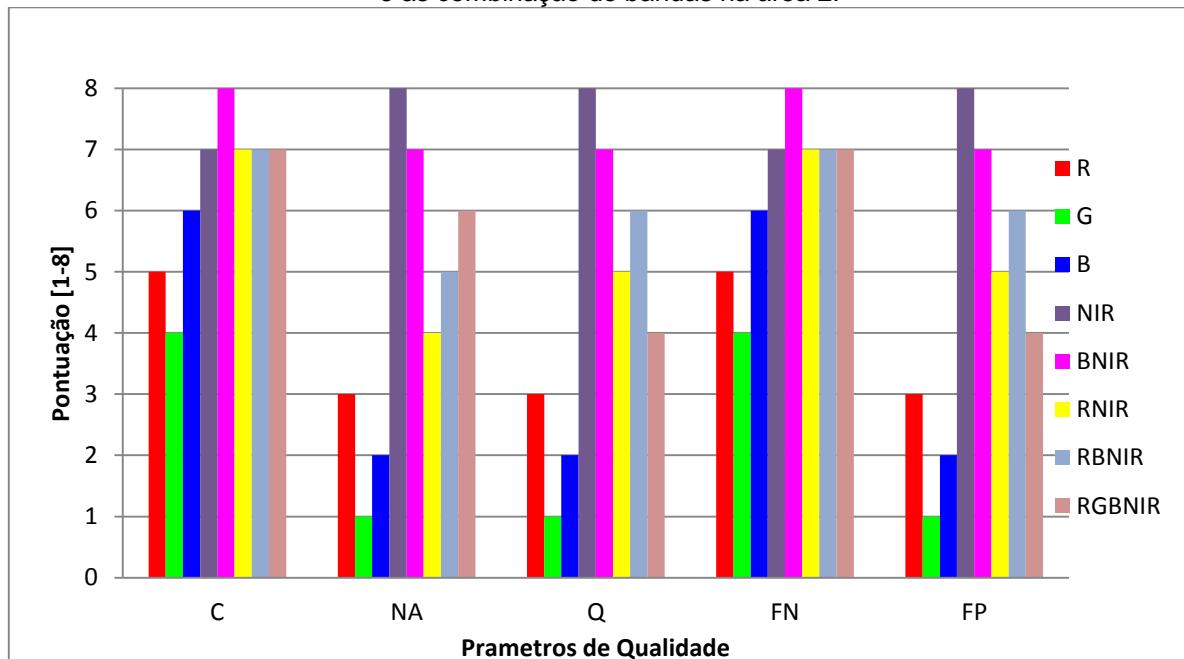
Conforme os resultados da Figura 62.a, nota-se que as bandas do visível apresentaram falsos positivos superiores a 100. Por outro lado, as composições com

a banda NIR, foram as que apresentaram os menores índices de falsos positivos, sendo, nesta ordem, ou seja: NIR, BNIR, RBNIR, RNIR, RGBNIR, R, B e G os respectivos pesos iguais a 1; 0,82; 0,79; 0,78; 0,77; 0,40; 0,38 e 0,34.

No que se refere aos resultados dos falsos negativos apresentados na Figura 62.b, nota-se que houve uma quantidade baixa de falsos negativos, principalmente considerando limiares maiores que 65%. A composição BNIR, a qual combina as características de delimitar os corpos d'água, realçar as áreas ocupadas com macrófitas aquáticas (banda NIR), bem como, a penetração em corpos d'água, foi a que apresentou o menor valor de falsos negativos (Figura 62.b), seguida das composições e bandas, NIR, RNIR, RBNIR, RGBNIR, B, R e G, que resultaram na respectivas contribuições de 0,97; 0,97; 0,97; 0,97; 0,51; 0,45 e 0,44.

Finalizando a análise para a área 2, a Figura 63 apresenta valores que resumem os resultados para os diferentes parâmetros avaliados. Como pode-se notar, a banda que apresentou maior performance quanto a classe de corpos d'água, foi a NIR, seguida das composição BNIR, RBNIR, RGBNIR, RNIR, e das bandas B, R e G, que resultaram respectivamente nos seguintes pesos: 1; 0,87; 0,48; 0,43; 0,42; 0,27; 0,25 e 0,19.

Figura 63. Análise dos cinco parâmetros de qualidade empregando as quatro bandas multiespectrais e as combinação de bandas na área 2.



Sendo assim, como base nos resultados finais para a classe de corpos

d'água, conclui-se então que para a detecção de alteração sob um corpo d'água de forma automática, recomenda-se a utilização da banda NIR com um limiar de 80%.

III. Área teste 3

Com base nos resultados referentes a área teste 3, descritos na Seção 4.6.(III), decidiu-se empregar a combinação das três melhores bandas, ou seja, Vermelho e Azul (RB); Vermelho e Verde (RG); Vermelho, Verde e Azul (RGB) e Vermelho, Verde, Azul e Infravermelho Próximo (RGBNIR). A Figura 64 apresenta os parâmetros de qualidade: completeza (a), nível de acerto (b) e qualidade (c) gerados, resultantes dos processamentos destas composições de bandas.

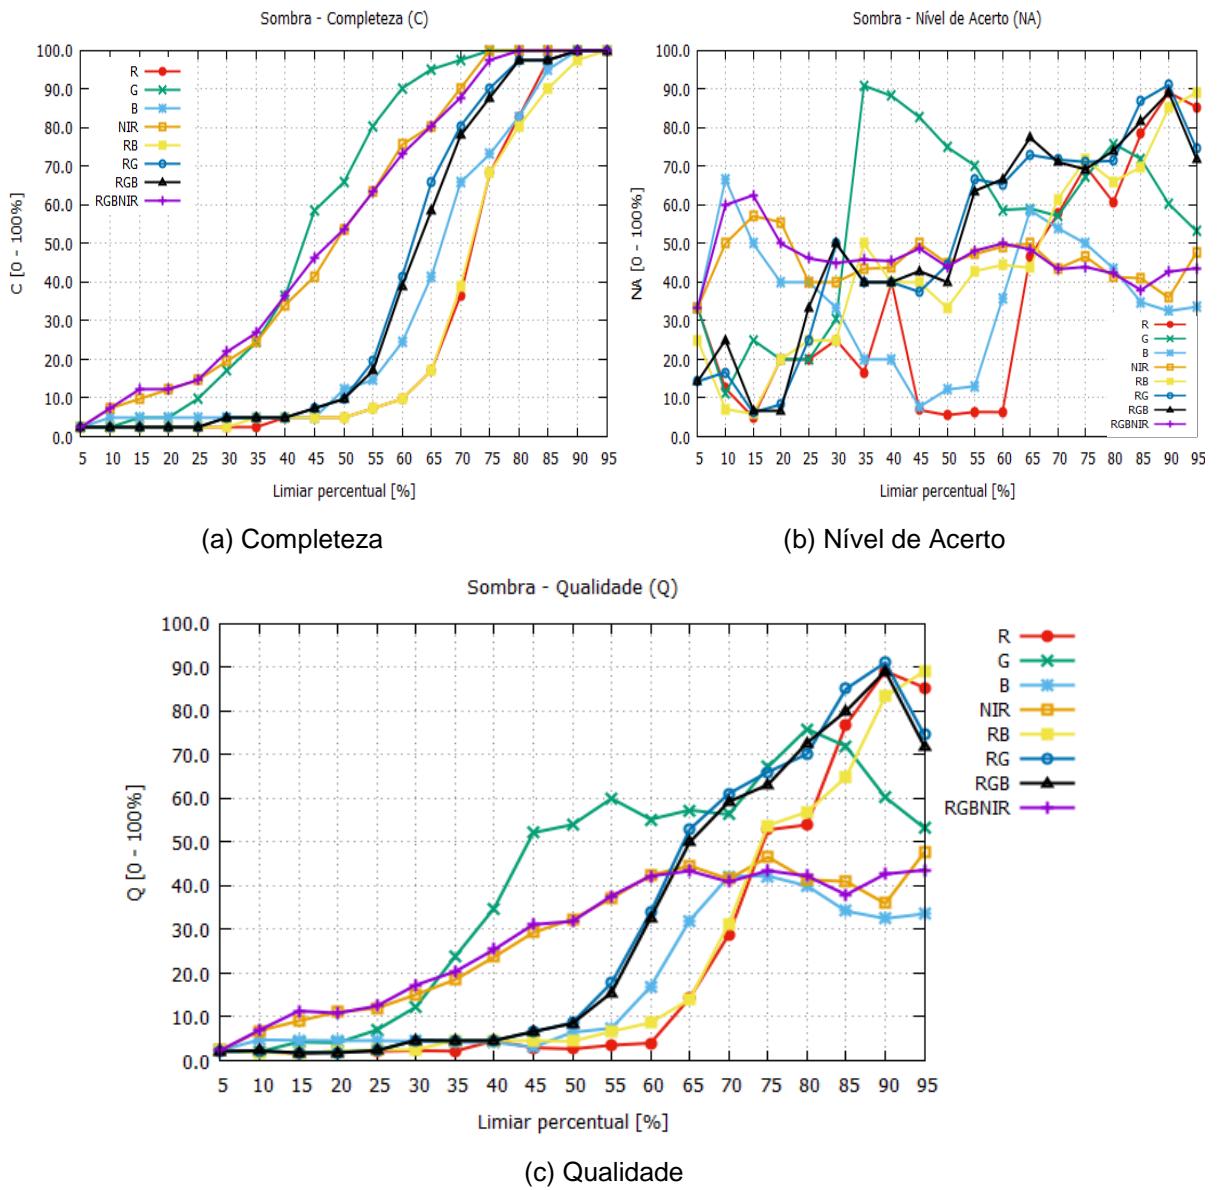
Vale ressaltar, que a sombra não era para ser considerada uma detecção de interesse, já que a mesma é uma alteração natural e inevitável. Porém, conforme analisado na Seção 4.6.(III) a banda R foi a melhor banda para esta classe, ou seja, a que possibilitou menor quantidade de detecções. Deste modo, nota-se na Figura 64.a, que as bandas e composições que são menos sensíveis a sombra são, nesta ordem: RB, R, RGB, RG, B, G, NIR e RGBNIR, as quais correspondem ao valores de peso de 0,96; 0,65; 0,63; 0,60; 0,42; 0,38 e 0,36, respectivamente.

Referente ao nível de acerto (ver Figura 64.b), verifica-se que a banda R apresentou o menor nível de acerto, seguida das bandas e composições, B, RB, RGB, RG, RGBNIR, NIR e G. Deste modo, considerando uma escala de [0;1], obteve-se, na ordem de maior desempenho para desconsiderar as sombras os seguintes valores 1; 0,84; 0,63; 0,59; 0,55; 0,52; 0,50 e 0,43. Além disso, observa-se que as bandas R e G, nos limiares 30% à 60%, não atingiram o nível de acerto de 50%.

Sendo assim, de modo geral e analisando o parâmetro qualidade (Figura 64.c), nota-se que as bandas e composições que tiveram menor sensibilidade às sombras foram (nesta ordem): R, B, RB, RGB, RG, RGBNIR, NIR e G, apresentando os valores de peso iguais a 1; 0,85; 0,74; 0,50; 0,47; 0,41; 0,39 e 0,32, respectivamente. Pode-se notar uma redução na qualidade em aproximadamente 50% ao empregar as bandas do visível. Além disso, verifica-se que as melhores bandas para a classe sombra, possuem melhor performance empregando limiares

abaixo de 65%.

Figura 64. Parâmetros de qualidade empregando a combinação de bandas para área 3.



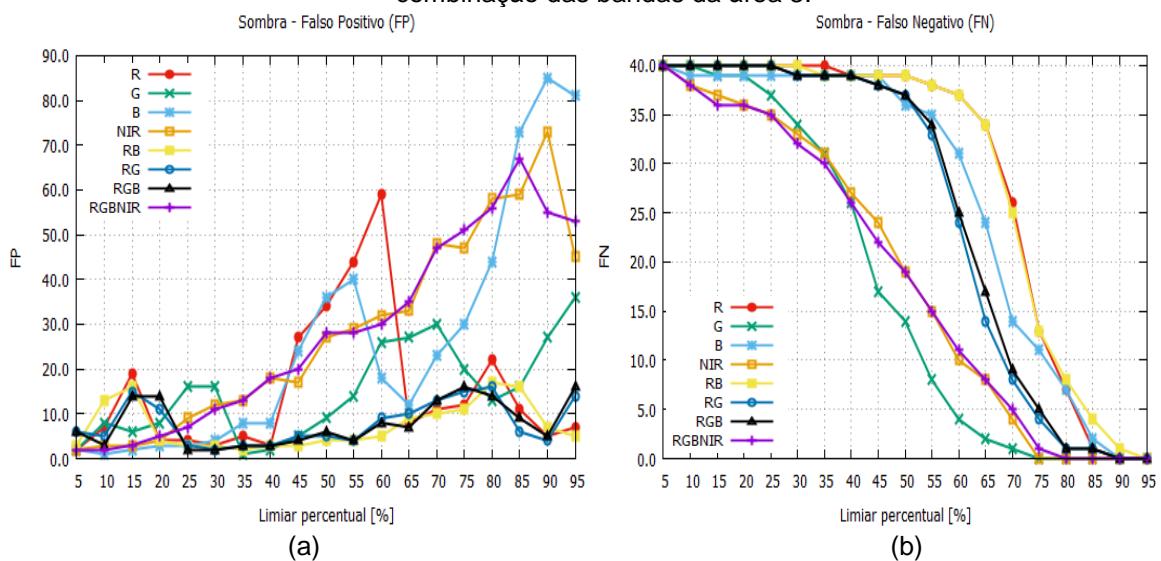
A Figura 65 apresenta os falsos positivos (a) e falsos negativos (b) relativos às detecções de sombra da área teste 3. Conforme os resultados da Figura 65.a, nota-se que as composições empregando as bandas do visível, RB, RGB, RG, resultaram nas menores quantidades de falsos positivos, de tal modo, que se mantiveram abaixo de 20, independente do limiar.

Em suma, as composições RB, RGB, RG, seguidas das bandas G, B, R, RGBNIR e NIR, são, nesta ordem, as que resultam em um menor número de falsos

positivos, representando em uma escala de 0 à 1, os respectivos valores de peso: 1; 0,85; 0,80; 0,67; 0,64; 0,62; 0,46 e 0,45.

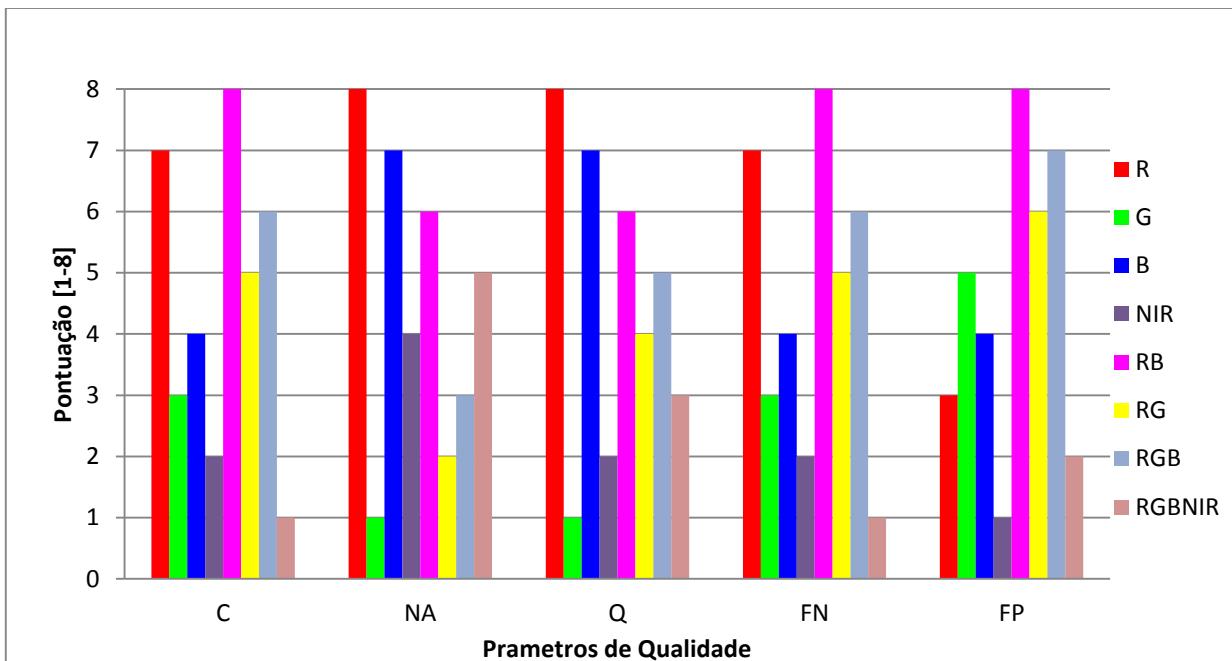
Em relação aos falsos negativos (Figura 65.b), nota-se que houve uma quantidade relativamente alta de ocorrência para limiares menores que 65%, para algumas combinações. Deste modo, as composições que resultaram na maior quantidade de sombras não detectadas são RB, R, RGB, RG, B, G, NIR e RGBNIR, correspondendo aos respectivos pesos de 1; 0,96; 0,68; 0,66; 0,62; 0,42; 0,39 e 0,36.

Figura 65. Falso Positivo (a) e Falso Negativo (FN) das quatro bandas multiespectrais e da combinação das bandas da área 3.



Diante do exposto, a Figura 66 apresenta um resultado síntese das análises dos parâmetros avaliados anteriormente. Como pode-se notar, a combinação que apresentou maior performance quanto a não detecção da sombra foi a RB, seguida das bandas do visível R, B, RGB, RG, G, e por último, com pior desempenho, RGBNIR e NIR que apresentam nesta ordem de escala os pesos 1; 0,86; 0,44; 0,43; 0,32; 0,23; 0,22 e 0,21, respectivamente. Vale ressaltar, que o emprego da banda NIR evidencia as sombras, por ser sensível a rugosidade das copas de florestas sendo, portanto, inadequado para aplicação de detecção de mudanças antrópicas e naturais.

Figura 66. Análise dos cinco parâmetros de qualidade empregando as quatro bandas multiespectrais e as combinação de bandas na área 3.



Logo, com base nos resultados finais para a classe de sombras, conclui-se que para a detecção de alteração de forma automática, de modo, que diminua a detecção em sombras, recomenda-se a utilização da combinação RB ou da banda R, ambas com um limiar de 15% a 60%. Admitiu-se utilizar duas possibilidades para a classe sombra, por esta classe não se tratar de uma intervenção, mas sim de apenas uma classe para auxiliar na diminuição da detecção de falsos positivos concernentes as sombras. Este intervalo foi escolhido após considerar as respostas das bandas R e RB, como mostrado na Figura 64.c, que corresponde a um intervalo onde a resposta destas bandas é baixa para este tipo de alvo.

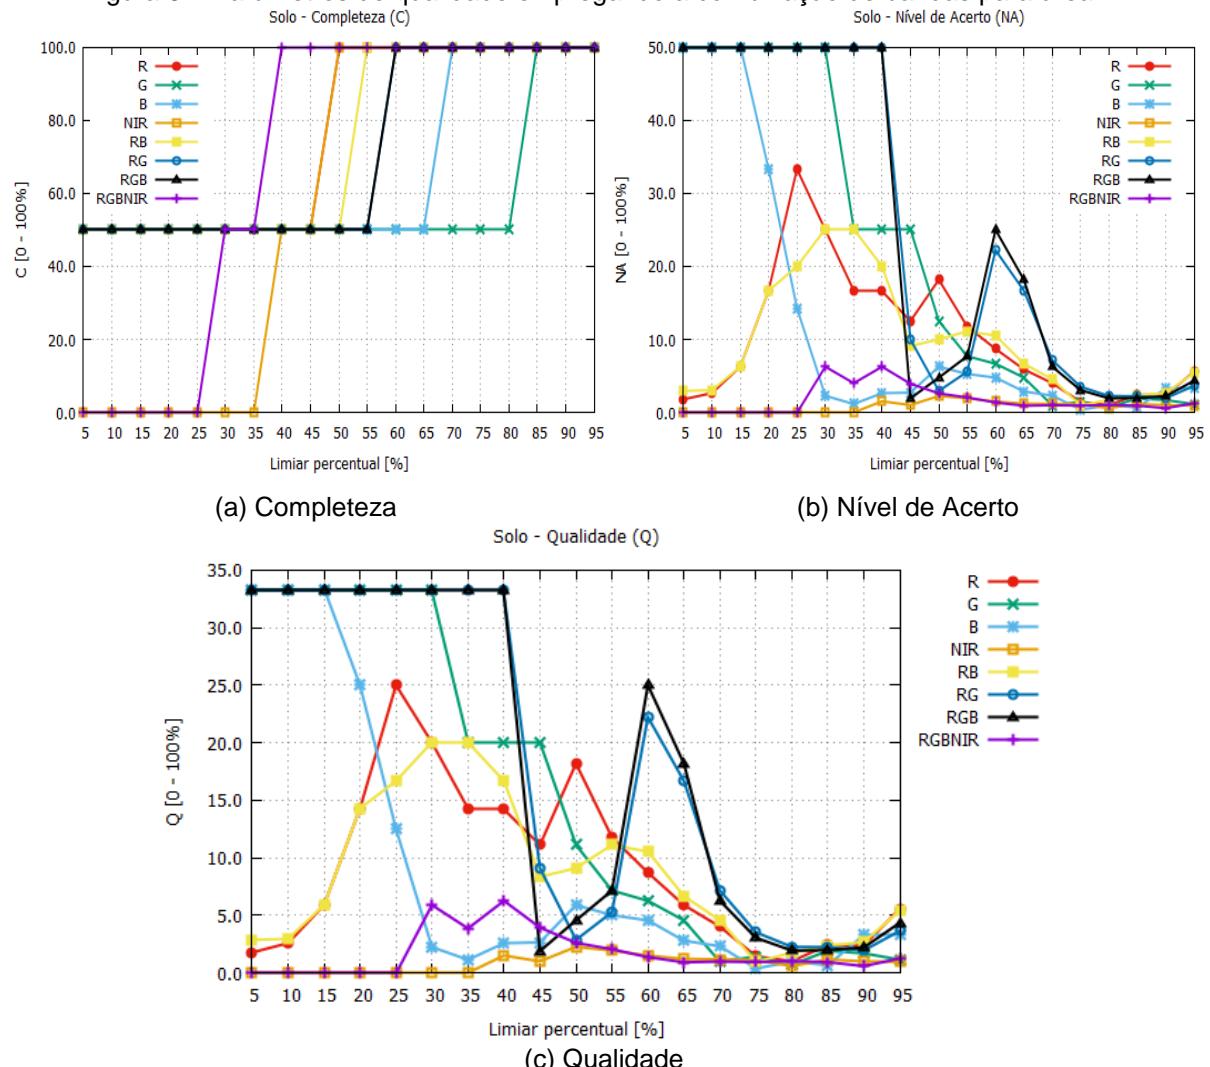
IV. Área teste 4

Nesta seção são apresentados os resultados e análises dos parâmetros de qualidade obtidos a partir das composições das melhores bandas empregadas na Seção 4.6.(IV) para a área teste 4 (solo exposto). As bandas consideradas são Vermelho e Azul (RB); Vermelho e Verde (RG); Vermelho, Verde e Azul (RGB) e Vermelho, Verde, Azul e Infravermelho Próximo (RGBNIR). A Figura 67 apresenta os

parâmetros de completeza (a), nível de acerto (b) e qualidade (c).

Como é possível ver na Seção 4.6.(IV) a banda R foi considerada a melhor banda para detectar alterações na classe solo, o que é justificado pela representação com grande contraste as áreas ocupadas com vegetação, solo exposto, estradas e área urbana. Deste modo, considerando as composições a partir da banda R, tem-se na ordem de maior completeza as composições, R, RB, RG, RGB, RGBNIR, B, G e NIR, com pesos proporcionais a 1; 0,97; 0,94; 0,94; 0,92; 0,89; 0,83 e 0,81, respectivamente. Pode-se observar para algumas dessas combinações uma grande ambiguidade.

Figura 67. Parâmetros de qualidade empregando a combinação de bandas para área 4.



É importante destacar que a resposta espectral do solo depende de diversos fatores tais como textura, umidade, concentração de matéria orgânica,

composição, entre outras. Em função da possibilidade de modificação de todos estes fatores ao longo do tempo percebe-se que não é fácil a seleção de uma única banda.

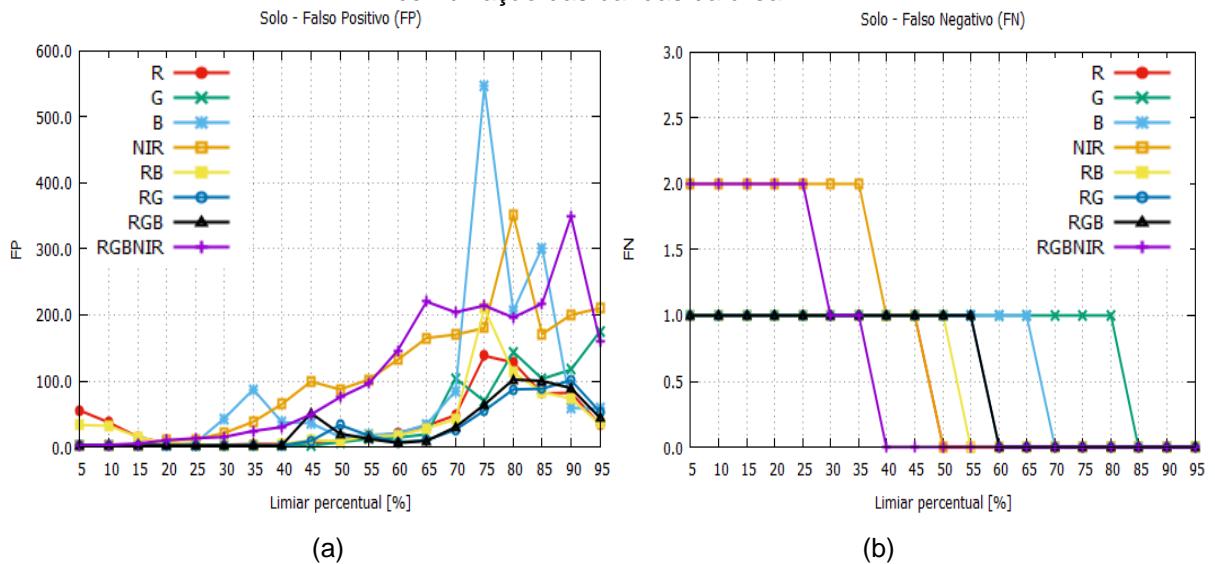
A partir deste fato e da análise da Figura 67.b, pode-se notar que a composição RGB apresentou o maior nível de acerto, para alguns intervalos, seguida das seguintes composições: RG, G, R, RB, B, RGBNIR e NIR. Deste modo, considerando uma escala entre 0 e 1, os valores dos respectivos pesos correspondem aos valores 1, 0,96; 0,77; 0,68; 0,56; 0,54; 0,27 e 0,26. Além disso, pode-se observar que as bandas e composições do experimento não atingiram o nível de acerto maior que 50% e que as respostas das bandas RGB e RG são similares.

Ao considerar a qualidade (Figura 67.c), nota-se que as bandas e composições de maior eficiência na detecção de alterações para solo expostos, foram nesta ordem de qualidade, RG, RGB, G, R, RB, B, RGBNIR e NIR, apresentando respectivamente os valores 1; 0,96; 0,76; 0,68; 0,56; 0,53; 0,28 e 0,25. Percebe-se que ocorre uma redução na qualidade ao empregar a banda do NIR. Além disso, verifica-se que as melhores bandas para classe solo, possuem melhor desempenho ao empregar limiares abaixo de 40%.

A Figura 68 apresenta os falsos positivos (a) e falsos negativos (b) para a detecção de solos para a área teste 4. Como se observa na Figura 68.a, as composições RGB e RG, seguidas das bandas e composições G, R, B, RB, NIR e RGBNIR são, nesta ordem, as que apresentaram a menor quantidade de falsos positivos, obtendo-se os seguintes pesos: 1; 0,99; 0,86; 0,54; 0,52; 0,49; 0,31 e 0,28, respectivamente.

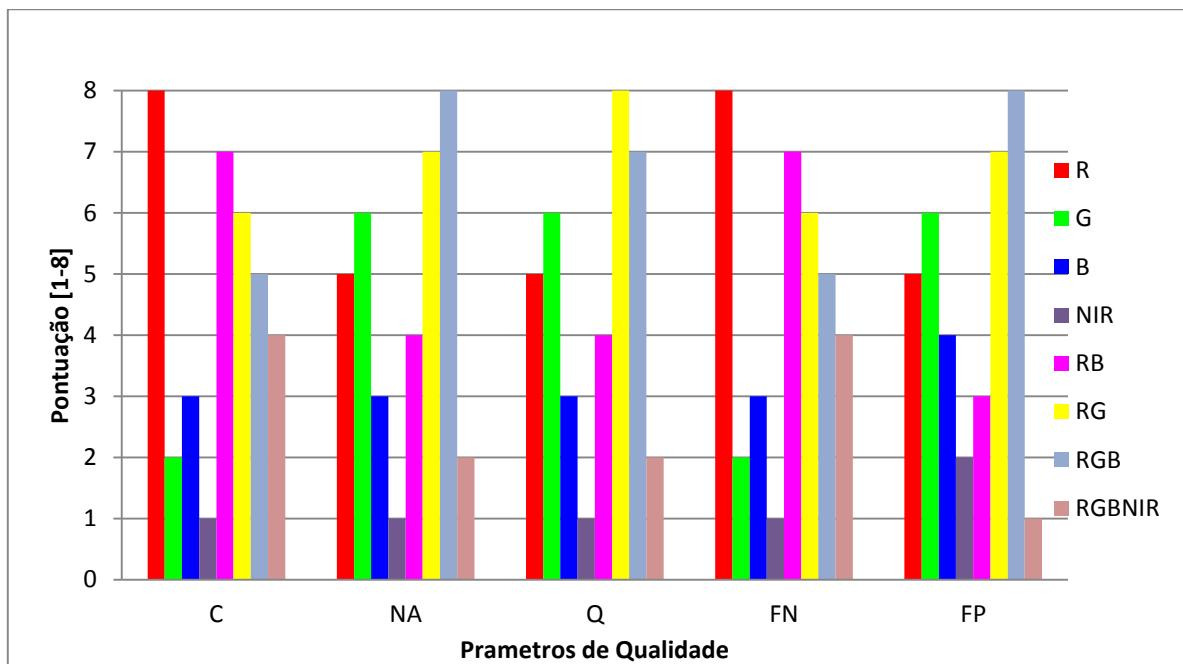
Na análise de falsos negativos (Figura 68.b), nota-se de modo geral que a quantidade de falsos negativos foi relativamente baixa. Deste modo, considerando a quantidade de falsos negativos as composições R, RB, RG, RGB, RGBNIR, B, G e NIR, as quais apresentaram pesos 1; 0,97; 0,94; 0,94; 0,92; 0,89; 0,81 e 0,78, respectivamente, foram as mais indicadas. Percebe-se que alguns valores são muito similares, indicando ambiguidade na detecção.

Figura 68. Falso Positivo (a) e Falso Negativo (FN) das quatro bandas multiespectrais e da combinação das bandas da área 4.



A Figura 69 apresenta uma síntese dos resultados obtidos nesta área teste. Como pode-se notar, as bandas que apresentaram maior desempenho quanto a detecção de solo, foi a composição RGB seguida da banda R, RG, RB, G, B, RGBNIR e NIR, que apresentam, respectivamente os seguintes pesos: 1; 0,92; 0,89; 0,52; 0,43; 0,29; 0,27 e 0,21.

Figura 69. Análise das quatro bandas multiespectrais e da combinação de bandas da área 4, para os cinco parâmetros de qualidade.



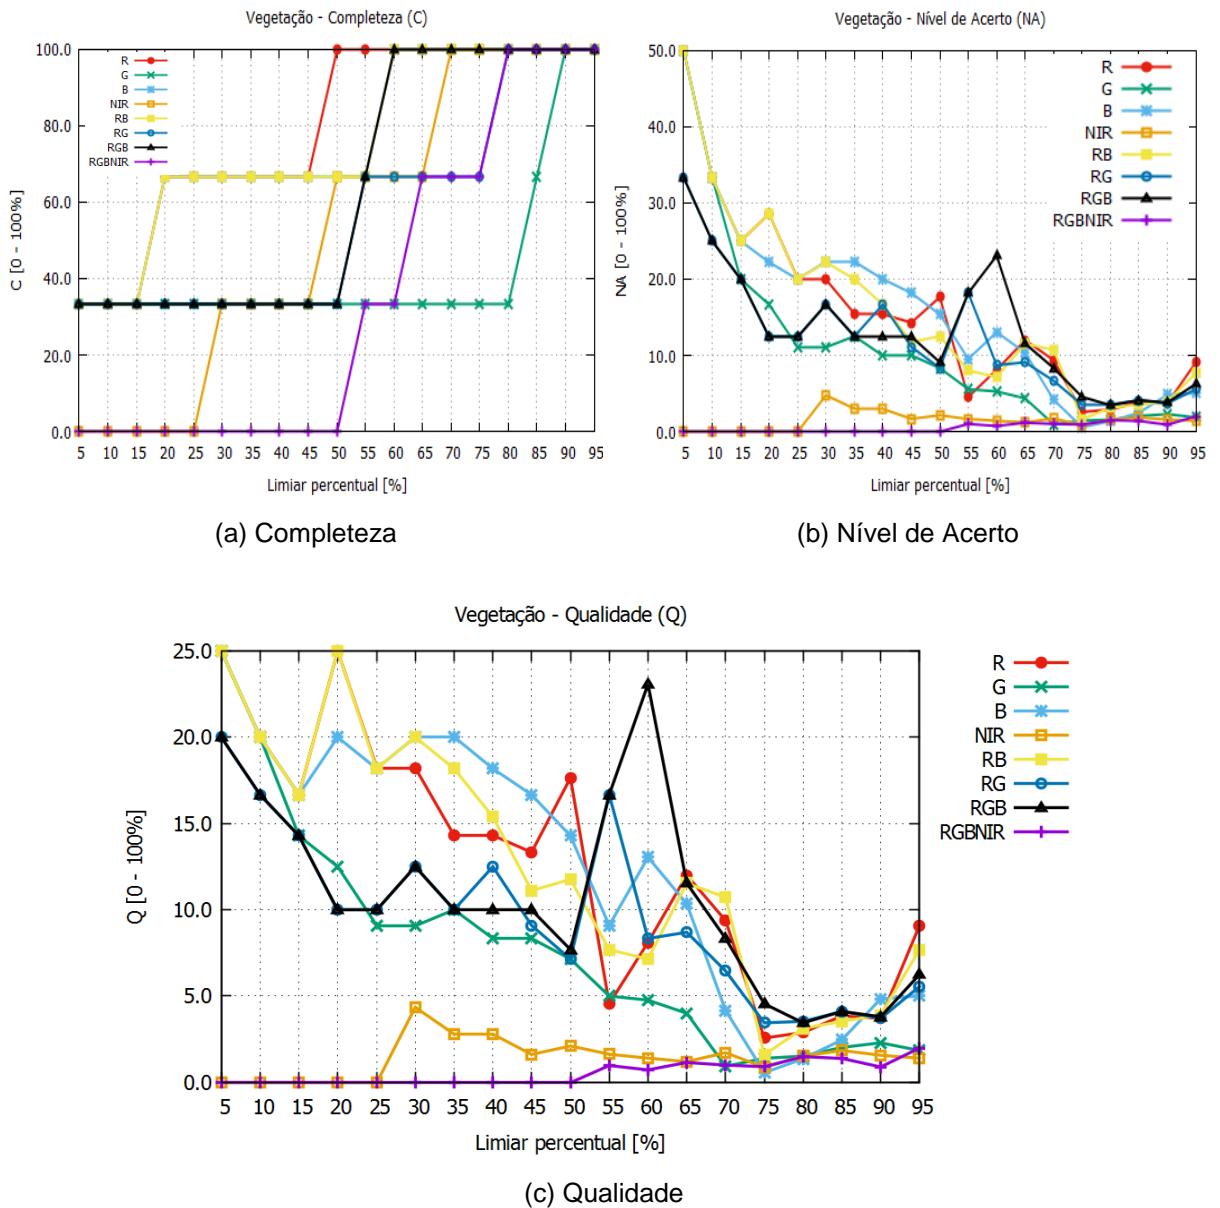
Portanto, com base nos resultados finais para a classe solo exposto, conclui-se que para a detecção de alteração de forma automática, para alterações em supressão de vegetação ou simplesmente o aparecimento de um solo exposto por remoção de algum alvo sobre o mesmo, recomenda-se a utilização da combinação RGB com um limiar de 60%.

V. Área teste 5

Esta última seção apresenta os resultados e parâmetros de qualidade obtidos a partir das composições das melhores bandas empregadas na Seção 4.6.(V), visando a detecção de vegetação para a área 5. As bandas e combinações analisadas são: Vermelho e Azul (RB); Vermelho e Verde (RG); Vermelho, Verde e Azul (RGB) e Vermelho, Verde, Azul e Infravermelho Próximo (RGBNIR). A Figura 70 apresenta os parâmetros de completeza a), nível de acerto (b) e qualidade (c).

Conforme apresentado na Seção 4.6.(V), a banda R foi considerada a melhor banda para detectar alterações concernentes à classe vegetação, pois possibilita a diferenciação entre o solo e a vegetação. Deste modo, com base na Figura 70.a, nota-se que a completeza da banda R atingiu o valor máximo para o limiar de 50%, enquanto as outras combinações e bandas, apresentaram a mesma completeza com limiar superior à 60%.

Figura 70. Parâmetros de qualidade empregando a combinação de bandas para área 5.



Portanto, considerando o parâmetro de completeza (Figura 70.a), em uma escala de [0;1], sendo que 1 representa a melhor banda associada, tem-se os seguintes valores, 1; 0,95; 0,95; 0,78; 0,68; 0,64; 0,58 e 0,52, para as bandas e composições, R, B, RB, RGB, RG, NIR, G e RGBNIR, respectivamente.

No que concerne ao nível de acerto (Figura 70.b), verifica-se que novamente a banda R manteve-se em destaque, seguidas das composições e bandas, RB, B, RGB, RG, G, NIR e RGBNIR. Deste modo, considerando uma escala no intervalo [0;1], obteve-se, na ordem de maior nível de acerto para detecção de alteração na vegetação os valores 1; 0,92; 0,91; 0,78; 0,76; 0,47; 0,30 e 0,28,

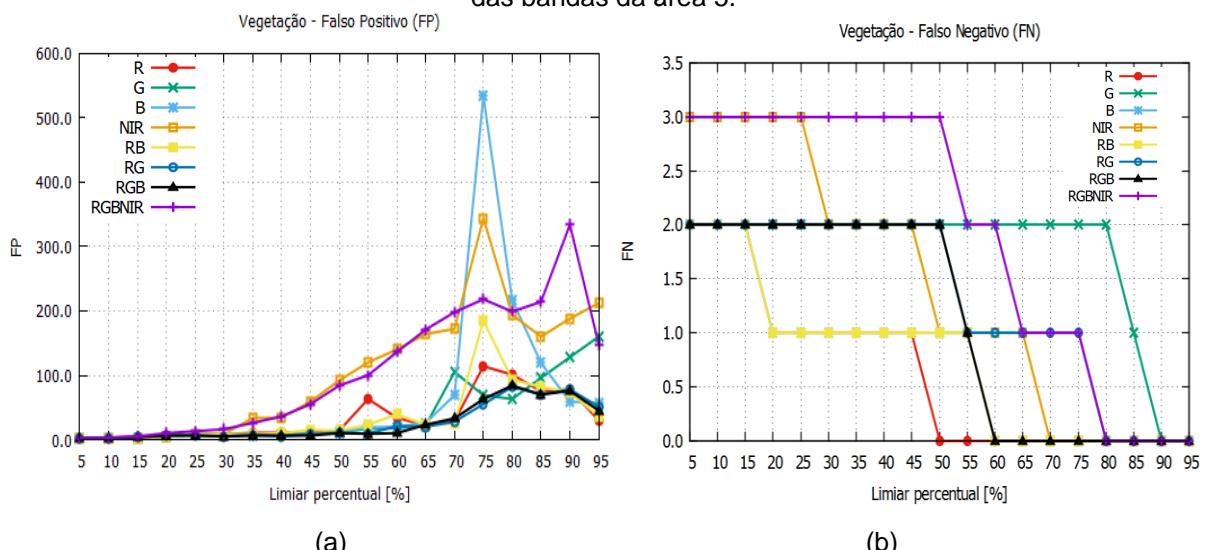
respectivamente. Além disso, observa-se que as bandas e composições do experimento atingiram o nível de acerto de 50% apenas uma única vez. Pode-se perceber também que as respostas para algumas bandas são similares.

De modo geral, analisando a Figura 70.c, nota-se que as bandas e composições de maior eficiência na detecção de vegetação foram B, R, RB, RGB, RG, G, NIR e RGBNIR, apresentando os respectivos valores de peso 1; 0,99; 0,94; 0,77; 0,70; 0,48; 0,30 e 0,29. Diante do exposto, vale ressaltar que o resultado utilizando as bandas R ou B, é similar. Além disso, verifica-se que as melhores bandas associadas à classe vegetação, possuem melhor desempenho para limiares abaixo de 70%.

A Figura 71 apresenta os falsos positivos (a) e falsos negativos (b) concernentes as detecções de vegetação, resultante da área teste 5. Conforme os resultados da Figura 71.a, nota-se que as composições RG e RGB, seguidas das bandas e composições G, B, RB, R, NIR e RGBNIR são, nesta ordem, as que apresentaram a menor quantidade de falsos positivos, representando em uma escala de 0 a 1, os respectivos valores, 1; 0,99; 0,84; 0,78; 0,77; 0,75; 0,55 e 0,35.

Nota-se, de modo geral, que a quantidade de falsos negativos (Figura 71.b) foi relativamente baixa. Deste modo, considerando a quantidade de falsos negativos, obtém-se as bandas e composições R, B, RB, RGB, RG, NIR, G e RGBNIR, com os respectivos pesos de 1; 0,95; 0,95; 0,78; 0,68; 0,64; 0,58 e 0,52.

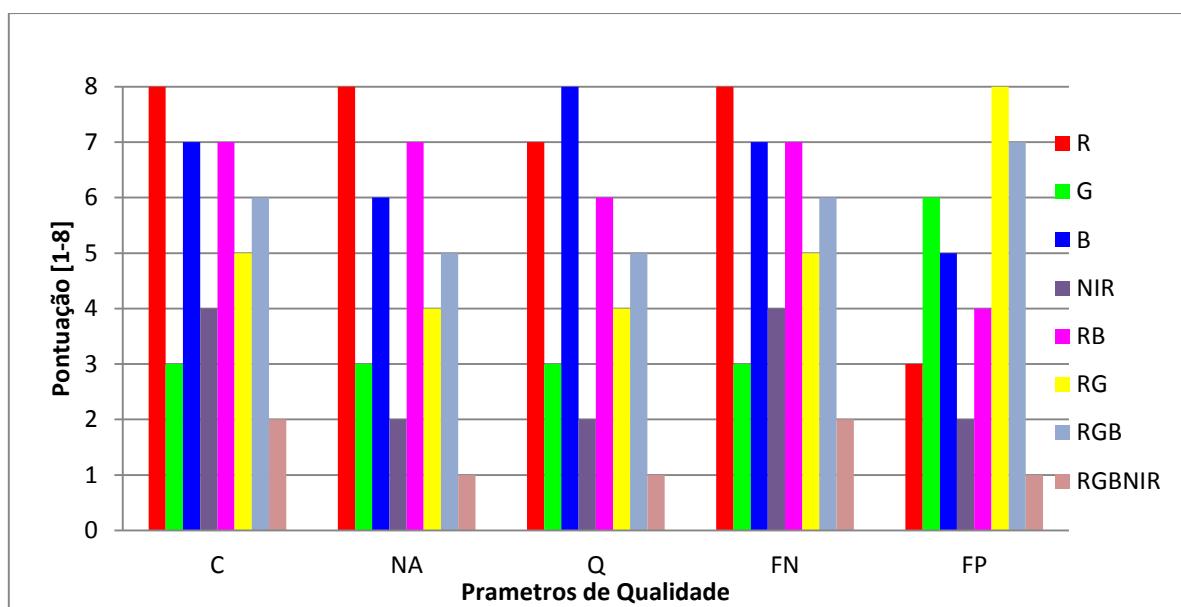
Figura 71. Falso Positivo (a) e Falso Negativo (b) das quatro bandas multiespectrais e da combinação das bandas da área 5.



Em suma, a Figura 72 apresenta o resultado geral referente ao

comportamento do algoritmo para a vegetação. Como pode-se notar, as bandas que apresentaram maior desempenho quanto a detecção de vegetação, foram as bandas R, seguida da banda B e por fim das composições e bandas, RB, RG, RGB, G, NIR e RGNIR, que apresentam as seguintes contribuições relativas: 1; 0,70; 0,55; 0,52; 0,45; 0,27; 0,23 e 0,18. Vale ressaltar, que o emprego da banda R permite a identificação de áreas agrícolas, e a banda B, sofre absorção pela clorofila e outros pigmentos fotossintéticos.

Figura 72. Análise das quatro bandas multiespectrais e da combinação de bandas da área 5, para os cinco parâmetros de qualidade.



Portanto, com base nos resultados finais para a classe de vegetação, conclui-se que para a detecção de alteração de forma automática desta classe, recomenda-se a utilização da banda R com um limiar de 50%.

4.7.1 Análise quantitativa dos resultados

Após uma análise dos resultados obtidos para as diferentes classes, conforme descrito nas seções anteriores, apresenta-se no Quadro 7 um resumo das sugestões em termos de banda, ou combinação de bandas, juntamente com o melhor limiar (ou intervalo), que permitiram obter os melhores índices de qualidade. Deste modo, estes valores podem ser utilizados na detecção de mudanças de forma

automática, para cada uma das classes de intervenções consideradas.

Quadro 7. Resumo das escolhas das melhores bandas, ou combinações de bandas, juntamente com o limiar escolhido.

Classe	Banda ou Combinação de Banda	Limiar (%)
Construção	R	40
Corpo D'Água	NIR	80
Sombras	RB ou R	15 a 60
Solo	RGB	60
Vegetação	R	50

Após análise dos resultados do Quadro 7, percebe-se que de um modo geral o uso da banda R, do sensor SPOT-6, resultou em um bom desempenho na maioria das classes. Porém, como não houve unanimidade em relação a uma banda, ou combinações de bandas para todas as classes, sugere-se que a detecção de mudanças de forma automática seja realizada por classes de interesse. Ou seja, antes de realizar a detecção de mudanças o usuário deverá escolher qual classe ele pretende detectar e assim o algoritmo irá utilizar a informação do Quadro 7, para realizar tais detecções.

Por fim, depois de todos os testes realizados, as Figuras 73 e 74 mostram a comparação entre a detecção de mudanças utilizando todas as bandas multiespectrais, como descrito da Seção 4.1, para a classe construção, e a detecção de mudanças utilizando apenas a banda R do sensor SPOT-6, que é a indicada, conforme Quadro 7.

Figura 73. Comparação dos parâmetros de qualidade entre o resultado final utilizando todas as bandas RGBNIR e somente a banda R, como sugerido no Quadro 7.

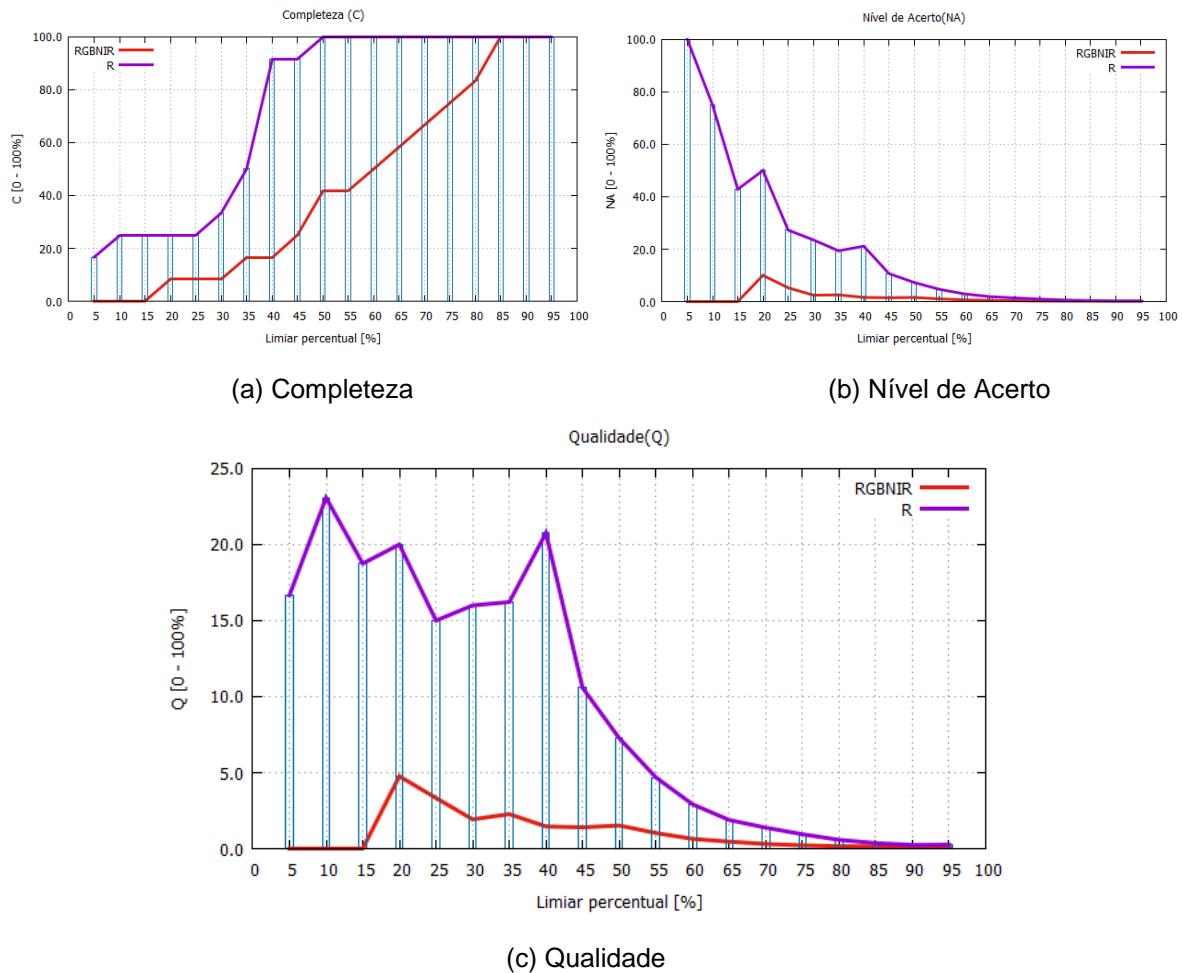
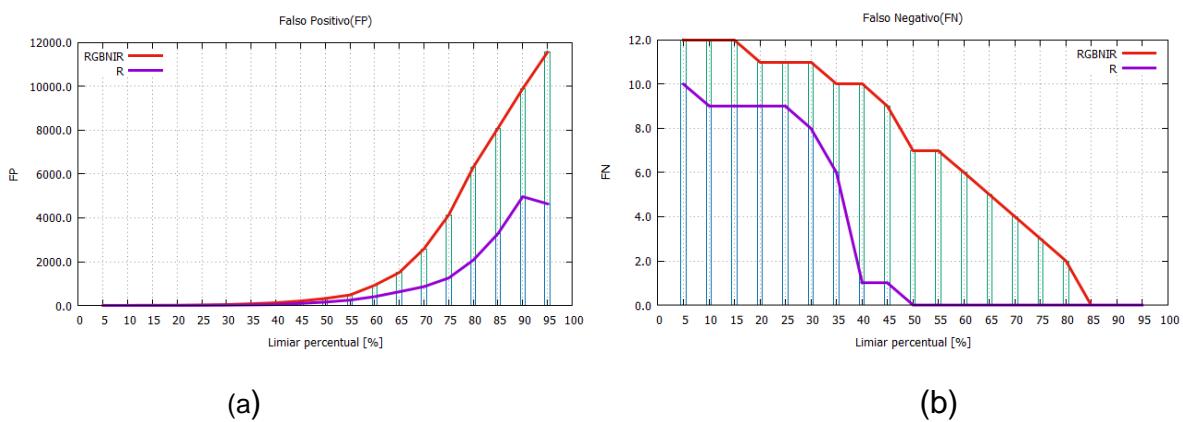


Figura 74. Número de Valores de Falsos Positivos (a) e Falsos Negativos (b) para as bandas RGBNIR e somente a melhor banda R.



Percebe-se de modo claro nos gráficos das Figuras 73 e 74, a melhora na

detecção de mudanças quando utiliza-se da melhor banda estudada em relação a utilização de todas as bandas, como realizado em alguns trabalhos. A completeza, conforme Figura 73.a, atingiu o valor máximo para um limiar de 50% ao utilizar apenas a banda R, porém unindo as demais bandas para a detecção final, nota-se que a completeza atinge seu valor máximo apenas com um limiar de 85%. Assim como a completeza, o nível de acerto (Figura 73.b) e consequentemente a qualidade (Figura 73.c), também indicam melhores resultados ao considerar a banda sugerida, ao invés da combinação de todas as bandas. O mesmo é válido para a quantidade de falsos positivos e falsos negativos (Figura 74), onde se percebe a redução de seus valores ao considerar a banda sugerida, tornando o método mais eficaz.

5 CONCLUSÕES E RECOMENDAÇÕES

A detecção de mudanças a partir de dados de sensoriamento remoto, segundo Tewkesbury et. al. (2015), é um assunto amplo e, embora as técnicas desenvolvidas com este propósito tenham evoluído significativamente nos últimos 30 anos, mais investigações ainda são necessárias para resolver os problemas que persistem, ainda mais quando trata-se de uma detecção de mudanças de forma automática.

A partir desta constatação percebe-se que a automação da detecção de mudanças a partir de imagens de sensoriamento não é trivial. Dentro deste contexto e visando fazer a detecção automática de alterações no entorno de reservatórios foi feita a proposição de um método, denominado RCEN modificado. Este método é baseado no método RCEN proposto por Maldonado et. al. (2007), onde algumas diferenças podem ser observadas: a determinação da direção do eixo de não mudança no método proposto é feita com base nos valores dos ND's tanto dos pixels que sofreram mudança quanto dos que não sofreram mudança; e na métrica utilizada no RCEN modificado, que se baseia na dimensão do vetor determinado pelas projeções de um determinado pixel, sobre a linha de não mudança estimada. Neste método, as imagens intermediárias obtidas para cada banda multiespectral geram informações que combinadas permitem a identificação de mudanças ao longo do tempo. A imagem de detecção final é criada a partir da combinação das imagens intermediárias produzidas por uma ou mais bandas espectrais, de cada uma das datas analisadas.

A partir dos resultados obtidos, utilizando imagens do sensor SPOT 6 do reservatório Canoas I, gerenciado pela empresa Duke Energy pode-se considerar que o algoritmo é indicado para análises de detecção de cenas com períodos sazonais distintos, onde somente algumas áreas tenham sido alteradas, pois o mesmo não realçou pequenas mudanças sazonais da cobertura vegetal, mostrando a robustez do método proposto.

Inicialmente foram realizados experimentos com o uso simultâneo de todas as bandas disponíveis do sensor SPOT 6, podendo-se perceber alguns problemas, o que induziu a incorporar ao processo a redução da área de trabalho.

Deste modo, foram aplicadas máscaras a fim de limitar o processamento para as áreas de interesse, visando minimizar o número de falsos positivos. Além disso foi feita a análise da influência das bandas, em separado e combinadas, sendo feita a análise com base em indicadores de qualidade como completeza, nível de acerto e qualidade, além do número de falsos positivos e negativos. A partir das análises realizadas, para áreas distintas, com a predominância de construção, corpo d'água, sombra, solo exposto e vegetação, foi possível definir as bandas e respectivos limiares, correspondentes aos melhores resultados, permitindo a automação do processo de detecção automática de mudanças.

Com base nos experimentos realizados utilizando dados do reservatório Canoas I relativos a análise dos efeitos das bandas e combinações das bandas, recomenda-se realizar a detecção de mudanças por classes de objetos, sendo utilizadas bandas específicas e limiares específicos para cada uma delas. Estas bandas e limiares foram escolhidos de modo que seja reduzido o número de falsos positivos e falsos negativos, bem como o aumento dos indicadores de completeza e nível de acerto (ou correta) e, consequentemente, da qualidade.

Entretanto, caso o usuário queira realizar a detecção de mudanças de modo simultâneo para todas as classes, o recomendado é a detecção de mudanças em duas etapas. Na primeira etapa sugere-se realizar uma detecção utilizando uma máscara para o corpo d'água, provindo do mapa do uso do solo, assim como foi feito para as áreas agrícolas (descrito na Seção 4.4), ou seja, realizar a detecção somente entre o corpo d'água e o limite da área de interesse. Na segunda etapa deve-se realizar a detecção de mudanças somente dentro do corpo d'água. Esta sugestão é válida pelo fato de que a melhor banda para detecção de alterações no corpo d'água é a banda do NIR, porém esta é a pior banda para as demais classes, sendo assim a realização da detecção de mudanças em duas etapas será a melhor combinação. Deste modo, para as classes construção, sombras, solo e vegetação recomenda-se a utilização da banda R com um limiar de 60%, garantindo assim uma boa detecção em tais classes e para a detecção sob o corpo d'água, remenda-se a utilização da banda NIR com um limiar de 80%.

É relevante destacar que os limiares apresentados foram obtidos ao usar dados do sensor SPOT 6 para o reservatório Canoas I, sendo recomendado testes com dados de outros reservatórios. Como recomendações adicionais, sugere-se um

aprimoramento do algoritmo, visando a minimização de detecção em sombras, de modo a tornar o algoritmo mais robusto. Uma alternativa seria a aplicação de uma análise de contexto espacial, em ambas as imagens nas duas épocas, visando realizar o mapeamento de sombras e excluir esta regiões do processamento. Além disso, é interessante que análises similares sejam realizadas com imagens de outros sensores, visando refinar os limiares e as respectivas combinações de bandas que resultem nos melhores resultados.

Outro fator a ser explorado se refere ao cálculo dos limiares, pois notou-se que o método é mais sensível na detecção de objetos que foram removidos de uma data para outra, como no caso de sombras, em sua maioria. Assim, uma possibilidade é utilizar pesos para os cálculos dos limiares, atribuindo-se um peso menor para áreas onde objetos e/ou feições foram removidos e consequentemente um peso maior para regiões onde novos objetos e/ou feições surgiram de uma época para outra.

REFERÊNCIAS BIBLIOGRÁFICAS

ARAGÃO, R.; ALMEIDA, J. A. P. Avaliação espaço temporal do uso do solo na área da bacia do rio Japaratuba – Sergipe, através de imagens landsat. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 14. (SBSR), 2009, Natal. Anais... São José dos Campos: INPE, 2009. p. 1231-1238. DVD, On-line. ISBN 978-85-17-00044-7. Disponível em:
<<http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.17.21.53.31/doc/1231-1238.pdf>>. Acesso em: 18 Fev. 2014.

ARASATO, L. S.; SANTOS, J. R.; MALDONADO, F. D.; AMARAL, S.; RENNÓ, C. D. Detecção de mudança da paisagem a partir de análise multissensor e multitemporal em associação com variáveis geomorfométricas no domínio da floresta atlântica. **Revista Brasileira de Cartografia**, v. 64, n. 4, p. 475-486, 2012.

ARASTOO, B.; GHAZARYAN, S. Land cover Changes Detection in Semnan province by Remote Sensing Techniques. **International Journal of Agronomy and Plant Production**, 4: 7, 1637-1644. 2013.

BESSA, J. C. M. de. **Utilização de imagens de sensoriamento remoto de alta e média resoluções espaciais na geração de informação sobre ocupações urbanas como subsídio ao planejamento**. Monografia (Especialista em Sensoriamento Remoto e Sistemas de Informação Geográfica), INPE, São José dos Campos/SP, 2005.

CHAVEZ JR., P. S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, 24:459-479. 1988.

COPPIN, P. R.; BAUER, M. E. Digital change detection in forest ecosystems with remote sensing imagery. **Remote Sensing Reviews**, 13, 207–234.1996.

COPPIN, P.; JONCKHEERE, I.; NACKAERTS, K.; MUYS, B.; LAMBIN, E. Review article digital change detection methods in ecosystem monitoring: A review. **International Journal of Remote Sensing**, 25(9), 1565-1596. (2004)

DIAS, T. C.; SHIMABUKURO, M. H.; PINTO, M. S; IMAI, N. N.; HASEGAWA, J. K.. Concepção de um sistema para organização e processamento de imagens multiespectrais, multitemporais e georeferenciadas de reservatórios para monitoramento de bordas. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 17. (SBSR), 2015, João Pessoa. Anais... São José dos Campos: INPE, 2015. Artigos, p. 2149-2156. Disponível em: < <http://www.dsr.inpe.br/sbsr2015/files/p0433.pdf>>. Acesso em: 01 Jul. 2015.

DEER, P. J. Digital change detection techniques: civilian and military applications. **International Symposium on Spectral Sensing Research**, 1995. Report

(Greenbelt, MD: Goddard Space Flight Center), <http://ltpwww.gsfc.nasa.gov/ISSR-95/digitalc.htm>.

FONSECA, L. M. G.; MANJUNATH, B. S. Registration techniques for multisensor remotely sensed imagery. **Photogrammetric Engineering & Remote Sensing**, Vol. 62, No. 9, September, pp. 1049-1056, 1996.

GALO, M. **Automação dos processos de correspondência e orientação relativa em visão estéreo**. Tese (Doutorado em Engenharia Elétrica) – FEEC – Universidade Estadual de Campinas, Campinas, 2003.

GREEN, K.; KEMPKA, D.; LACKEY, L. Using remote sensing to detect and monitor land-cover and land-use change. **Photogrammetric Engineering and RemoteSensing**, 60, 331–337. 1994.

HENEBRY, G. M. Detecting change in grasslands using measures of spatial dependence with Landsat TM data. **Remote Sensing of Environment**. 46, 223–234. 1993.

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

HUSSIN, Y. A.; DE GIER, A.; HARGYONO. Forest cover change detection analysis using remote sensing: a test for the spatially resolved area production model. **Fifth European Conference and Exhibition on Geographic Information Systems, EGIS'94 Proceedings**. Paris, France, 29 March 29–1 April 1994 (Utrecht: EGIS Foundation), vol. II, pp. 1825–1834. 1994.

IMAI, N. N.; CALDEIRA, C. R. T.; GALO, M. de L. B. T.; GALO, M.; HASEGAWA, J. K.; AMORIM, A.; PINTO, M. S. Detecção de alterações em Áreas de Preservação Permanentes de reservatórios de UHE: primeiros experimentos na automatização do processo. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 17. (SBSR), 2015, João Pessoa. Anais... São José dos Campos: INPE, 2015. Artigos, p. 2149-2156. Disponível em: < <http://www.dsr.inpe.br/sbsr2015/files/p0433.pdf>>. Acesso em: 01 Jul. 2015.

JENSEN, J. R.; COWEN, D.; NARUMALANI, S.; HALLS; J. Principles of change detection using digital remote sensor data. In: **Integration of Geographic Information Systems and Remote Sensing**, edited by J. L. Star, J. E. Estes, and K. C. McGwire (Cambridge: Cambridge University Press), pp. 37–54. 1997.

LAMBIN, E. F.; STRAHLER, A. H. Indicators of land-cover change for change- vector analysis in multitemporal space at coarse spatial scales. **International Journal of Remote Sensing**. 15, 2099–2119. 1994.

LIU, W. T. H. **Aplicações de sensoriamento remoto**. Editora UNIDERP, Campo Grande: UNIDERP, 2007.

LU, D.; MAUSEL, P.; BRONDIZIO, E.; MORAN, E. F. Change Detection Techniques. *International Journal of Remote Sensing*. 25 (12):2365-2407. 2004

LU, D.; MAUSEL, P.; BRONDIZIO, E.; MORAN, E. F. Land-cover binary change detection methods for use in the moist tropical region of the Amazon: A comparative study. *International Journal of Remote Sensing*. 26:101. 2005.

MAIA, J. L. **Metodologia para avaliação de rodovias extraídas computacionalmente em imagens digitais**. 2003. 116 f. Dissertação (Mestrado em Ciências Cartográficas) - FCT/Universidade Estadual Paulista, Presidente Prudente, 2003.

MACHADO, H. M.; LAMPARELLI, R. A. C; ROCHA, J. V.; ZULLO JÚNIOR, J. Estudo da variação de parâmetros atmosféricos necessários para correção atmosférica de imagens de satélite. In: **Simpósio Brasileiro Sensoriamento Remoto**, 11, 2003, Belo Horizonte. Anais XI SBSR, Belo Horizonte: INPE. p. 2537 – 2539, 2003.

MALDONADO, F. D.; SANTOS, J. R.; GRAÇA, P. M. L. Change detection technique based on the radiometric rotation controlled by no-change axis, applied on a semi-arid landscape. *International Journal of Remote Sensing*, v .28, n.8, p.1001-1016, 2007.

MENESES, P. R.; ALMEIDA, T. **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: UNB, 2012, p. 90-93.

MOUAT, D. A.; MAHIN, G. C.; LANCASTER, J. Remote sensing techniques in the analysis of change detection. *Geocarto International*, 2, 39–50. 1993.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. São Paulo: Edgard Blucher, 308p, 1992.

PETIT, C. C.; LAMBIN, E. F. Integration of multi-source remote sensing data for land cover change detection. *International Journal of Geographical Information Science*, 15, 785–803. 2001.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação**. São José dos Campos: Parêntese, 2007.

RADKE, R. J.; ANDRA, S.; AL-KOFAHI, O., ROYSAM, B. Image change detection algorithms: A systematic survey. *IEEE Transactions on Image Processing*, 14(3), 294-307.

RIDD, M. K.; LIU, J. A comparison of four algorithms for change detection in an urban environment. *Remote Sensing of Environment*, 63, 95–100. 1998.

RODRIGUES, S. W. P.; RAMOS, E. M. L. S. Detecção de Mudança do Litoral da Ilha de Cotijuba, Pará, Brasil. In: **Anais do XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, Foz do Iguaçu – PR. 2013.

ROUSE, J. W.; HAAS, R. H.; SCHEL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. In **Earth Resources Technology Satellite- 1 Symposium**, 3, 1973. Proceedings. Washington, 1973, v.1, Sec. A, p. 309-317.

SAUSEN, T. M. **Sensoriamento Remoto e suas aplicações para recursos naturais. Projeto Educa SeRe III – Carta Imagem CBERS**, INPE – Instituto Nacional de Pesquisas Espaciais, 2010. Disponível em <https://educacaoespacial.files.wordpress.com/2010/10/iespacial_14_sensoriamento_remoto.pdf>. Acesso em: Jul. 2015.

SERPICO, S. B.; BRUZZONE, L. Change detection. In: **Information Processing for Remote Sensing**, Edited by C. H. Chen (Singapore: World Scientific Publishing), pp. 319–336. 1999.

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

SILVA, R. R. da. **Aplicação de imagens orbitais de alta resolução espacial no cadastro técnico rural multifinalitário**. Dissertação (Mestrado em Sensoriamento Remoto), Universidade Federal do Rio Grande do Sul, Porto Alegre/RS, 2007.

SOARES, A. R. **Avaliação da correção atmosférica em imagens orbitais utilizando dados de modelo de PNT**. Dissertação (Mestrado em Ciências Geodésicas e Tecnologias da Geoinformação), Universidade Federal de Pernambuco, Recife/PE, 2014.

SONG, C.; WOODCOCK, C. E.; SETO, K. C.; LENNEY, M. P.; MACOMBER, S. A. Classification and change detection using Landsat TM data: when and how to correct atmospheric effects?, **Remote Sens. Environ.** 75, 230–244, 2001.

TEWKESBURY, A. P.; COMBER, A. J.; TATE, N. J.; LAMB, A.; FISHER, P. F. A critical synthesis of remotely sensed optical image change detection techniques. **Remote Sensing of Environment**, 160, 1–14. 2015. <http://dx.doi.org/10.1016/j.rse.2015.01.006>.

VERSTRAETE, M. The contribution of remote sensing to monitor vegetation and to evaluate its dynamic aspects. In **Vegetation, Modeling and Climatic Change Effects**, (F. Veroustraete, R. Ceulemans, et al., Eds.), SPB Academic Publishing, The Hague, The Netherlands. Pp. 207-212.

ZULLO JUNIOR, J.; BEZERRA, P. C. . Correção Atmosférica de Imagens de Satélite Utilizando o 5S. In: **VII Simpósio Brasileiro de Sensoriamento Remoto**, 1993, Curitiba. Anais, 1993. p. 1.

WANG, F. A knowledge-based vision system for detecting land change at urban fringes. **IEEE Transactions on Geoscience and Remote Sensing**. 31, 136–145. 1993.

WARNER, T.; ALMUTAIRI, A.; LEE, J. Y. **Remote sensing of land cover change.** In T.A. WARNER, D. M. NELLIS, G. M. FOODY (Eds.), the SAGE handbook of remote sensing (pp. 459-472). SAGE Publications.

WIEDEMANN, C.; HEIPKE, C.; MAYER, H.; JAMET, O. Empirical Evaluation of Automatically Extracted Road Axes. In. Bowyer, K. J; Phillips, P. J. (Eds.) Empirical evaluation techniques in computer vision. Los Alamitos, **IEEE Computer Society Press**. p. 172-187. 1988.

WIEDEMANN, C.; HINZ, S. Automatic extraction and evaluation of road networks from satellite imagery. In: **International Archives for Photogrammetry and Remote Sensing**, vol. 32, CD-ROM, 1999.

BIBLIOGRAFIA CONSULTADA

CASTELLI, V.; ELVIDGE, C. D.; LI, C. S.; TUREK, J. J. Classification based change detection: theory and applications to the NALC data sets. In **Remote Sensing Change Detection: Environmental Monitoring Methods and Applications**, edited by R. S. Lunetta and C. D. Elvidge (Chelsea, MI: Ann Arbor Press), pp. 53–73. 1998.

COLLINS, J. B.; and WOODCOCK, C. E. Change detection using the Gramm–Schmidt transformation applied to mapping forest mortality. **Remote Sensing of Environment**, 50, 267–279. 1994.

CROSTA, A. P. **Processamento Digital de Imagens de Sensoriamento Remoto.** Ed. Rev. – Campinas, SP: IG/UNICAMP, 1993.

EL HAJJ, M.; BÉGUÉ, A.; LAFRANCE, B.; HAGOLLE, O.; DEDIEU, G.; RUMEAU, M. **Relative Radiometric Normalization and Atmospheric Correction of a SPOT 5 Time Series**, Sensors, n.8, pp. 2774-2791, 2008.

EHLERS, M.; SOFINA, N.; FILIPPOVSKA, Y.; KADA, M. Automated techniques for change detection using combined edge segment texture analysis, GIS, and 3D information. In **Q. WENG (Ed.), Global urban monitoring and assessment through Earth observation** (pp. 325-351). CRC Press, Taylor & Francis Group.

GONZALES, R. C.; WOODS, R. E. **Digital image processing**, Addison-Wesley Publishing Company, Inc., Reading, 716p. 1993.

GOPAL, S.; WOODCOCK, C. E. Artificial neural networks for detecting forest change. In **Information Processing for Remote Sensing**, edited by C. H. Chen (Singapore: World Scientific Publishing Co.), pp. 225–236. 1999.

HAJJM. el; BÉGUÉ, A.; LAFRANCE, B.; HAGOLLE, O.; DEDIEU, G.; RUMEAU, M. **Relative Radiometric Normalization and Atmospheric Correction of a SPOT 5 Time Series**, Sensors, n.8, pp. 2774-2791, 2008.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres (Tradução da Segunda Edição)**. São José dos Campos, Parêntese Editora, 598 p. 2011.

LATORRE, M.; CARVALHO JÚNIOR, O. A.; CARVALHO, A. P. F.; SHIMABUKURO, Y. E. **Correção Atmosférica: Conceitos e Fundamentos**. Espaço&Geografia, v.5, n.1, pp. 153-178, 2002.

LU, D. S. **Estimation of forest stand parameters and application in classification and change detection of forest cover types in the Brazilian Amazônia basin**. PhD dissertation, Indiana State University, Terre Haute, IN, USA. 2001.

LU, D. S.; MAUSEL, P.; BRONDÍZIO, E. S.; MORAN, E. Change detection of successional and mature forests based on forest stand characteristics using multitemporal TM data in the Altamira, Brazil. **XXII FIG International Congress, ACSM-ASPRS Annual Conference Proceedings**, Washington, DC, USA, 19–26 April (Bethesda, MD: American Society of Photogrammetry and Remote Sensing) (CD-ROM). 2002.

LYON, J. G.; YUAN, D.; LUNETTA, R. S.; ELVIDGE, C. D. A change detection experiment using vegetation indices. **Photogrammetric Engineering and Remote Sensing**, 64, 143–150. 1998.

MACLEOD, R. D.; CONGALTON, R. G. A quantitative comparison of change-detection algorithms for monitoring eelgrass from remotely sensed data. **Photogrammetric Engineering and Remote Sensing**, 64, 207–216. 1998.

NOVO, E. M. L. M. **Sensoriamento Remoto: Princípios e Aplicações**. 4^a Ed. São Paulo: Blucher, 2010. 387 p.

POLIDORIO, A. M.; IMAI, N. N.; TOMMASELLI, A. M. G. Índice indicador de corpos d'água para imagens multiespectrais. In: **I Simpósio de Ciências Geodésicas e Tecnologias da Geoinformação**. 9, 2004a. Recife. Disponível em CD-ROM não paginado.

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

ROSENDÔ, J. dos S. **Índices de Vegetação e Monitoramento do uso do solo e cobertura vegetal na Bacia do rio Araguari - MG - utilizando dados do sensor Modis**. 2005. 130 p. Dissertação (Mestrado em Geografia e Gestão do Território) - Programa de Pós-Graduação em Geografia, Universidade Federal de Uberlândia, Uberlândia. 2005.

SALLES R. N.; MURA J. C.; FONSECA L. M. G. Registro Automático de Imagens SAR Interferométricas. **Revista Brasileira de Cartografia**, v.4, n. 64, p. 451-463, Out. 2012.

WONG, A.; CLAUSI, D.A. ARRSI: Automatic registration of remote sensing images.
IEEE Transactions on Geoscience and Remote Sensing, Vol. 45, No. 5, Part II,
pp. 1483-1493. 2007.