

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AMBIENTAL
CÂMPUS APUCARANA/LONDRINA**

ANDERSON PAULO RUDKE

**DINÂMICA DA COBERTURA DO SOLO PARA A BACIA HIDROGRÁFICA DO
ALTO RIO PARANÁ**

DISSERTAÇÃO

**LONDRINA
2018**

ANDERSON PAULO RUDKE

**DINÂMICA DA COBERTURA DO SOLO PARA A BACIA HIDROGRÁFICA DO
ALTO RIO PARANÁ**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Ambiental, da Universidade Tecnológica Federal do Paraná, Campus Apucarana/Londrina, como requisito parcial para obtenção do título de Mestre em Engenharia Ambiental.

Orientador: Prof. Dr. Jorge Alberto Martins

LONDRINA
2018

TERMO DE LICENCIAMENTO

Esta Dissertação está licenciada sob uma Licença Creative Commons *atribuição uso não-comercial/compartilhamento sob a mesma licença 4.0 Brasil*. Para ver uma cópia desta licença, visite o endereço <http://creativecommons.org/licenses/by-nc-sa/4.0/> ou envie uma carta para Creative Commons, 171 Second Street, Suite 300, San Francisco, Califórnia 94105, USA.



Dados Internacionais de Catalogação na Publicação (CIP)
Biblioteca UTFPR - Câmpus Londrina

R916d Rudke, Anderson Paulo
Dinâmica da cobertura do solo para a bacia hidrográfica do Alto Rio
Paraná / Anderson Paulo Rudke. – Londrina: [s.n.], 2018.
111 f. : il.; 30 cm.

Orientador: Prof. Dr. Jorge Alberto Martins
Dissertação (Mestrado) - Universidade Tecnológica Federal do Paraná.
Programa de Pós-Graduação em Engenharia Ambiental. Londrina, 2018.
Bibliografia: f. 85-99

1. Sensoriamento Remoto. 2. Bacias Hidrográficas. 3. Paraná, Rio. I.
Martins, Jorge Alberto, orient. II. Universidade Tecnológica Federal do
Paraná. III. Programa de Pós-Graduação em Engenharia Ambiental. IV.
Título.

CDD: 628



Ministério da Educação
Universidade Tecnológica Federal do Paraná
Pró-reitora de Pesquisa e Pós Graduação
Programa de Pós-Graduação em Engenharia Ambiental
Campus Apucarana/Londrina



TERMO DE APROVAÇÃO

DINÂMICA DA COBERTURA DO SOLO PARA A BACIA HIDROGRÁFICA DO ALTO RIO PARANÁ

por

Anderson Paulo Rudke

Dissertação de mestrado apresentada no dia trinta de maio de dois mil e dezoito como requisito parcial para a obtenção do título de MESTRE EM ENGENHARIA AMBIENTAL pelo Programa de Pós-Graduação em Engenharia Ambiental, Câmpus Apucarana/Londrina, Universidade Tecnológica Federal do Paraná. O Candidato foi arguido pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho APROVADO.

Prof. Dr Jorge Alberto Martins
(UTFPR)

Prof.^a Dr.^a Cintia Regina Bertacchi Uvo
(Lund University)

Prof.^a Dr.^a Leila Droprinchinski Martins
(UTFPR)

Prof.^a Dr.^a Alessandra Furtado da Silva
Coordenadora do Programa de Pós-Graduação em Engenharia Ambiental

AGRADECIMENTOS

Agradeço primeiramente a Deus cuja presença se demonstra constante em minha vida.

Sou grato, sobretudo, a minha família que sempre me motivou a adquirir conhecimentos e cuja felicidade, tristeza e em especial o amor foram compartilhados. Em particular aos meus pais, Lauri e Divanir, que não mediram esforços para garantir uma boa educação a mim e a meus irmãos, aos quais constantemente me espelho, devido a sua dedicação e compromisso.

Ao meu orientador Jorge Alberto Martins agradeço pela oportunidade de participar do Laboratório de Eventos Atmosféricos Extremos, por todo conhecimento adquirido, pela paciência e de forma geral pela confiança em mim despendida.

À professora Leila D. Martins, por corroborar com o meu aprendizado e pelas oportunidades concedidas ao longo do mestrado.

Aos professores da banca examinadora, pela contribuição dedicada a este estudo.

Ao Ronaldo Alves, por todo apoio, compreensão e carinho durante a realização deste trabalho.

Ao professor Alex Mota dos Santos, por instigar minha paixão pela pesquisa e pela amizade que se mantém ao longo dos anos.

À todos os pesquisadores e amigos dos Laboratórios EAE e LAPAR, pelo auxílio no desenvolvimento desta pesquisa.

À todas as pessoas que de alguma forma me acolheram em Londrina, em particular aos meus incontestáveis amigos, Daniela Sanches, Rudnei Cruz, Ana Carolina Xavier, Beatriz Kawashima, Rafaela Alves, Marília Moreira, Thais Fujita, Eduardo Duarte, Gabriela Tsay, Elias Rodrigues e Vitor Oliveira, que tornaram minha jornada em Londrina inesquecível.

Aos meus amigos de longa data que se mostraram sempre presentes em minha vida, em especial a Alan Pestana, Witan da Silva, Ediharly, Lore, Vinicius Souza e Shadai Mendes.

À Comissão de Aperfeiçoamento de Pessoal do Nível Superior (CAPES) e à Agência Nacional de Águas (ANA) pelo apoio financeiro que proporcionou o desenvolvimento desta pesquisa, à toda equipe do projeto “Detecção do papel das mudanças climáticas e das condições de uso e ocupação do solo sobre a hidrologia da Bacia do Rio Paraná” nº 23038.003963/2016-17, ao Programa de Pós-Graduação em Engenharia Ambiental, à Universidade Tecnológica Federal do Paraná, e a todos os parceiros e colegas que auxiliaram no decorrer do projeto.

Por fim, agradeço a todos que de forma direta ou indireta contribuíram para que esse trabalho pudesse ser realizado.

“There are more people who surrender, than those who fail.”

(Henry Ford)

RESUMO

RUDKE, A.P. **Dinâmica da cobertura do solo para a Bacia Hidrográfica do Alto Rio Paraná**. 2018. 107 f. Dissertação (Mestrado). Programa de Pós-Graduação em Engenharia Ambiental (PPGEA) - Universidade Tecnológica Federal do Paraná, Paraná, Câmpus Apucarana/Londrina Londrina, 2018.

Este trabalho teve como principal objetivo desenvolver produtos de cobertura do solo para a Bacia Hidrográfica do Alto Rio Paraná (BHAPR) com o uso de técnicas de sensoriamento remoto, bem como avaliar mudanças nesta entre os anos de 1985 e 2015. Os produtos foram desenvolvidos com a utilização do classificador supervisionado SVM (*support vector machine*) e dados dos sensores Landsat TM (*Thematic Mapper*) e OLI (*Operational Land Imager*). A classificação dos produtos foi realizada com base em mais de 50 cenas para os anos de 1985 e 2015, cobrindo toda a área da BHAPR. Foram coletadas aproximadamente 300 amostras de treinamento em cada cena Landsat, e utilizou-se os métodos baseado a pixel e em objetos para a classificação das cenas. A acurácia dos produtos gerados foi avaliada através de critérios estatísticos adotados na literatura - Precisão Global e Índice Kappa. O produto gerado foi ainda comparado com produtos globais tradicionalmente em uso. Os resultados não demonstraram variação significativa entre as classificações baseada a pixel e em objetos - a classificação baseada em objetos foi mais representativa para o ano de 1985 (Precisão Global de 63%) e a baseada a pixel para o ano de 2015 (Precisão Global de 80%). Observou-se que os menores valores de acurácia estão associados às sub-bacias com maior rugosidade do terreno, bem como maior complexidade espacial da vegetação – mosaicos de cerrado, agricultura e pastagem. A comparação com produtos globais evidenciou concordâncias razoáveis entre o produto desenvolvido para o ano de 2015 e os produtos globais GlobCover-2009 e Globeland30-2010 – concordância em 50% da área. Em contrapartida, a maior discordância foi encontrada para o produto MODIS-2013, que apresenta menor resolução espacial, dentre os produtos avaliados. Especialmente a comparação entre os produtos evidenciou que as sub-bacias de maior concordância foram as sub-bacias com características agrícolas intensas. A mudança mais expressiva na cobertura terrestre entre 1985 e 2015 refere-se ao aumento na classe Agricultura e a diminuição nas áreas da classe Cerrado/Vegetação arbustiva. Cerca de 63% da área original de Cerrado/Vegetação arbustiva passou a ser representada por agropecuária em 2015. Para a classe Cerrado/Vegetação arbustiva as sub-bacias com as reduções mais acentuadas foram aquelas localizadas na margem direita da BHAPR, onde a classe ocupava mais de 50% da área em 1985 e reduziu para valores de alguns poucos percentuais em 2015. De um modo geral os resultados mostram avanço das áreas agrícolas sobre áreas de pastagem e destas sobre o Cerrado. Ficou evidente também que as áreas de floresta sofreram intensa mudança, tanto pela redução de áreas nativas, quanto pelo surgimento de novas áreas de florestamento e reflorestamento.

Palavras-Chave: Cobertura do solo; Sensoriamento remoto; Bacia Hidrográfica do Alto Rio Paraná; Máquina de Vetores Suporte; Satélite Landsat.

ABSTRACT

RUDKE, A.P. **Land cover dynamics for the Upper Paraná River Basin**. 2018. 107 p. Dissertation (Master degree). Environmental Engineering Master Program (PPGEA), campus Apucarana/Londrina, Federal University of Technology - Paraná. Londrina, 2018.

The main objective of this work was to develop land cover products using remote sensing techniques for the Upper Paraná River Basin (UPRB), as well as evaluate changes between the years 1985 and 2015. The products were developed with the SVM (Support Vector Machine) supervised classifier and Landsat TM (Thematic Mapper) and OLI (Operational Land Imager) sensor data. The product classification was based on more than 50 scenes from 1985 and 2015, covering an entire area of the UPRB, and totalizing about 300 training samples for each Landsat scene. Pixel-based and object-based methods were used for the scene classification. The accuracy of the generated products was evaluated through statistical criteria adopted in the literature - Overall Accuracy and Kappa Index. The product was also compared with global products traditionally in use. The results did not show significant variation between the pixel-based and object-based classifications - the object-based classification was more representative for the year 1985 (Overall Accuracy of 63%) and the pixel-based classification for the year 2015 (Overall Accuracy of 80%). It was observed that the lower values of accuracy are associated to the sub-basins with greater roughness of the terrain, as well as greater spatial complexity of the vegetation - mosaics of cerrado, agriculture and pasture. The comparison with global products showed reasonable agreement between the product developed for 2015 and the global products GlobCover-2009 and Globeland30-2010 - agreement in 50% of the area. On the other hand, the greatest disagreement was found for the MODIS-2013 product, which presents lower spatial resolution, among the evaluated products. Spatially the comparison between the products showed that the sub-basins of greater agreement were those with intense agricultural activities. The most significant change in land cover between 1985 and 2015 refers to the increase in the Agriculture class and the decrease in the areas of the Cerrado/Shrub vegetation class. About 63% of the original Cerrado/shrub vegetation area was classified as Agriculture in the year 2015. For the Cerrado/Shrub vegetation class, the sub-basins with the sharpest reductions were those located on the right bank of the BHAPR, where the class occupied more than 50% of the area in 1985 and decreased to values of a few percentages in 2015. Overall, the results show the advance of the agricultural areas on pasture areas and from these on the Cerrado. It was also evident that the forest areas underwent an intense change, due both to the reduction of native areas and to the emergence of new afforestation and reforestation areas.

Keywords: Land cover; Remote Sensing; Upper Paraná River Basin; Support Vector Machine (SVM), Landsat satellite.

LISTA DE FIGURAS

Figura 1 - Características técnicas de dados de sensoriamento remoto.....	19
Figura 2 - Localização da Bacia Hidrográfica do Alto Rio Paraná.	32
Figura 3 - Fluxograma global da metodologia aplicada para classificação do uso e ocupação do solo.	34
Figura 4 – Cenas utilizadas para os mapeamentos de cobertura do solo de 1985 (A) e 2015 (B).....	35
Figura 5 - Perfil espectral para as classes de cobertura do solo avaliadas para a BHAPR, considerando-se o sensor Landsat TM (A) e o sensor Landsat OLI (B).	40
Figura 6 – Metodologia de coleta de amostras de treinamento (A) e validação (B).	41
Figura 7 – Imagem Landsat não segmentada (a) e segmentada (b) através do algoritmo watershed.....	44
Figura 8 – RGB (a), Global Urban Footprint (b), composição dos índices (c) e resultado de aplicação do método (d) para a cidade de Três Lagoas (MS).	45
Figura 9 – Metodologia aplicada à detecção de alterações de uso e ocupação do solo.	53
Figura 10 – Delimitação das sub-bacias da BHAPR consideradas neste estudo.	55
Figura 11 – Classificação da cobertura do solo baseada a pixel e em objetos para 1985.	57
Figura 12 – Classificação da cobertura do solo baseada a pixel e em objetos para 2015.	59
Figura 13 – Área das classes de cobertura do solo para os anos de 1985 e 2015.....	60
Figura 14 – Concordância dos produtos por sub-bacia, considerando-se os intervalos descritos na Tabela 7.....	63
Figura 15 – Produtos de cobertura do solo com legenda generalizada através da Tabela 9. ...	65
Figura 16 - Comparação de áreas entre e produtos de cobertura do solo para a BHARP.....	70
Figura 17 - Concordância espacial entre conjuntos de dados com legenda generalizada.	71
Figura 18 - Concordância espacial entre os conjuntos de dados por sub-bacia.	72
Figura 19 – Distribuição espacial de perdas e ganhos para as classes Floresta (A), Agricultura (B), Pastagem (C), Água (D), Urbano (E) e Cerrado (F).	74
Figura 20 – Valores absolutos de mudanças na área para as classes de cobertura do solo para o período de 1985 a 2015.	75
Figura 21 – Mudanças em relação à cobertura do solo original entre 1985 e 2015.	80
Figura 22 – Mapeamento das mudanças na cobertura do solo para a sub-bacia Paraná, Guaçu, São Francisco Verdadeiro e outros.....	81
Figura 23 – Diagrama de mudanças para a sub-bacia Paraná, Guaçu, São Francisco Verdadeiro e outros para o período de 1985 a 2015.....	82

LISTA DE TABELAS

Tabela 1 - Resumo dos diferentes tipos de sensores Landsat com indicação das resoluções espacial, temporal, radiométrica e espectral.	21
Tabela 2 - Produtos regionais de cobertura do solo nos limites da Bacia Hidrográfica do Alto Rio Paraná.	27
Tabela 3 - Produtos de cobertura do solo desenvolvidos para a América do Sul.....	28
Tabela 4 – Principais produtos globais de cobertura do solo.	29
Tabela 5 – Orbita, ponto e data de imageamento das cenas utilizadas nesta pesquisa.....	35
Tabela 6 - Classes de cobertura do solo utilizadas nesta pesquisa e suas características.....	39
Tabela 7 - Atributos para a coleta de amostras.....	41
Tabela 8 – Parâmetros definidos para o classificador SVM.....	43
Tabela 9 – Grau de exatidão da classificação de acordo com o valor do índice Kappa.....	47
Tabela 10 - Legendas empregadas nos cinco conjuntos de dados globais.	48
Tabela 11 – Relação entre as classes geradas neste trabalho e classes de uso e ocupação do solo em escala global.....	52
Tabela 12 – Precisão Global e Índice Kappa para os produtos de cobertura do solo.....	61
Tabela 13 – Valores de Precisão Global (PG) e Índice Kappa para mapeamentos de cobertura do solo realizados no Brasil.....	62
Tabela 14 - Concordância global entre os mapas de cobertura do solo para a BHAPR.	72
Tabela 15 – Matriz de mudanças para o período de 1985 a 2015, área em porcentagem.	79

LISTA DE APÊNDICES

Apêndice 1 - Perfis NDVI característicos das classes pastagem (a), floresta (b), agricultura (c), cerrado (d) e desmatamento (e).....	100
Apêndice 2 – Exemplos de amostras de treinamento mapeadas na Bacia Hidrográfica do Alto Rio Paraná.	101
Apêndice 3 – Matriz de confusão para BHAPR-1985 baseado a pixel.....	104
Apêndice 4 – Matriz de confusão para BHAPR-1985 baseado em objetos.	104
Apêndice 5 – Matriz de confusão para BHAPR-2015 baseado a pixel.....	105
Apêndice 6 – Matriz de confusão para BHAPR-2015 baseado em objetos.	105
Apêndice 7 – Número de pontos de validação (PV), Precisão Global (PG) e Índice Kappa dos mapeamentos da cobertura solo de 1985 e 2015 para as sub-bacias da BHAPR.....	106
Apêndice 8 – Comparação de áreas (km ²) entre os produtos de cobertura do solo para a BHARP.....	107
Apêndice 9 – Área e variação de área para as 10 classes de cobertura do solo mapeadas para as sub-bacias da BHAPR.....	108

SUMÁRIO

1 INTRODUÇÃO	13
2 OBJETIVOS	16
2.1 OBJETIVO GERAL	16
2.2 OBJETIVOS ESPECÍFICOS	16
3 REVISÃO BIBLIOGRÁFICA	17
3.1 SENSORIAMENTO REMOTO	17
3.2 SATÉLITE LANDSAT	19
3.3 CLASSIFICAÇÃO DE IMAGENS DIGITAIS	23
3.3.1 Classificação baseada a pixel	23
3.3.2 Classificação baseada em objetos	24
3.3.3 Algoritmos de classificação	24
3.4 PANORAMA GERAL DO MAPEAMENTO DA COBERTURA DO SOLO DA BACIA DO ALTO PARANÁ	26
4 METODOLOGIA.....	32
4.1 ÁREA DE ESTUDO	32
4.2 DESENVOLVIMENTO DO MAPA DE COBERTURA DO SOLO.....	33
4.2.1 Conjunto de dados.....	34
4.2.2 Sistema de Classificação.....	38
4.2.3 Coleta de amostras de treinamento e validação	40
4.2.4 Classificação de imagens	42
4.2.5 Avaliação da acurácia.....	46
4.3 COMPARAÇÃO ENTRE AS BASES DE COBERTURA DO SOLO	47
5 RESULTADOS E DISCUSSÕES	54
5.1 MAPEAMENTO DA COBERTURA DO SOLO PARA A BHAPR.....	55
5.1.1 Mapeamento da cobertura do solo para o ano de 1985	56
5.1.2 Mapeamento da cobertura do solo para o ano de 2015	58
5.1.3 Avaliação dos métodos de classificação e acurácia	60
5.2 COMPARAÇÃO ENTRE BHAPR-2015 E OUTROS PRODUTOS	63
5.2.1 Floresta	66
5.2.2 Agricultura	66
5.2.3 Pastagem.....	67
5.2.4 Água	68

5.2.5 Urbano.....	68
5.2.6 Solo exposto.....	69
5.2.7 Cerrado/Vegetação arbustiva.....	69
5.2.8 Avaliação espacial comparativa.....	70
5.3 MUDANÇAS NA COBERTURA DO SOLO DA BHAPR.....	73
5.3.1 Alteração de área e distribuição por classes.....	74
5.3.2 Padrão de perdas e ganhos entre classes.....	78
6 CONCLUSÃO.....	83
REFERÊNCIAS.....	85
APÊNDICES.....	100

1 INTRODUÇÃO

Diversos estudos comprovam que a mudança climática em curso é decorrente principalmente do aumento de gases do efeito estufa na atmosfera (IPCC, 2013). A mudança climática representa um dos maiores desafios da modernidade e os efeitos dessa mudança podem trazer diversas consequências para a sociedade, mas em particular para as comunidades mais pobres (MENDELSON; DINAR; WILLIAMS, 2006; TOL, 2009; IPCC, 2013; WINSEMIUS et al., 2015).

Estudos recentes têm demonstrado que mudanças antropogênicas e naturais da cobertura terrestre também podem impactar diretamente no clima (e.g., BARNETT *et al.*, 2008; FINDELL *et al.*, 2007; FOLEY *et al.*, 2005; KALNAY; CAI, 2003). Nesse aspecto, para Ayoade (1996), a ação antrópica é considerada um dos maiores responsáveis pelas mudanças climáticas, principalmente em escala local. O autor indica que a urbanização, industrialização, desmatamento, atividades agrícolas, drenagem e construção de lagos artificiais, são responsáveis por profundas mudanças no balanço energético, causando principalmente aumento da temperatura, ocorrência de fenômenos extremos e redução de precipitações.

A sensibilidade do clima em relação às características da superfície terrestre tem sido demonstrada através de diversos experimentos numéricos conduzidos com Modelos de Circulação Geral e Modelos Climáticos Regionais. Os experimentos têm demonstrado em especial, que diferentes componentes do ciclo hidrológico são sensíveis à umidade do solo ou à capacidade de retenção de água, bem como ao albedo ou à rugosidade da superfície terrestre (SHUKLA; MINTZ, 1982; SCHULZ; DÜMENIL; POLCHER, 2001; SOUZA; OYAMA, 2011). Alguns estudos demonstram ainda que, mudanças na cobertura do solo ocorridas ao longo do último século, alteram a evapotranspiração e podem ter impacto significativo sobre a hidrologia das bacias hidrográficas, com efeitos diretos sobre o regime de vazão (MATHEUSSEN et al., 2000; COGNARD-PLANCQ et al., 2001; NIEHOFF; FRITSCH; BRONSTERT, 2002; COSTA; BOTTA; CARDILLE, 2003).

Devido à influência direta nos resultados de simulações numéricas, uma avaliação menos incerta do passado e presente da cobertura do solo é essencial para detectar e atribuir causalidade às mudanças atualmente em curso no ciclo hidrológico – variabilidade natural, mudança climática, mudança nas formas de uso e ocupação do solo (HOERLING et al., 2006; VERBURG; NEUMANN; NOL, 2011; WANG et al., 2015). A exemplo de tal afirmação, Sertel, Robock e Ormeci (2010) estudaram os impactos da representação de bases de dados de

cobertura do solo em Modelos Climáticos Regionais na Região de Mármara – Turquia. Os autores compararam simulações geradas a partir do *Global Land Cover Characteristics* (GLCC) (resolução de 1 km) com simulações geradas por meio de um produto feito com imagens Landsat (resolução de 30 m). Os resultados evidenciaram que a base de dados da cobertura do solo afetou nas respostas dos modelos, com aumento nas temperaturas regionais.

Nesse contexto, produtos de cobertura do solo mais refinados podem contribuir para melhorias na gestão de uma bacia hidrográfica, uma vez que reduzem incertezas quanto às previsões de modelos hidrológicos. Loosvelt (2013), por exemplo, avaliou a variação do nível de informação da cobertura do solo em simulações com modelo hidrológico na bacia do rio Bellebeek (Bélgica) e observou variações entre 2,0 e 2,4% no fluxo de água, o autor observou ainda a redução local de até 50% de incerteza na previsão do modelo quando dados refinados foram utilizados. Wegehenkel et al. (2006) avaliaram a influência de diferentes conjuntos de dados de cobertura do solo em simulações com modelo hidrológico na bacia do rio Ucker (Nordeste da Alemanha) e indicaram mudanças de até 70% na previsão de escoamento superficial ao usar diferentes fontes de entrada de cobertura do solo.

A necessidade de tal assertiva é premente para várias bacias hidrográficas brasileiras, e em especial a Bacia Hidrográfica do Alto Rio Paraná (BHAPR), que com cerca de 900.000 km² é a região mais intensamente explorada do Brasil, produzindo a maior parcela dos alimentos e eletricidade do país (SRH/MMA, 2006). Sendo, neste sentido, potencialmente afetada por mudanças na cobertura original do solo e, em paralelo, por possíveis mudanças climáticas.

A BHAPR passou por grandes alterações na sua cobertura vegetal ao longo do último século, sendo estas atribuídas por Doyle e Barros (2011) como principal propulsor em incrementos no regime de vazão da bacia. Segundo Tucci (2003), a cobertura florestal dos estados de São Paulo e Paraná, situados no centro da bacia, reduziu de aproximadamente 70% em 1907 para menos de 8% em 1990. Na década de 70, culturas anuais como soja, milho e trigo, aumentaram e, assim, geraram maior escoamento superficial (TUCCI, 2002). Também houve aumento da mecanização, gerando incrementos ainda maiores no escoamento médio devido à compactação do solo (TUCCI, 2002).

Contudo, foram realizados poucos estudos relacionados à tal temática na região; e os trabalhos desenvolvidos são, muitas vezes, realizados em escala global ou, quando muito, para Bacia do Prata. Assim, a região permanece à margem de estudos que proporcionem resultados mais conclusivos sobre a sua hidrologia, em particular a ocorrência de eventos atmosféricos extremos – secas e inundações.

Outra problemática refere-se a escala de abrangência dos mapeamentos disponíveis. Tais produtos de uso e ocupação disponíveis atualmente para a região foram desenvolvidos em escala global ou pontual. Neste último caso, os produtos estão disponíveis de forma muito fragmentada ao longo da bacia. Já os mapeamentos globais, foram comumente desenvolvidos em três resoluções distintas: 1 km (STRAHLER et al., 1999; HANSEN et al., 2000; LOVELAND et al., 2000; BARTHOLOME; BELWARD, 2005), 500 m (FRIEDL et al., 2010) e 300 m (ARINO et al., 2008), apresentando limitações inerentes às suas resoluções e metodologias de classificação.

Além da baixa resolução espacial, poucos pontos de amostragem estão localizados ao longo do perímetro da BHAPR. Por exemplo, seis amostras de treinamento foram utilizadas no produto desenvolvido por Friedl *et al.*(2010) e apenas uma no de Bartholome e Belward (2005). Como resultado, produtos pouco representativos para a região podem estar sendo utilizados em simulações regionalizadas para a área da bacia. Estudos como os de Cândido (2002) e Capucim *et al.*(2015) demonstram inconsistências significativas nos mapeamentos globais para algumas regiões do território brasileiro. Cândido (2002), por exemplo, encontrou uma grande área erroneamente classificada como caatinga no produto desenvolvido por Hansen *et al.* (2000) para partes da Região Central e Sul do Brasil, o que gerou resultados pouco representativos para a região.

Neste sentido, embora existam outros mapeamentos disponíveis para uso em modelos hidrológicos e climáticos, o presente trabalho busca construir uma base de dados de cobertura do solo para a Bacia Hidrográfica do Alto Rio Paraná, com alta resolução espacial, bem como avaliar mudanças na cobertura do solo ao longo do tempo.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Este trabalho tem por objetivo mapear a Bacia Hidrográfica do Alto Rio Paraná com maior resolução espacial do que os mapas globais existentes. Além disso, este trabalho busca analisar o uso e ocupação do solo, através de uma perspectiva regional, para compreender os efeitos por sub-bacias, que podem diferir substancialmente entre as bases já desenvolvidas, bem como compreender importantes transformações ocorridas nas últimas décadas.

2.2 OBJETIVOS ESPECÍFICOS

Em termos mais específicos os objetivos do estudo são:

- a) Gerar produtos de cobertura do solo com imagens Landsat para os anos de 1985 e 2015;
- b) Implementar algoritmo de classificação supervisionado para classificação de imagens Landsat;
- c) Avaliar a qualidade estatística da nova base de dados gerada;
- d) Analisar e comparar o produto gerado com produtos de cobertura do solo desenvolvido em períodos próximos aos estudados;
- e) Avaliar as principais mudanças ocorridas na cobertura do solo entre 1985 e 2015.

3 REVISÃO BIBLIOGRÁFICA

3.1 SENSORIAMENTO REMOTO

O campo do sensoriamento remoto evoluiu substancialmente em termos de aplicações recentes (HANSEN; LOVELAND, 2012; YU et al., 2014a). Isso se deve ao desenvolvimento tecnológico notório que ocorreu nas últimas décadas, juntamente com o maior desempenho e a redução dos custos de obtenção de dados (GREKOUSIS; MOUNTRAKIS; KAVOURAS, 2015; TOTH; JÓZKÓW, 2016). Os produtos associados ao uso e ocupação do solo foram, certamente, os grandes beneficiários desse desenvolvimento. Antes da década de 1960, o imageamento da superfície terrestre estava restrito a observações e fotografias utilizando a luz visível, obtidas por meio de aeronaves (SABINS, 2007). Atualmente, a ciência de sensoriamento remoto oferece uma capacidade única de monitoramento ambiental, por meio de satélites e radares, de maneira econômica e em comprimentos de onda maiores que os da luz visível (SABINS, 2007; KHATAMI; MOUNTRAKIS; STEHMAN, 2016).

Diversas são as soluções operacionais que podem ser extraídas de dados de sensoriamento remoto, por exemplo, estudos de biodiversidade e aplicações ecológicas (KERR; KERR; OSTROVSKY, 2003; COHEN; GOWARD, 2004; PETTORELLI et al., 2014), mapeamento topográfico (FARR; KOBRICK, 2000; LEHNER; VERDIN; JARVIS, 2008; DE MORISSON VALERIANO; DE FÁTIMA ROSSETTI, 2012), monitoramento de emissões de carbono (SCHWALM et al., 2012; BIRDSEY et al., 2013; AVITABILE et al., 2016), avaliação de riscos naturais (VRIELING, 2006; KHATAMI; MOUNTRAKIS, 2012), dinâmica hidrológica e climática (BOLCH, 2007; JHA et al., 2007; LI et al., 2009; WENG, 2009) e monitoramento da cobertura terrestre (HANSEN et al., 2000, 2013; HOUGHTON et al., 2012; GONG et al., 2013; GREKOUSIS; MOUNTRAKIS; KAVOURAS, 2015; PÉREZ-HOYOS et al., 2017).

A aquisição de dados de sensoriamento remoto depende do tipo de informação buscada, do tamanho e dinâmica do objeto ou fenômeno em estudo (ELSAYED; RISCHBECK; SCHMIDHALTER, 2015). Os diferentes dados existentes de sensoriamento remoto podem ser divididos em: sensores fotográficos, de radar, laser, espectrômetros e radiômetros. Estes, por sua vez, podem ser divididos em dois grandes grupos, sensores passivos e ativos. A principal diferença entre eles é que sensores passivos dependem da radiação solar como fonte luminosa e sensores ativos estão equipados com componentes que emitem luz (ELSAYED; RISCHBECK; SCHMIDHALTER, 2015).

Independente do tipo de sensor utilizado, existem características que descrevem e determinam se a aplicação de um dado é apropriada para um estudo particular. Resolução espacial, espectral e radiométrica são considerados conceitos-chave utilizados na caracterização de dados de sensoriamento remoto.

A resolução espacial indica o tamanho do menor elemento ou superfície distinguível que pode ser gravada separadamente em uma imagem. Esta unidade de área é conhecida como pixel (CAMPBELL; WYNNE., 2011). Sendo assim, um sensor com resolução espacial de 30 metros possui pixels que distinguem objetos com equivalência de 900m² (30m x30m) ou maiores (FLORENZANO, 2002).

A resolução espectral é a medida da largura das faixas espectrais de um sensor (GITAS et al., 2012). Uma alta resolução espectral indica que cada detector está recebendo energia em uma faixa mais estreita de comprimentos de onda (LILLESAND; KIEFER; CHIPMAN, 2014). Outras características desse tipo de resolução são o número e a posição das bandas espectrais.

A resolução radiométrica, por sua vez, expressa a capacidade do sensor captar diferentes intensidades ou níveis digitais do campo eletromagnético dos objetos (GITAS et al., 2012). A resolução radiométrica é, regularmente, expressa em número de dígitos binários (bits). Assim, um sensor com resolução radiométrica de 8 bit tem 256 níveis de luminosidade (RICHARDS; JIA, 2006).

A Figura 1 ilustra os termos associados aos diferentes tipos de resolução anteriormente citados. Outros termos recorrentes, mas não associados à obtenção do dado em si, são a resolução temporal e geométrica. A resolução temporal está relacionada à frequência que uma dada área é imageada e a resolução geométrica ao alinhamento entre pontos no solo e suas representações correspondentes na imagem.

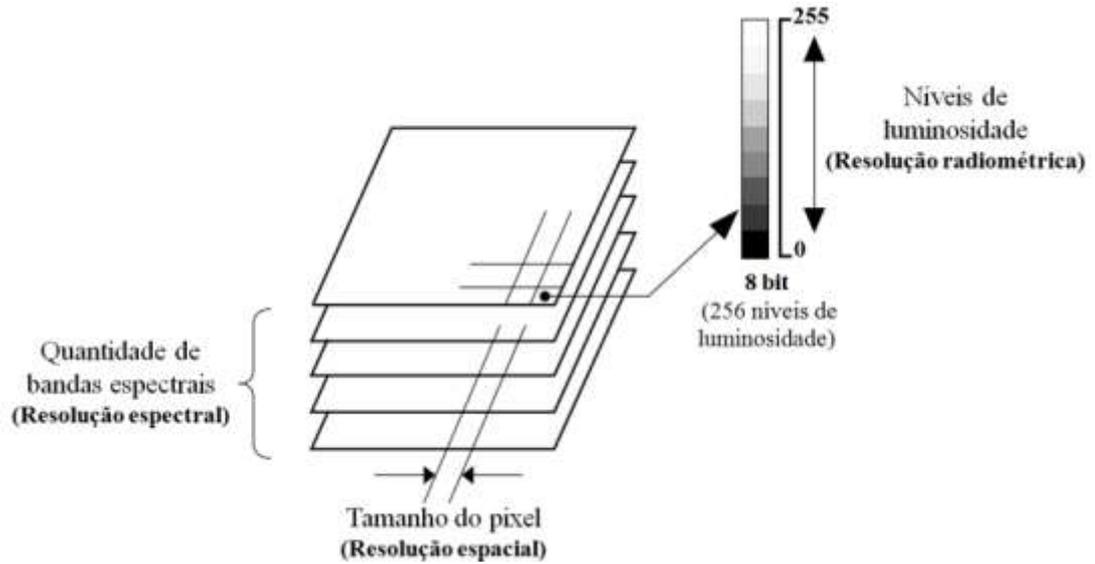


Figura 1 - Características técnicas de dados de sensoriamento remoto.

3.2 SATÉLITE LANDSAT

O Programa Landsat, cooperação entre *United States Geological Survey (USGS)* e *National Aeronautics and Space Administration (NASA)*, constitui o registro mais longo de dados de observação terrestre em escala global (HANSEN; LOVELAND, 2012). Desde o primeiro satélite da série, lançado em 1972 e denominado *Earth Resources Technology Satellite (ERTS)* (designado mais tarde de Landsat 1), vários avanços foram realizados nos sensores. Atualmente, a série conta com mais de 5 milhões de cenas da superfície terrestre (YU et al., 2014a; PHIRI; MORGENROTH, 2017), sendo, neste sentido, o tipo de dado mais utilizado para o mapeamento da cobertura terrestre (KNORN et al., 2009).

Quanto aos sensores, os três primeiros satélites da série Landsat (Landsat 1, 2 e 3) contavam com os sensores *Return Beam Vidicom (RBV)*, que permite observar a cena imageada instantaneamente, e o *MSS (Multispectral Scanner)*, sistema de varredura que opera em quatro canais (dois no visível e dois no infravermelho próximo) (NOVO, 2010; USGS, 2015). Os satélites Landsat 4 e 5, continham além do sensor MSS o sensor *TM (Thematic Mapper)*, que apresenta sete bandas espectrais (CHANDER; MARKHAM; HELDER, 2009). O satélite Landsat 6 possuía o sensor *Enhanced Thematic Mapper (ETM)* que, no entanto, faliu no lançamento, em 1993, e não chegou a entrar em órbita (FLORENZANO, 2002). O Landsat 7 contém o sensor *Enhanced Thematic Mapper Plus (ETM+)*, que apresenta as mesmas bandas espectrais do sensor TM, com a adição de uma banda pancromática (CHANDER; MARKHAM; HELDER, 2009). Mais recentemente, em

2013, foi lançado o satélite Landsat 8, equipado com os sensores *Operational Land Imager* (OLI) e *Thermal Infrared Sensor* (TIRS). Em comparação com o sensor ETM+, o sensor OLI possui 2 bandas reflexivas a mais e o sensor TIRS possui duas bandas térmicas (ROY et al., 2014). As características espectrais de cada sensor podem ser observadas na Tabela 1.

Tabela 1 - Resumo dos diferentes tipos de sensores Landsat com indicação das resoluções espacial, temporal, radiométrica e espectral.

Landsat 1-3 (MSS) ¹ 1972 – 1983			Landsat 4-5 (MSS) 1975 - 2013			Landsat 4-5 (TM) 1975 - 2013			Landsat 7 (ETM+) 1999 até o presente			Landsat 8 (OLI/TIRS) 2013 até o presente		
Temporal 18 dias	Radiométrica 6 bits		Temporal 18 dias	Radiométrica 6 bits		Temporal 16 dias	Radiométrica 8 bits		Temporal 16 dias	Radiométrica 9 bits		Temporal 16 dias	Radiométrica 12 bits	
Nome da banda	Espectral (μm)	Espacial (m)	Nome da banda	Espectral (μm)	Espacial (m)	Nome da banda	Espectral (μm)	Espacial (m)	Nome da banda	Espectral (μm)	Espacial (m)	Nome da banda	Espectral (μm)	Espacial (m)
Banda 4- verde	0,5–0,6	60	Banda 4- verde	0,5–0,6	60	Banda 1- Azul	0,45-0,52	30	Banda 1- Azul	0,45-0,52	30	Banda 1- Ultra	0,43-0,45	30
Banda 5- Vermelho	0,6-0,7	60	Banda 5- Vermelho	0,6-0,7	60	Banda 2- verde	0,52-0,60	30	Banda 2- verde	0,52-0,60	30	Banda 2- Azul	0,45-0,51	30
Banda 6- NIR	0,7-0,8	60	Banda 6- NIR	0,7-0,8	60	Banda 3- Vermelho	0,63-0,69	30	Banda 3- Vermelho	0,63-0,69	30	Banda 3- Verde	0,53-0,59	30
Banda 7 - NIR	0,8-1,10	60	Banda 7 - NIR	0,8-1,10	60	Banda 4- NIR	0,76-0,90	30	Banda 4- NIR	0,77-0,90	30	Banda 4- vermelho	0,64-0,67	30
												Banda 5- NIR	0,85-0,88	
						Banda 5- SWIR1	1,55-1,75	30	Banda 5- SWIR1	1,55-1,75	30	Banda 6- SWIR1	1,57-1,65	30
						Banda 7- SWIR2	2,08-2,35	30	Banda 7- SWIR2	2,09-2,35	30	Banda 7- SWIR2	2,11-2,29	30
									Banda 8- Pan	0,52-0,90	15	Banda 8- Pan	0,50-0,68	15
												Banda 9- Circus	1,36-1,38	30
						Banda 6- TIR	10,40- 12,50	120	Banda 6- 1-TIR	10,40- 12,50	60	Banda 10- TIR	10,60- 11,19	100
									Banda 6- 2-TIR	10,40- 12,50	60	Banda 11- TIR	11,50- 12,51	100

Notas: NIR, infravermelho próximo; SWIR, infravermelho vermelho de ondas curtas; TIR, termal; MSS, Multiespectral Scanner; TM, Thematic Mapper; ETM+, Enhanced Thematic Mapper Plus; OLI, Operational Land Imager; TIRS, Thermal Infrared Sensor.

Fonte: Phiri e Morgenroth (2017).

A série de dados Landsat é uma das fontes de informação mais importantes para a observação da superfície terrestre, em especial para o estudo de mudanças na cobertura do solo (ZHU; WOODCOCK, 2014). Sua aplicação é bastante recorrente devido ao longo registro de medição contínua e a resolução espacial (HANSEN; LOVELAND, 2012; YU et al., 2014a). As aplicações recentes envolvem avaliações da cobertura do solo e desmatamento (KINDU et al., 2013; ZOUNGRANA et al., 2015; WINGATE et al., 2016); expansão e intensificação da agricultura (ZHU et al., 2016; XIONG et al., 2017); crescimento urbano (MAHMOUD et al., 2016; SHI et al., 2017); estudos de inundações (OLTHOF, 2017) e; mapeamentos de água superficial (LYONS; SHENG, 2017; NITZE et al., 2017).

Análises de mudanças da cobertura do solo e/ou em áreas extensas demandam um conjunto de imagens geometricamente consistentes. Historicamente, a retificação geométrica tem sido um fator limitante no processamento de dados Landsat (HANSEN; LOVELAND, 2012). Visando a disseminação de dados Landsat, instituições, como o Serviço Geológico dos Estados Unidos (*United States Geological Survey* – USGS), passaram a desenvolver e disponibilizar produtos ortoretificados. Atualmente, o USGS conta com uma seção que disponibiliza produtos de Nível 2 para observação terrestre - imagens Landsat com efeitos geométricos, atmosféricos, adjacentes e topográficos corrigidos.

As imagens Landsat Nível 2 contam com reflectância de Topo da Atmosfera (*Top of Atmosphere* - TOA) corrigidas através do software *Landsat Ecosystem Disturbance Adaptive Processing System* (LEDAPS) para os sensores TM e ETM+ e pelo software *Landsat Surface Reflectance Code* (LaSRC) para o sensor OLI. Enquanto o LEDAPS aplica rotinas de correção atmosférica com auxílio do *Moderate Resolution Imaging Spectroradiometer* (MODIS), o LaSRC utiliza, além do MODIS, a banda ultra (banda 1) para realizar testes de inversão de aerossóis. Ambos os softwares são aplicados sobre imagens Landsat Nível 1 – produtos ortoretificados. As imagens Landsat Nível 1 (USGS, 2017), por sua vez, são divididas em 3 categorias: *Tier 1* (T1) que exige que o Root Mean Square Error (RMSE), registro (georreferenciado) a partir dos produtos do *Global Land Survey* (GLS), seja inferior a 12 m; *Tier 2* (T2), que inclui todos os produtos de Landsat Nível 1 que não atendem aos critérios do T1 e; a terceira categoria, Real-Time (RT), que utiliza parâmetros estimados para gerar produtos imediatamente após a aquisição da imagem (MICIJEVIC; HAQUE; MISHRA, 2016).

3.3 CLASSIFICAÇÃO DE IMAGENS DIGITAIS

Entende-se como classificação de imagens digitais o processo capaz de converter automaticamente pixels de imagens digitais em categorias de cobertura terrestre, transformando assim, imagens detectadas remotamente em produtos utilizáveis (WILKINSON, 2005; KHATAMI; MOUNTRAKIS; STEHMAN, 2016). A classificação da cobertura terrestre é um dos temas mais estudados em sensoriamento remoto (ZHU; WOODCOCK, 2014), servindo como base em diversas aplicações, em especial aquelas relacionadas à modelagem (BAI et al., 2014).

Zhu e Woodcock (2014) indicam que, embora seja relativamente fácil gerar um mapa de cobertura terrestre a partir de dados de detecção remota, não é fácil torná-lo preciso. Isto se deve a necessidade do analista de imagem ter que selecionar uma infinidade de opções para realizar a classificação de imagens, incluindo o tipo de imagem, algoritmo de classificação, dados de treinamento/validação, recursos de entrada, técnicas de pré e pós-processamento e categorias a serem mapeadas (KHATAMI; MOUNTRAKIS; STEHMAN, 2016).

Os métodos de classificação de imagens mais comumente utilizados podem ser divididos em duas categorias: métodos supervisionados e não-supervisionados. Na classificação supervisionada, os pixels da imagem são definidos a partir de descrições numéricas realizadas por um analista de imagens, que precisa definir primeiramente a quantidade e as classes temáticas que serão utilizadas na classificação (LILLESAND; KIEFER; CHIPMAN, 2014). As áreas escolhidas para a coleta de pixels representativos do tipo de cobertura do solo são denominadas de amostras de treinamento. São elas que irão direcionar o algoritmo de classificação na agregação dos pixels em cada classe de interesse (MOBLEY, 2016). Na classificação não-supervisionada, não existe a necessidade de coleta de amostras de treinamento, sendo assim, a mesma é realizada de forma automatizada pelos algoritmos, que fazem a extração, identificação e classificação dos pixels (RICHARDS; RICHARDS, 2006).

3.3.1 Classificação baseada a pixel

A classificação baseada a pixel utiliza apenas a informação espectral de cada elemento isolado para achar a classe de cobertura do solo mais provável para este. De forma geral, o algoritmo de classificação baseado a pixel identifica as diferentes assinaturas espectrais dos alvos terrestres por meio da análise de pixel de um determinado conjunto de bandas espectrais

(LILLESAND; KIEFER; CHIPMAN, 2014). Os dados usados geralmente consistem em valores de escala de cinza de um pixel de canais multiespectrais (YAN et al., 2006).

Através deste método, os pixels são comparados um a um com as amostras de treinamento fornecidas. Desta forma, o algoritmo decide a qual classe temática o mesmo pertence. Por serem classificados um a um, esses métodos desconsideram o contexto de inserção dos pixels e a textura da imagem (POHL; VAN GENDEREN, 1998).

3.3.2 Classificação baseada em objetos

Em contraste com os métodos de classificação baseados em pixel, que classificam pixels individuais, a classificação baseada em objetos agrega essas unidades em objetos espectralmente homogêneos, através da segmentação da imagem (PHIRI; MORGENROTH, 2017). A segmentação da imagem é a divisão desta em diferentes regiões baseada em propriedades espectrais e espaciais, assim, cada segmento contém informações relacionadas ao pixel e a sua circunvizinha (MOBLEY, 2016).

Para a classificação da imagem, os segmentos são utilizados como fonte de informação espectral. Estes, por sua vez, contêm forma (área, perímetro), textura, tipologia com relação a outras camadas ou níveis dos objetos e informações adicionais como atributos, além da intensidade de brilho (BAATZ, 2001).

Segundo Phiri e Morgenroth (2017), a metodologia de classificação baseada a objetos tem produzido maiores precisões de classificação que a classificação baseada a pixel. Pode-se salientar como vantagem o fato do processamento da segmentação não trabalhar somente com o pixel individualmente, mas com regiões homogêneas; outra vantagem é a redução do número de unidades de processamento, demandando um menor esforço computacional (YU; WANG; GONG, 2013).

3.3.3 Algoritmos de classificação

Os algoritmos de classificação de imagens digitais podem ser reunidos em dois grupos distintos: os paramétricos e não-paramétricos. Algoritmos paramétricos assumem que os dados seguem uma distribuição estatística de classe particular, normalmente a distribuição normal, que requer estimação de parâmetros como média e covariância (SCHOWENGERDT, 2007). Os algoritmos paramétricos mais conhecidos são o de Máxima Verossimilhança (MAXVER), Distância Euclidiana e o *K-means clustering* (KMC) (MOBLEY, 2016).

Os algoritmos não paramétricos, por outro lado, não fazem suposições sobre a distribuição de probabilidade e são frequentemente considerados classificadores bastante robustos, pois apresentam bons resultados para uma grande variedade de distribuições de classes, desde que as assinaturas da classe sejam razoavelmente distintas (SCHOWENGERDT, 2007). Os algoritmos não-paramétricos mais comumente aplicados são as redes neurais artificiais (RNA), Árvores de decisão e Máquinas de Vetores Suporte (*Support Vector Machine* – SVM) (MOBLEY, 2016).

3.3.3.1 *Support Vector Machine* (SVM)

O algoritmo SVM é uma técnica supervisionada, que fundamenta-se nos princípios da Minimização do Risco Estrutural (Structural Risk Minimization – SRM) para classificar uma imagem. Através de dados de treinamento, o SVM visa encontrar um hiperplano que separa o conjunto de dados em um número discreto de classes predefinidas (MOUNTRAKIS; IM; OGOLE, 2011). O termo hiperplano de separação ideal é usado para se referir ao limite de decisão que minimiza classificações erradas (MOUNTRAKIS; IM; OGOLE, 2011).

Na sua forma mais simples, o SVM só pode ser utilizado na separação de um par de classes de dados de cada vez (CANTY, 2009). Dados de sensoriamento remoto, por outro lado, envolvem uma gama de classes de cobertura do solo. Uma maneira comum de superar a restrição de duas classes é determinar todos os resultados possíveis destes pares e, em seguida, usar um esquema de votação para decidir sobre o rótulo da classe, assim como descrito em Canty (2009).

Para transformar um método simplificado que trabalha com apenas duas classes em um método mais robusto são utilizados kernels. Neste usa-se as correlações não-lineares em um espaço maior (Euclidiano ou Hilbert) (MOUNTRAKIS; IM; OGOLE, 2011). Desta forma, para classificar imagens com o algoritmo SVM é preciso primeiramente decidir qual o kernel que será utilizado e, em seguida, escolher os parâmetros associados a este, bem como a constante de penalização “C” (CANTY, 2009).

Os principais kernels utilizados em conjunto com o SVM são o Linear, o Polinomial, o Função de Base Radial (Radial Basis Function – RBF) e o *Sigmoid*. O kernel RBF é o mais utilizado, devido à velocidade de convergência e a precisão, que são itens já avaliados em trabalhos anteriores (MOUNTRAKIS; IM; OGOLE, 2011).

3.4 PANORAMA GERAL DO MAPEAMENTO DA COBERTURA DO SOLO DA BACIA DO ALTO PARANÁ

A informação da cobertura do solo na Bacia Hidrográfica do Alto Rio Paraná é altamente fragmentada e localizada (Tabela 2). Embora a BHAPR seja representada em diversos produtos de cobertura do solo desenvolvidos para a América do Sul (Tabela 3) e produtos globais (Tabela 4), não há, atualmente, produtos desenvolvidos e validados exclusivamente para esta área.

Tabela 2 - Produtos regionais de cobertura do solo nos limites da Bacia Hidrográfica do Alto Rio Paraná.

Conjunto de dados	Resolução espacial	Precisão Global (%)	Aquisição dos dados	Sensor	Esquema de classificação	Método de classificação	Desenvolvedor	Referência
Brasil								
2000	1:250.000	Indisponível	Vários anos	MODIS	13 classes	Classificação supervisionada	IBGE	IBGE (2017)
2010	1:250.000	Indisponível		MODIS	13 classes			
2012	1:250.000	Indisponível		MODIS	13 classes			
2014	1:250.000	Indisponível		MODIS	13 classes			
Cobertura do solo do Brasil	250m	Indisponível	2000, 2010	MODIS	9 classes	Classificação não supervisionada	INPE	Macedo et al. (2013)
TerraClass Cerrado	1:250.000	80,2	2013	Landsat OLI	13 classes	Classificação supervisionada e não supervisionada	MMA, UFG, UFU, INPE, IBAMA, EMBRAPA	(MMA, 2015)
São Paulo	1:100.000	97,1	2010	Landsat TM	7 classes	Classificação baseada em regra	SMA	SMA (2010)
Paraná								
1990	1:50.000	Indisponível	1989/1990	Indisponível	9 classes	Indisponível	ITCG	ITCG (s.d.)
2002	1:50.000	Indisponível	2001/2002	Indisponível	7 classes	Indisponível		
Bacia do Alto Iguaçu	1:20.000	Indisponível	2000	Ortofotos	22 classes	Interpretação visual	SUDERHSA	SUDERHSA (2004)
Minas Gerais								
2005	30m	Indisponível	2005	Indisponível	15 classes	Indisponível		Carvalho et al. (2008)
2007	30m	Indisponível	2007	Indisponível	15 classes	Indisponível		
2009	30m	Indisponível	2009	Indisponível	17 classes	Indisponível		
Goiás	1:250.000	Indisponível	2001-2002	Landsat ETM+	14 classes	Classificação não supervisionada	WWF Brasil	WWF Brasil (2004)

Notas: IBGE, Instituto Brasileiro de Geografia e Estatística; INPE, Instituto Nacional de Pesquisas Espaciais; MMA, Ministério do Meio Ambiente; UFG, Universidade Federal de Goiás; UFU, Universidade Federal de Uberlândia; IBAMA, Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis; EMBRAPA, Empresa Brasileira de Pesquisa Agropecuária; SMA, Secretaria do Meio Ambiente de São Paulo; ITCG, Instituto de Terras, Cartografia e Geologia do Paraná; SUDERHSA, Superintendência de Desenvolvimento de Recursos Hídricos e Saneamento Ambiental; WWF, World Wide Fund for Nature.

Tabela 3 - Produtos de cobertura do solo desenvolvidos para a América do Sul.

Conjunto de dados	Resolução espacial	Precisão Global (%)	Aquisição dos dados	Sensor	Esquema de classificação	Método de classificação	Desenvolvedor	Referência
LBA-ECO LC-08	1km	Indisponível	1987–1991	AVHRR	41 classes	Interpretação visual	WHRC	Stone et al. (1994)
SERENA	500m	84,2	2008	MODIS	FAO LCCS - 22 classes	Classificação supervisionada	Red LaTIF	Blanco et al. (2013)
MERISAM2009	300m	Apenas floresta tropical avaliada	2009–2010	MERIS	9 classes	Classificação não supervisionada	JRC	Gascon et al. (2012)
South America 30 m of 2010	30m	89,0	2010	Landsat TM e ETM+	FAO LCCS - 5 classes	Árvore de decisão de classificação supervisionada	USGS/ EROS	Giri e Long (2014)

Notas: WHRC, Woods Hole Research Centre; Red LaTIF, Red Latinoamericana de Teledeteccion e Incendios Foresatles; JRC, European Commission's Joint Research Center; USGS, United States Geological Survey. Baseado em: Grekousis, Mountrakis e Kavouras, (2015).

Tabela 4 – Principais produtos globais de cobertura do solo.

Conjunto de dados	Resolução espacial	Precisão Global (%)	Aquisição dos dados	Sensor	Esquema de classificação	Método de classificação	Desenvolvedor	Referência
GLOBAL								
DISCover	1km	66,9	1992–1993	AVHRR	IGBP - 17 classes	Classificação não supervisionada	USGS, UNL	Loveland et al. (2000)
UMD	1km	65,0	1992–1993	AVHRR	IGBP - 14 classes	Classificação supervisionada	UMD	Hansen et al. (2000)
GLC 2000	1km	68,6	1999–2000	SPOT-VGT	FAO LCCS - 22 classes	Classificação não supervisionada	JRC	Bartholome e Belward (2005)
MODIS Land Cover (MCD12Q1)	500m	71,6	Anualmente (de 2001 a 2013)	MODIS	IGBP - 17 classes	Classificação supervisionada	NASA	Friedl et al. (2010)
GlobCover								
GlobCover2005	300m	73,1	2004–2006	MERIS	FAO LCCS - 22 classes	Classificação supervisionada e não supervisionada	ESA	Arino et al. (2008); Bontemps et al. (2011)
GlobCover2009	300m	67,5	2009					Tateishi et al. (2011); Tateishi et al. (2014)
GLCNMO								
GLCNMO V1	1km	76,5	2003	MODIS	FAO LCCS - 20 classes	Classificação supervisionada	ISCGM	
GLCNMO V2	500m	77,9	2008					
CCI Land Cover	Detectado em 1km e re-mapeado para 300m	Validação em processo (71.1 – 2015)	Anualmente (de 1992 a 2015)	AVHRR (1992-1999) SPOT-VGT (1999-2013) PROBA-V (2014-2015)	FAO LCCS - 22 classes	Classificação não supervisionada	ESA	Defourny et al. (2017)
FROM-GLC								
FROM-GLC	30m	63,7	Cerca de 2010	Landsat TM e ETM+	9 classes	Classificação supervisionada	CESSC	Gong et al. (2013)
FROM-GLC-seg	30m	64,4				Classificação supervisionada		Yu, Wang e Gong (2013)
FROM-GLC-agg	30m	65,5				Procedimento de agregação		Yu et al. (2014)
GlobeLand30								
2000	30m	78,6	2000	Landsat TM, ETM+, HJ-1A/b/	10 classes	Classificação supervisionada	UN, NASG	Chen et al. (2015)
2010	30m	80,3	2010					

Notas: USGS, United States Geological Survey; UNL, University of Nebraska-Lincoln; UMD, University of Maryland; JRC, European Commission's Joint Research Center; NASA, National Aeronautics and Space Administration; ESA, European Space Agency; ISCGM, International Steering Committee for Global Mapping; FAO UN, Food and Agriculture Organization of the United Nations; CESSC, Centre for Earth System Science China; NASG, National Administration of Surveying, Mapping and Geoinformation; Baseado em: Grekousis, Mountrakis e Kavouras, (2015).

Diversos produtos regionais foram desenvolvidos nos limites da BHAPR, apresentados na Tabela 2. Embora sejam produzidos, em geral, em escala espacial mais fina, a falta de validação dificulta a avaliação do grau de exatidão de vários produtos. No que diz respeito aos registros históricos gerais de mapeamento da cobertura do solo da BHAPR, o primeiro produto regional foi desenvolvido para o estado do Paraná, com dados de 1989/1990 e escala de mapeamento de 1:50.000 (ITCG, s.d.). Já o produto mais recente foi desenvolvido para o Bioma Cerrado, com dados de 2013 e escala de mapeamento de 1:250.000 (MMA, 2015).

Dos quatorze produtos apresentados na Tabela 2, dois conjuntos de dados (cinco produtos) foram desenvolvidos para todo o território brasileiro. O primeiro deles foi elaborado pelo Instituto Brasileiro de Geografia e Estatística (IBGE) e contém produtos para os anos de 2000, 2010, 2012 e 2014 - produtos desenvolvidos com dados MODIS, imagens Landsat 5, 7 e 8, séries temporais de NDVI (*Normalized Difference Vegetation Index*) e informações provenientes da Pesquisa de Produção Agrícola Municipal (PAM) do IBGE e escala de mapeamento de 1:250.000 (IBGE, 2017). O segundo produto apresenta a cobertura do solo do Brasil para 2000 e 2010 com resolução espacial de 250m (MACEDO et al., 2013). Já o produto Terraclass Cerrado foi desenvolvido com base em imagens Landsat do ano de 2013 para o Bioma Cerrado (2.050.000 km²) e apresenta Precisão Global de 80%. Os demais produtos regionais foram desenvolvidos, em geral, por órgãos públicos estaduais e apresentam dados de cobertura do solo dos estados de São Paulo, Paraná, Minas Gerais e Goiás.

Observa-se que a maioria dos mapeamentos regionais foram desenvolvidos em escala de 1:250.000. Da área total da bacia, aproximadamente 97% é representada em escala de 1:250.000, 28% em 1:100.000, 22% em 1:50.000 e 3% em 1:20.000. Além disso, 97% da área da região foi mapeada com resolução espacial 250m e 18% com resolução de 30m.

Quanto aos mapeamentos realizados para a América do Sul, apenas quatro produtos de cobertura do solo foram produzidos entre 1994 e 2014 (Tabela 3), desconsiderando-se produtos desenvolvidos em nível global e, em seguida, utilizados para análise continental, tal como em Eva et al. (2004). O produto LBA-ECO (*Large-Scale Biosphere-Atmosphere Experiment in the Amazon*) foi o primeiro mapeamento de cobertura do solo desenvolvido exclusivamente para a América do Sul, este cobre o período 1987-1991 com resolução espacial de 1km. O produto SERENA (*Seguimiento y Estudio de los Recursos Naturales*) foi desenvolvido com dados do sensor MODIS para o ano de referência de 2008, resolução espacial de 500m e Precisão Global de 84% (BLANCO et al., 2013). O conjunto de dados MERISAM2009 (MERIS América do Sul) tem resolução espacial de 300m e utilizou dados

de 2009 (GREKOUSIS; MOUNTRAKIS; KAVOURAS, 2015). Neste caso, dados do satélite Landsat processados para o projeto TREES (BODART et al., 2011) foram utilizados para avaliar a precisão das classes de ampla cobertura do solo (florestas, arbustos, água e outras coberturas de solo), apresentando correlações de 0,84 para cobertura florestal, 0,9 para água, 0,7 para outras coberturas de solo e 0,34 para a classe arbustos (GASCON et al., 2012). O produto ‘*South America 30m land cover of 2010*’ é o mais recente e detalhado (resolução de 30m) produto desenvolvido para a América do Sul. Este foi produzido com dados de 2010 do satélite Landsat pelo Serviço Geológico dos Estados Unidos (*United States Geological Survey* – USGS), obtendo valores de Precisão Global de 89% (GREKOUSIS; MOUNTRAKIS; KAVOURAS, 2015).

Em relação aos produtos desenvolvidos para a América do Sul é possível observar uma melhora quanto à resolução espacial nos mapeamentos realizados - primeiro mapeamento realizado com resolução de 1km e mapeamento recente com resolução de 30m. Tal melhora pode estar relacionada aos avanços computacionais já mencionados anteriormente.

Em escala global, é possível observar que os primeiros produtos globais de cobertura do solo produzidos com imagens de satélite surgiram a partir do lançamento do Satélite da *National Oceanographic and Atmospheric Administration* (NOAA), equipado com o sensor *Advanced Very High Resolution Radiometer* (AVHRR) (DEFRIES; HANSEN; TOWNSHEND, 1995). Desde então, várias bases de dados foram desenvolvidas por diferentes iniciativas, gerando produtos que podem diferir quanto às classes e a resolução espacial e temporal.

Os conjuntos de dados globais de cobertura do solo mais conhecidos incluem: Global Land Cover Characteristics (GLCC) (LOVELAND et al., 2000); Moderate Resolution Imaging Spectroradiometer (MODIS) (FRIEDL et al., 2010); University of Maryland (UMD) (HANSEN et al., 2000); Global Land Cover 2000 (GLC 2000) (BARTHOLOME; BELWARD, 2005); GlobCover (SOPHIE; PIERRE; ERIC, 2010); Global Land Cover by National Mapping Organizations (GLCNMO) (TATEISHI et al., 2014); Climate Change Initiative-Land Cover (CCI-LC) (KIRCHES et al., 2016); com resoluções espaciais que variam entre 250m e 1km e recentemente os produtos Finer Resolution Observation and Monitoring-Global Land Cover (FROM-GLC) (GONG et al., 2013) e; GlobeLand30 (CHEN et al., 2015) com resolução espacial de 30m (Tabela 4). De forma geral, os produtos tiveram uma melhora quanto a resolução espacial dos sensores utilizados para os mapeamentos ao longo do tempo, assim como para os produtos desenvolvidos para a América do Sul.

4 METODOLOGIA

4.1 ÁREA DE ESTUDO

O Rio Paraná, formado pela confluência dos rios Grande e Paranaíba, é o maior contribuinte da Bacia Hidrográfica do Rio da Prata (BHRP) e, juntamente com o Rio Paraguai, formam uma bacia combinada que cobre uma área de cerca de $2,6 \times 10^6$ km² (aproximadamente 84% da BHRP) (KREPPER; VENTURINI, 2009). A Bacia combinada Paraná-Paraguai, também conhecida como Bacia Hidrográfica do Rio Paraná (BHRPR), pode ser, por sua vez, sub-dividida em 4 regiões hidrográficas: o Alto Paraná (BHAPR), que faz parte deste estudo e estende-se desde sua formação até a barragem de Itaipu; o Médio Paraná, formado pelo Rio Paraguai até a confluência com o Rio Paraná perto de Corrientes (Argentina); o Baixo Paraná, que corresponde a uma vasta planície aluvial até ao sul de Rosario (Argentina) e; o Delta, disposto entre a confluência do Rio Carcarana com o Rio Paraná e o estuário no Prata (STEVAUX, 2000) (Figura 2).

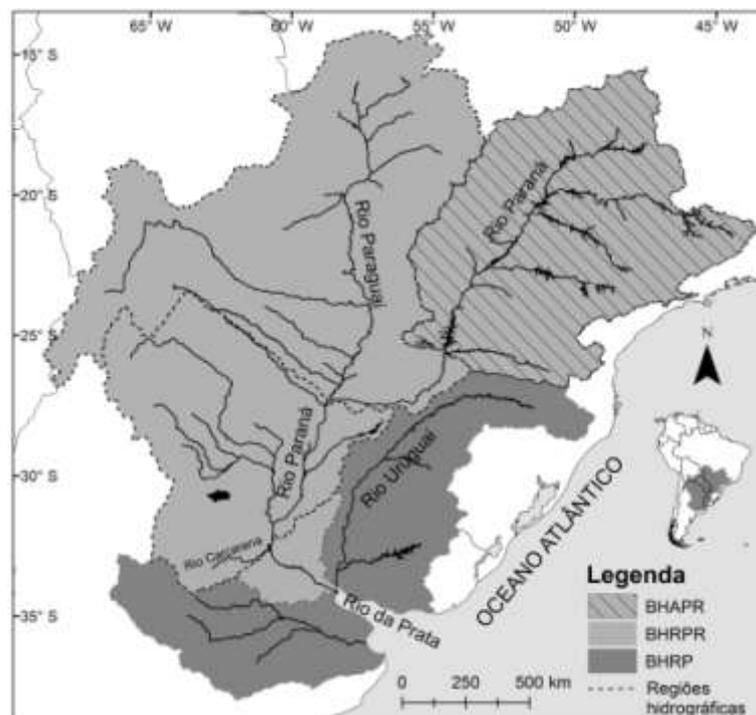


Figura 2 - Localização da Bacia Hidrográfica do Alto Rio Paraná.

A Bacia Hidrográfica do Alto Rio Paraná (BHAPR) compreende aproximadamente um terço da BHRPR, 898.880 km², destes 97% pertencente ao território brasileiro. A região, que ocupa aproximadamente 10% do território nacional, é de grande importância para o

Brasil, uma vez que há altas taxas de ocupação humana (65.596.000 habitantes, 35% da população) e grandes centros industriais em sua extensão. Além disso, a agricultura, pecuária e construção de barragens são atividades econômicas históricas (AGOSTINHO et al., 2007).

Quanto ao uso e cobertura do solo, observa-se antropização generalizada da BHAPR (SRH/MMA, 2006; DA PONTE et al., 2017). Na porção brasileira predominam, atualmente, áreas de agricultura, pastagem e remanescentes florestais dos biomas mata atlântica e cerrado. A produção agrícola da região é bastante diversificada, sendo soja, café, cana-de-açúcar, milho e laranja suas principais culturas (SRH/MMA, 2006). As áreas de pastagem estão dispostas em grande parte da margem direita da bacia, sendo mais expressivas nos estados de Mato Grosso e Goiás, onde a pecuária extensiva cresceu significativamente ao longo dos últimos anos (SRH/MMA, 2006). Quanto à região da BHAPR localizada no Paraguai, é possível perceber um desflorestamento recente. Grande parte da floresta atlântica do Alto Paraná localizada no Paraguai permaneceu intacta até a década de 1950. Entre 1973 e 2000 o Paraguai perdeu quase dois terços da floresta atlântica e hoje a região conta com menos de 10% de sua cobertura original (HUANG et al., 2007; DA PONTE et al., 2017). Atualmente a porção paraguaia da BHAPR é utilizada principalmente para a produção de soja e milho, feita por grandes proprietários, que representam 80% da área (HUANG et al., 2007; DA PONTE et al., 2017).

4.2 DESENVOLVIMENTO DO MAPA DE COBERTURA DO SOLO

O fluxograma geral de desenvolvimento do produto de cobertura do solo para a BHAPR está ilustrado na Figura 3. Cada etapa de execução da metodologia será descrita nas seções subsequentes.

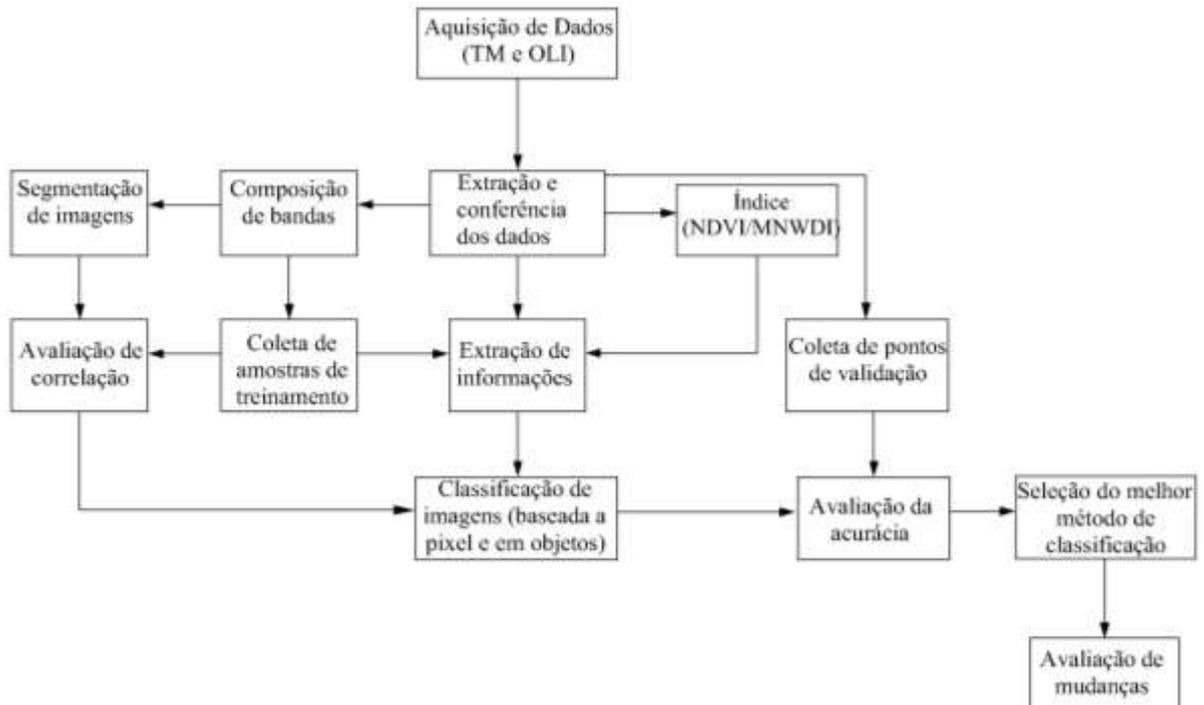


Figura 3 - Fluxograma global da metodologia aplicada para classificação do uso e ocupação do solo.

4.2.1 Conjunto de dados

Imagens Landsat Nível 2 dos sensores TM e OLI foram utilizadas para gerar os mapas de cobertura do solo de 1985 e 2015, respectivamente, sendo obtidas em formato GEOTIFF por meio do Serviço Geológico dos Estados Unidos (*United States Geological Survey – USGS*)¹. Para cobrir integralmente a área em estudo foram necessárias 52 cenas para 1985 e 50 cenas para 2015, sendo priorizadas imagens do período seco (abril a setembro). A Figura 4 apresenta as cenas escolhidas para os mapeamentos de 1985 e 2015 e a Tabela 5 mostra as características destas.

¹ <https://earthexplorer.usgs.gov>

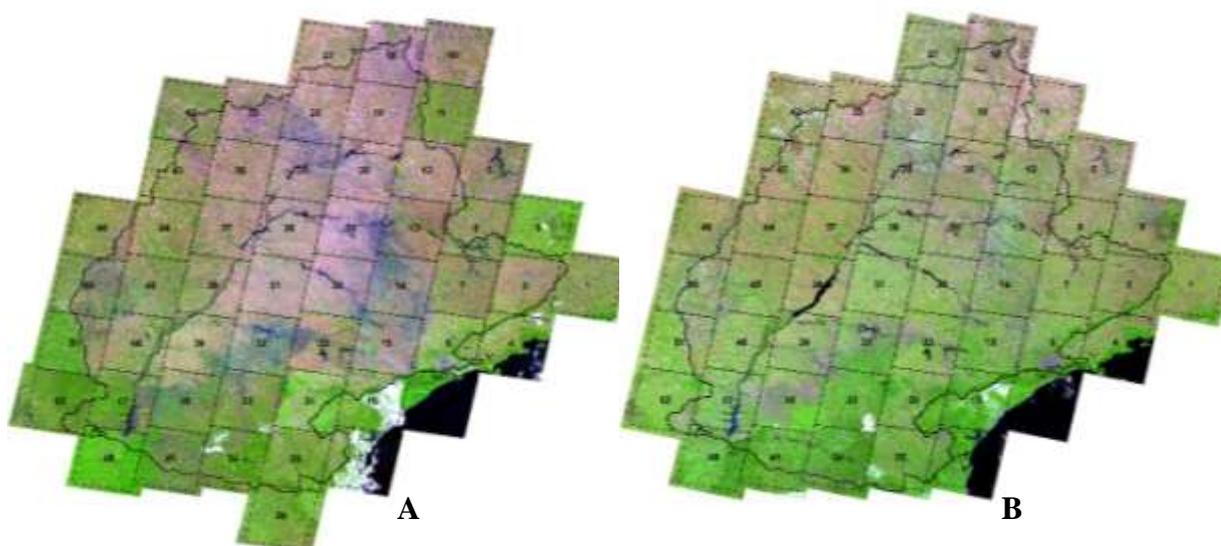


Figura 4 – Cenas Landsat utilizadas para os mapeamentos de cobertura do solo de 1985 (A) e 2015 (B).

Tabela 5 – Orbita, ponto e data de imageamento das cenas Landsat utilizadas nesta pesquisa.

(continua)

Número	Orbita	Ponto	1985	2015
01	217	75	04/07/1985	25/09/2015
02	218	74	08/05/1985	31/08/2015
03	218	75	15/10/1985	31/08/2015
04	218	76	15/10/1985	31/08/2015
05	219	73	02/07/1985	23/09/2015
06	219	74	16/06/1985	23/09/2015
07	219	75	06/08/1986	23/09/2015
08	219	76	22/10/1985 (12/03/1985)*	23/09/2015
09	219	77	16/06/1985	23/09/2015
10	220	71	25/07/1985	-
11	220	72	22/05/1985	16/10/2015
12	220	73	13/10/1985	13/08/2015
13	220	74	09/06/1985	29/08/2015
14	220	75	10/08/1985	29/08/2015
15	220	76	10/08/1985	13/08/2015
16	220	77	13/10/1985	29/08/2015
17	220	78	13/10/1985	29/08/2015
18	221	71	18/09/1985	21/09/2015
19	221	72	18/09/1985	21/09/2015
20	221	73	19/09/1985	21/09/2015
21	221	74	18/09/1985	21/09/2015
22	221	75	18/09/1985	21/09/2015
23	221	76	04/10/1985	21/09/2015
24	221	77	07/12/1985	21/09/2015
25	221	78	23/10/1986	07/10/2015 (21/09/2015)*
26	221	79	23/10/1986	-
27	222	71	08/08/1985	11/08/2015

*Imagens que necessitaram correções localizadas devido à presença de nuvens; Imagens que não estão em parênteses são consideradas imagens de referência, para ponto e orbita específicos; Imagens em parênteses foram utilizadas para as correções de nuvens.

Tabela 5 – Orbita, ponto e data de imageamento das cenas Landsat utilizadas nesta pesquisa.
(conclusão)

Número	Orbita	Ponto	1985	2015
28	222	72	08/08/1985	11/08/2015
29	222	73	08/08/1985	11/08/2015
30	222	74	08/08/1985	11/08/2015
31	222	75	08/08/1985	11/08/2015
32	222	76	08/08/1985 (23/07/1985)*	11/08/2015
33	222	77	09/09/1985 (05/06/1985)*	11/08/2015 (12/09/2015)*
34	222	78	05/06/1985 (09/09/1985)*	12/09/2015 (28/09/2015)*
35	223	72	15/08/1985	19/09/2015
36	223	73	15/08/1985	19/09/2015
37	223	74	15/08/1985	19/09/2015
38	223	75	15/08/1985	03/09/2015
39	223	76	15/08/1985	03/09/2015
40	223	77	15/08/1985	21/10/2015
41	223	78	15/08/1985	02/08/2015*
42	224	72	19/06/1985	25/08/2015
43	224	73	10/09/1986	09/08/2015
44	224	74	10/09/1986	09/08/2015
45	224	75	09/08/1986	09/08/2015
46	224	76	22/08/1985	09/08/2015
47	224	77	22/08/1985	09/08/2015
48	224	78	02/05/1985	09/08/2015
49	225	74	13/08/1985	17/09/2015
50	225	75	26/08/1985	01/09/2015
51	225	76	12/07/1985	17/09/2015
52	225	77	26/08/1985	31/15/2015

*Imagens que necessitaram correções localizadas devido à presença de nuvens; Imagens que não estão em parênteses são consideradas imagens de referência, para ponto e orbita específicos; Imagens em parênteses foram utilizadas para as correções de nuvens.

Devido à presença de cenas com nuvens, foram utilizadas oito imagens para correções localizadas (4 para cada ano). Além disso, devido à presença persistente de nuvens em seis cenas do ano de 1985, imagens do ano subsequente foram utilizadas, prática comumente empregada em estudos realizados para grandes áreas (e.g., GONG et al., 2013; WANG et al., 2015).

Os sensores TM e OLI possuem sete e nove bandas espectrais, respectivamente. No entanto, foram utilizadas apenas as bandas referentes aos comprimentos de onda do visível (bandas azul, verde e vermelho), infravermelho próximo (NIR) e infravermelho de ondas curtas (SWIR) (Tabela 1), assim como nos trabalhos de Gong et al. (2013) e Yu, Wang e Gong (2013). A característica evidenciada por cada uma das bandas selecionadas para a classificação é demonstrada abaixo (BARSÍ et al., 2014):

Banda Azul – Faz boa distinção entre solo e vegetação e também entre vegetação decídua e conífera;

Banda Verde - É útil para avaliar o vigor da vegetação;

Banda Vermelha - Discrimina as encostas da vegetação;

Banda NIR - Enfatiza o conteúdo de biomassa e linhas costeiras;

Banda SWIR 1 - Discrimina o teor de umidade do solo e da vegetação;

Banda SWIR 2 – Detecta alterações hidrotermais associadas a depósitos minerais

Além das bandas reflexivas, foram incorporados dois índices à classificação. Experimentos usando combinações de bandas refletivas com índices físicos têm obtido resultados promissores (e.g., CHEN et al., 2006; YU; WANG; GONG, 2013). Os índices aplicados foram: o Índice de Vegetação por Diferença Normalizada (*Normalized Difference Vegetation Index* – NDVI) (Rouse Jr et al., 1973) e o Índice de Água por Diferença Normalizada Modificado (*Modified Normalized Difference Water Index* – MNDWI) (XU, 2006), que realçam aspectos físicos referentes à vegetação e água, respectivamente.

O NDVI utiliza as bandas espectrais do vermelho e do infravermelho próximo (Equação 1), que são consideradas fortes indicadores da quantidade de biomassa fotossinteticamente ativa (WULDER; FRNKLIN, 2003) e tem sido amplamente utilizado durante as duas últimas décadas (CHENG et al., 2008).

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (1)$$

onde: *Red* = Banda referente ao espectro do vermelho e; NIR = Banda referente ao infravermelho próximo.

O MNDWI (Equação 2) foi utilizado para maximizar a refletância da água. Como resultado da aplicação, os corpos hídricos terão valores positivos e, portanto, se tornarão mais evidentes para a classificação (XU, 2006).

$$MNDWI = \frac{Green - SWIR1}{Green + SWIR1} \quad (2)$$

onde: *Green* = Banda referente ao espectro do verde e; *SWIR1* = Banda referente ao infravermelho de ondas curtas 1

4.2.1.1 Detecção e remoção de nuvens

Procedimentos espaciais para correção de nuvens foram utilizados em oito cenas, descritas na Tabela 5. Os procedimentos foram realizados a partir da banda *Quality Assessment* (QA)², que acompanha as demais bandas Landsat Nível 2. As etapas para remoção de nuvens foram: (1) ambas as imagens, referência e auxiliar, foram classificadas; em seguida, (2) a banda QA foi usada para remover os pixels dominados por nuvens na imagem de referência; que foram, por fim, (3) substituídos por pixels sem nuvens advindas da imagem auxiliar.

4.2.2 Sistema de Classificação

As classes temáticas apresentadas pelo mapa de cobertura do solo da BHAPR são representadas por áreas naturais, áreas antrópicas, corpos d'água e áreas não observadas. As áreas naturais incluem as categorias floresta e cerrado/vegetação arbustiva; áreas antrópicas foram divididas em agricultura, pastagem, urbano, solo exposto e queimada; corpos d'água superficiais são representados pela a classe água (rios, lagos, represas etc.) e; áreas não observadas contêm alvos de respostas espectrais relacionadas a nuvens e sombras. A Tabela 6 apresenta as classes de cobertura do solo adotadas nesta pesquisa.

² A banda QA é gerada a partir do algoritmo *Spatial Procedures for Automated Removal of Cloud and Shadow* (SPARCS) (HUGHES; HAYES, 2014), que é capaz de identificar nuvens utilizando um classificador supervisionado.

Tabela 6 - Classes de cobertura do solo utilizadas nesta pesquisa e suas características.

Nível 1	Nível 2	Descrição
(10) Floresta		Contém áreas de vegetação arbórea com predominância de dossel contínuo.
	(11) Floresta plantada	Contém vegetação florestal característica de silvicultura, tal como eucalipto e pinus.
(20) Agricultura		Considera áreas utilizadas para plantações.
	(21) Agricultura em transição.	Contém áreas de solo exposto devido à agricultura.
	(22) Campos de arroz	Contém áreas para cultivo de arroz, caracterizadas pela baixa resposta espectral.
	(23) Vegetação frutífera	Contém áreas agrícolas de produção frutífera, tal como café e laranja.
(30) Pastagem		Considera áreas típicas de pastagens para pecuária.
(40) Água		Contém todas as classes de água identificadas, tais como: rios, represas, lagos e áreas alagadas.
(50) Urbano		Contém área urbanizada (áreas edificadas, pequenos distritos, etc).
(60) Solo exposto		Além do solo permanentemente exposto, rochas expostas foram incluídas nessa classe.
	(61) áreas arenosas/mineração	Incluem áreas de mineração e áreas arenosas, caracterizadas pela alta resposta espectral.
(70) Cerrado/ vegetação arbustiva		Contém áreas de vegetação arbustiva-herbácea, com árvores distribuídas aleatoriamente sobre o terreno.
(80) Queimada		Contém áreas de queima de biomassa.
(888) Sombra		-
(999) Nuvem		-

A Figura 5 apresenta o perfil espectral das classes de cobertura do solo analisadas. O ganho quanto à separabilidade de classes é evidente no sensor OLI, que teve modificações radiométricas recentes, assim como demonstrado por Ke et al. (2015). Além de melhorias no sistema operacional, metodologias diferenciadas na correção radiométrica das imagens podem estar relacionadas aos ganhos.

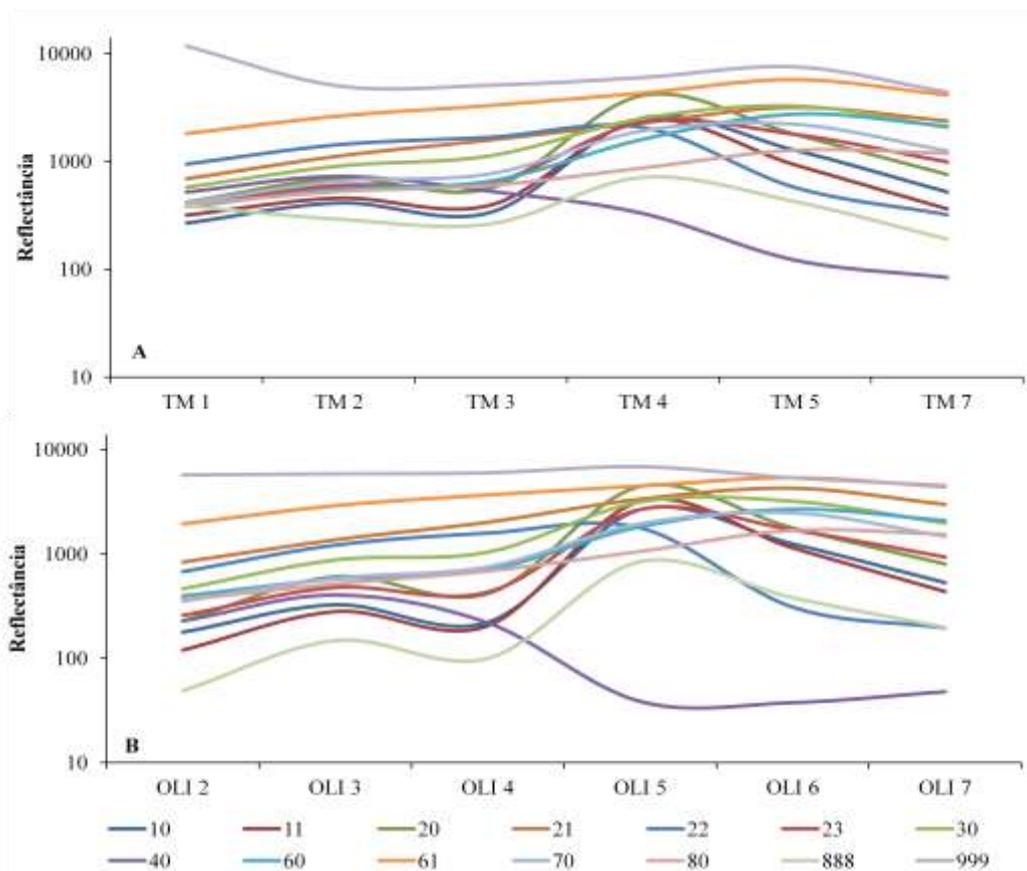


Figura 5 - Perfil espectral para as classes de cobertura do solo avaliadas para a BHAPR, considerando-se o sensor Landsat TM (A) e o sensor Landsat OLI (B).

4.2.3 Coleta de amostras de treinamento e validação

Amostras de treinamento representativas são um dos componentes mais críticos na classificação supervisionada, sendo importante não só a quantidade de amostras, mas também a qualidade e a distribuição destas (GONG et al., 2013). Neste sentido, para coletar um grande volume de dados de treinamento de forma eficiente alguns critérios foram adotados, são eles:

- (1) Cada cena Landsat foi dividida em quatro partes (Figura 6-A). Em cada quadrante foram coletadas de 50 a 70 amostras, buscando-se representar todas as classes disponíveis na imagem;
- (2) As amostras foram coletadas em áreas homogêneas;
- (3) As imagens foram interpretadas com auxílio de imagem de alta resolução (Google Earth) e perfis NDVI-MODIS, quando disponíveis;
- (4) Evitou-se a coleta de amostras incertas, sendo necessário o preenchimento da Tabela 7 para posteriores revisões, caso necessário.
- (5) As amostras foram bem distribuídas ao longo da imagem, evitando-se áreas com aglomeração de amostras.

Tabela 7 - Atributos para coleta de amostras.

ID	Nome-img	Código	Grande área	Resol-img	OBS
----	----------	--------	-------------	-----------	-----

A referência a cada atributo da Tabela 7 é demonstrada a seguir:

- (1) ID: identificação da amostra de treinamento em uma determinada Cena Landsat.
- (2) Nome-img: Ponto e órbita da cena Landsat.
- (3) Código: Código da classe de uso e ocupação do solo de acordo com a Tabela 6.
- (4) Grande área: campo destinado a informações relacionadas ao entorno da amostra. Sendo, campo vazio quando o entorno contiver uma grande área referente à mesma classe de uso e ocupação do solo e 0 no caso de se tratar de uma pequena área isolada.
- (5) Resol-img: quando houver imagens de alta resolução para constatação da classe o campo de atributo será vazio, quando não, será 0.
- (6) OBS: campo destinado a comentários quanto à amostra de treinamento.

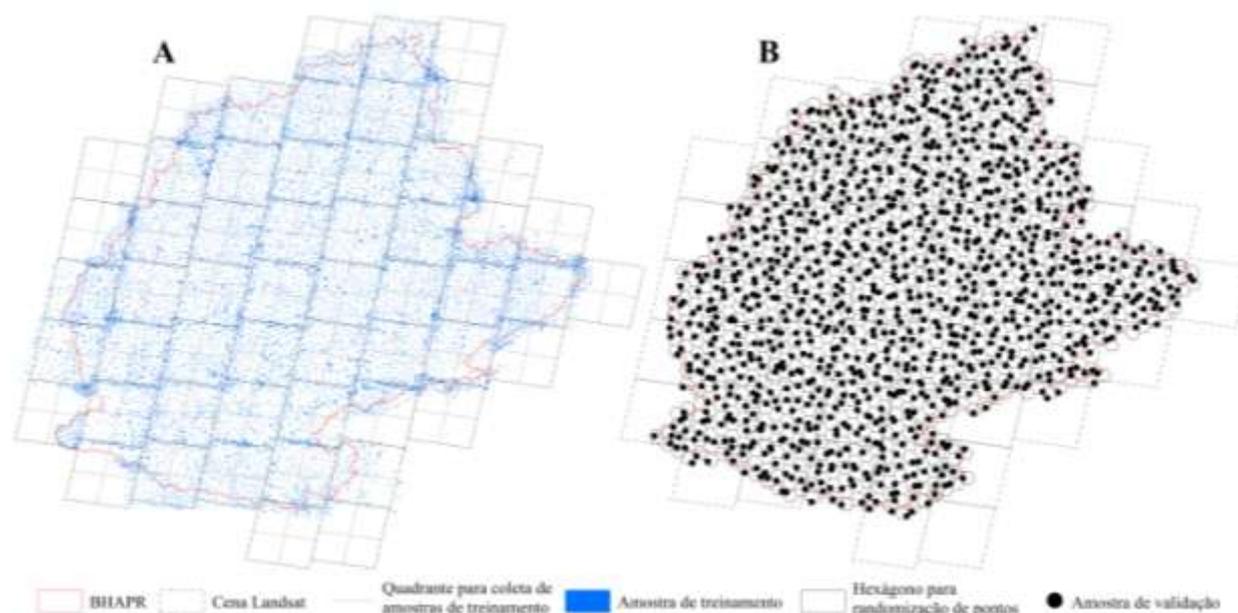


Figura 6 – Metodologia de coleta de amostras de treinamento (A) e validação (B).

Para garantir a representatividade das amostras de treinamento mapas de referência foram utilizados, são eles: mapa de Unidades de Conservação (MMA, 2012); mapa de áreas prioritárias para proteção (MMA, 2007a); mapa síntese de área de pastagem (LAPIG, 2014) e; Terraclass cerrado - mapeamento realizado para o cerrado brasileiro (MMA, 2015). Além disso, imagens Google Earth e perfis temporais de NDVI do *Moderate Resolution Imaging Spectroradiometer* (MODIS) foram utilizados como auxílio para as coletas de treinamento para o ano de 2015; esta metodologia não foi empregada para o ano de 1985, uma vez que

imagens Google Earth e perfis de NDVI não estão disponíveis para o período. Os perfis NDVI foram observados através do Sistema de Análise Temporal da Vegetação (SATVeg), software online³. Exemplos de perfis típicos de NDVI utilizados como auxílio para a coleta de amostras de treinamento podem ser observados no Apêndice 1.

No total, foram coletadas 32.768 amostras de treinamento, destas 17.040 para o ano de 1985 e 15.728 para o ano de 2015. A distribuição das amostras de treinamento para o ano de 1985 pode ser observada na Figura 6. Exemplos de amostras utilizadas para o treinamento do classificador podem ser observados no Apêndice 2.

A metodologia para coleta de amostras de validação é baseada na estrutura de análise do trabalho de Gong *et al.*, 2013, no qual as amostras foram predefinidas de uma forma sistemática não alinhada (BANKO, 1998a). Primeiramente, a BHAPR foi dividida em 1.149 hexágonos igualmente distribuídos, gerados através do pacote *Discrete Global Grids-software R* (dggridR). Em seguida, foi distribuído um ponto randomizado para validação em cada hexágono, locais fixos que não foram alterados (Figura 6-B). Pontos de validação gerados fora do perímetro da bacia foram excluídos da análise, assim como pontos com incertezas (principalmente áreas de transição entre classes). Imagens Google Earth e perfis NDVI-MODIS também foram utilizados como auxílio nesta Etapa.

Para o ano de 2015, 1.033 pontos de validação foram randomizados no perímetro da bacia, destes 953 foram avaliados com exatidão e foram utilizados para a avaliação de acurácia. Já para o ano de 1985, 1054 pontos de validação foram randomizados no perímetro da bacia, destes 993 foram considerados apropriados para a avaliação de acurácia.

4.2.4 Classificação de imagens

Após a avaliação de classificadores em uma área teste, tanto supervisionados (Support Vector Machine - SVM e Máxima Verossimilhança - MAXVER) como não supervisionados (*Iterative Self-Organizing Data Analysis Technique Algorithm* - ISOData), optou-se pela aplicação do classificador SVM, que apresentou os resultados mais precisos, assim como já mencionado em outros estudos (e.g., GONG *et al.*, 2013; YU *et al.*, 2014).

Para a aplicação do SVM considerou-se as seis bandas reflexivas dos sensores TM e OLI e os índices NDVI e MNDWI, descritos anteriormente. O conjunto de parâmetros

³ <https://www.satveg.cnptia.embrapa.br/satveg/login.html>

utilizados para classificação de imagens baseou-se no estudo de Gong et al. (2013) e está listado na Tabela 8.

Tabela 8 – Parâmetros definidos para o classificador SVM.

Classificador	Software	Parâmetros
SVM	ENVI	Kernel: RBF Gamma: 0,125 C (<i>cost</i>): 100 Limiar de probabilidade: 0

Notas: O parâmetro Gamma define o alcance da influência de uma única amostra de treinamento, sendo aqui considerado o inverso da quantidade de bandas espectrais; o parâmetro C está relacionado à simplicidade da superfície de decisão – um valor alto de C torna o algoritmo mais robusto. Limiar de probabilidade está relacionado à porcentagem de pixels que será classificada - um limiar zero indica que todos os pixels serão classificados.

Assim sendo, as imagens foram classificadas através de duas técnicas de classificação de imagens, são elas: classificação baseada a pixel e classificação baseada em objetos, detalhadas na sequência.

4.2.4.1 *Classificação baseada a pixel*

Para a classificação baseada a pixel a classe urbano não foi considerada, sendo esta mapeada apenas com o algoritmo regra de decisão (*Rule-Based*) descrito posteriormente. Desta forma, as cenas Landsat foram inseridas no software ENVI juntamente com as amostras de treinamento das demais classes e utilizou-se os parâmetros descritos na Tabela 8 para classificação.

4.2.4.2 *Classificação baseada em objetos*

Para classificação de imagens baseada em objetos é necessário primeiramente realizar a segmentação da imagem, na qual pixels são agregados em conjuntos contínuos. Sendo assim, as imagens Landsat TM e OLI foram segmentadas usando o algoritmo de segmentação *Watershed* disponível no software ENVI, assim como pode ser observado na Figura 7.

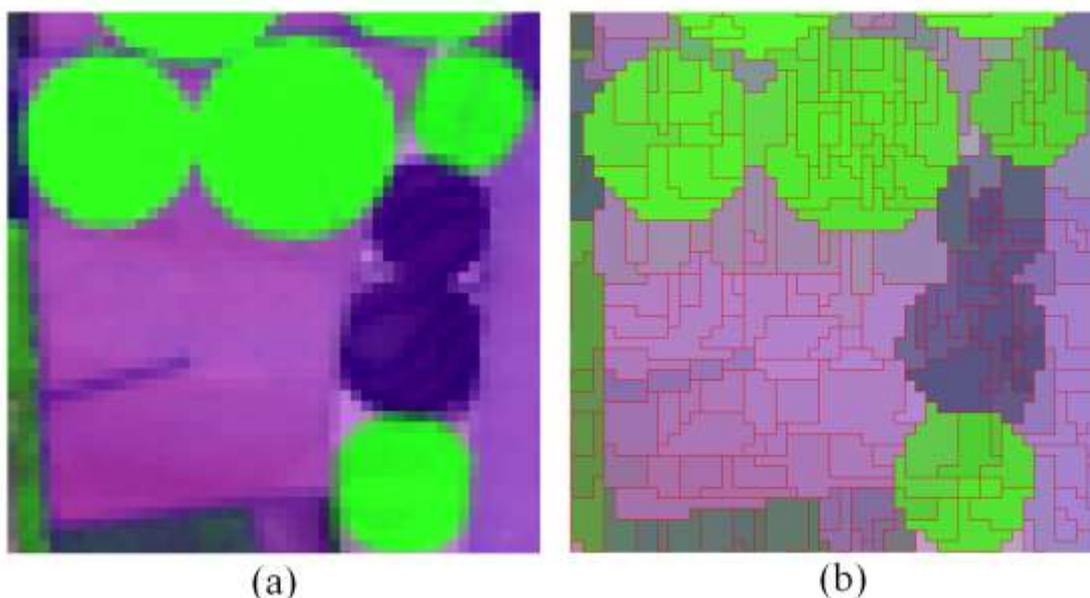


Figura 7 – Imagem Landsat não segmentada (a) e segmentada (b) através do algoritmo watershed.

Para não degradar excessivamente a resolução espacial da imagem Landsat (30m) foram adotados valores 0 para os parâmetros nível de escala (*scale level*)⁴ e nível de agrupamento (*merge level*)⁵. Desta forma, o tamanho médio dos segmentos foi de aproximadamente 13 pixels TM /OLI, menor que um pixel MODIS, por exemplo (~66 TM/OLI pixels).

Por fim, as amostras de treinamento, coletadas anteriormente, foram utilizadas para selecionar os segmentos mais fidedignos e posteriormente usados para classificar as imagens segmentadas. A metodologia para seleção de segmentos baseou-se na metodologia empregada por Yu, Wang e GONG (2013), que utilizaram correlação para selecionar apenas os segmentos com maior similaridade com as amostras de treinamento.

4.2.4.3 Extração da classe urbano

A classificação de áreas urbanas foi feita separadamente devido à confusão espectral com outras classes, como solo exposto e agricultura. Esta metodologia é comumente aplicada em estudos de grandes áreas, procedimento usado também por Schneider, Friedl e Potere (2009, 2010).

⁴ Nível de escala determina o percentual de valores do gradiente que serão descartados (ENVI, 2013b).

⁵ Nível de agrupamento permite um novo agrupamento de segmentos adjacentes (ENVI, 2013b).

Para a classificação de áreas urbanas foram considerados apenas pixels incluídos dentro de uma máscara produzida através de 1km de *buffer* a partir do arquivo *Global Urban Footprint* (ESCH et al., 2012, 2013) - mapeamento mundial de assentamentos com resolução espacial de 0,4 arcseg (~12m) realizado para o ano de 2013. Ademais, foram utilizados três índices para a classificação, são eles: MNDWI (equação 2), *Soil Adjusted Vegetation Index* (SAVI) (equação 3) e *Index-Based Built-up Index* (IBI) (equação 4), descritos em Xu (2008), Taubenböck et al. (2012) e Zhang et al. (2017). As equações 2 e 4 são descritas por:

$$SAVI = \frac{NIR - Red (1+l)}{NIR + Red + 1} \quad (3)$$

$$IBI = \frac{2SWIR1/(SWIR1+NIR) - [NIR/(NIR+Red) + Green/(Green+SWIR1)]}{2SWIR1/(SWIR1+NIR) - [NIR/(NIR+Red) - Green/(Green+SWIR1)]} \quad (4)$$

onde: *Red* = Banda referente ao espectro do vermelho; NIR = Banda referente ao infravermelho próximo; *l* é um fator de correção, variando de 0, para alta densidade de vegetação, a 1, para baixa densidade de vegetação; *Green* = Banda referente ao espectro do verde e; SWIR1 = Banda referente ao Infravermelho de ondas curtas 1.

Por fim, as imagens foram classificadas através do algoritmo Rule-based, que agrupa clusters de pixels da imagem segmentada em grupos de classes (ENVI, 2013a). A aplicabilidade da metodologia pode ser observada na Figura 8.

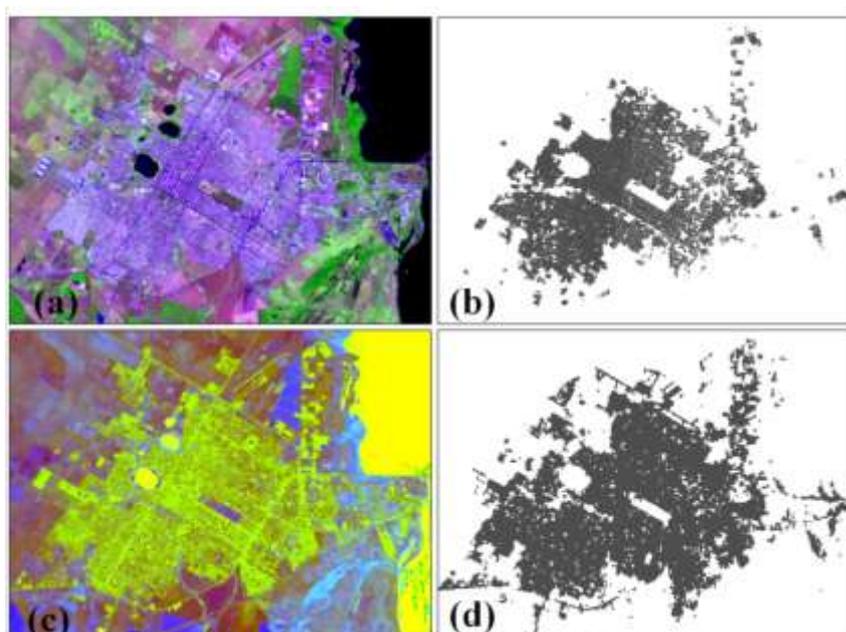


Figura 8 – RGB (a), Global Urban Footprint (b), composição dos índices (c) e resultado de aplicação do método (d) para a cidade de Três Lagoas (MS).

4.2.5 Avaliação da acurácia

Para avaliar a acurácia dos produtos de cobertura do solo foram utilizadas as metodologias de matriz de confusão, Precisão Global e Índice Kappa.

A maneira mais comum de expressar a precisão da classificação é a preparação de uma matriz de confusão (FOODY, 2002). Essas matrizes mostram a tabulação cruzada da cobertura territorial classificada e a cobertura real da terra revelada pelos resultados do local da amostra de validação (BANKO, 1998b). Nas colunas da matriz são expressos os valores dos tipos de cobertura reais, nas linhas os dados classificados e a diagonal principal lista os pixels classificados corretamente (CONGALTON, 1991).

Através da matriz de confusão é possível avaliar também a Acurácia do Produtor (AP) e do Usuário (AU), método descrito em Banko (1998b). A Acurácia do Produtor indica a probabilidade de um pixel de referência ter sido corretamente classificado e Acurácia do Usuário calcula a probabilidade de um pixel classificado no mapa representar a categoria no solo (STORY; CONGALTON, 1986).

A Precisão Global é uma medida simples e comumente aplicada, o cálculo é realizado através da razão entre os pixels corretamente classificados (soma dos valores na diagonal principal) e o número total de pixels verificados (BANKO, 1998b).

Outro método amplamente utilizado para avaliar a classificação é o Índice Kappa (SIEGEL; CASTELLAN, 1988), representado pela Equação 5. O coeficiente Kappa é uma medida de concordância global de matriz, assim como a metodologia de Precisão Global. No entanto, o Índice Kappa leva em consideração elementos não diagonais (BANKO, 1998b). O Índice Kappa foi avaliado de acordo com o grau de exatidão definido na Tabela 9.

$$Kappa = \frac{n \sum_{i=1}^c x_{ii} - \sum_{i=1}^c (x_i + x + i)}{n^2 - \sum_{i=1}^c (x_i + x + i)} \quad (5)$$

onde: $\sum_{i=1}^c x_{ii}$ = somatório da diagonal da matriz de confusão; n = número de amostras coletadas; c = número do total de classes; x_i = soma da linha i da matriz de confusão; $x + i$ = soma da coluna i da matriz de confusão.

Tabela 9 – Grau de exatidão da classificação de acordo com o valor do Índice Kappa.

Valor do Kappa	Força da Concordância
< 0,20	Pobre
0,21 - 0,40	Fraca
0,41 - 0,60	Moderada
0,61 - 0,80	Boa
0,81 - 1,00	Muito boa

Fonte: Aniekan Eyoh et al. (2012)

4.3 COMPARAÇÃO ENTRE AS BASES DE COBERTURA DO SOLO

Apenas o produto BHAPR-2015 foi considerado para comparação entre as bases de cobertura do solo, uma vez que não há produtos de cobertura do solo disponíveis para comparação com o produto de 1985. Para comparação, foram utilizados cinco produtos de períodos próximos a 2015, são eles: GlobCover-2009, Globeland30-2010, GLCNMO-2013, MODIS-2013, CCI-2015, legendas descritas na Tabela 10.

Tabela 10 - Legendas empregadas nos produtos globais de cobertura do solo GlobeLand 30, MODIS, GLCNMO, GlobCover e CCI.

(continua)

Globeland30	MODIS	GLCNMO	GlobCover	CCI
(10) Área cultivada	(0) Água	(1) Floresta latifoliada perene	(11) Agricultura irrigada ou pós-inundação (ou aquática)	(10) Agricultura, sequeiro
(20) Floresta	(1) Floresta perene de folha agulhada	(2) Floresta latifoliada decídua	(14) Terras cultivadas de sequeiro	(20) Agricultura, irrigada ou pós-inundada
(30) Pastagem	(2) Floresta latifoliada perene	(3) Floresta perene de folha agulhada	(20) Mosaico de agricultura (50-70%)/ vegetação (pastagem/arbusto/floresta) (20-50%)	(30) Mosaico de Agricultura (>50%)/ Vegetação natural (cobertura arbórea, arbustiva, herbácea) (<50%)
(40) Arbusto	(3) Floresta decídua de folha agulhada	(4) Floresta decídua de folha agulhada	(30) Mosaico de vegetação (pastagem/arbusto/floresta) (50-70%)/ agricultura (20-50%)	(40) Mosaico de vegetação natural (cobertura arbórea, arbustiva, herbácea) (<50%)/ Agricultura (<50%)
(50) Área alagável	(4) Floresta latifoliada decídua	(5) Floresta mista	(40) Floresta latifoliada perene ou semi- decídua (>5m) - densa à esparsa (>15%)	(50) Cobertura arbórea, latifoliada, perene, densa à esparsa (>15%)
(60) Corpo d'água	(5) Floresta mista	(6) Árvores esparsas	(50) Floresta latifoliada decídua (>5m) - densa (>40%)	(60) Cobertura arbórea, latifoliada, decídua, densa à esparsa (>15%)
(70) Tundra	(6) Vegetação arbustiva densa	(7) Arbusto	(60) Floresta latifoliada decídua/ Floresta lenhosa (>5m) - esparsa (15-40%)	(70) Cobertura arbórea, de folha agulhada, perene, densa à esparsa (>15%)
(80) Superfície artificial	(7) Vegetação arbustiva esparsa	(8) Vegetação herbácea	(70) Floresta perene de folha agulhada (>5m) - densa (>40%)	(80) Cobertura arbórea, de folha agulhada, decídua, densa à esparsa (>15%)
(90) Área descoberta	(8) Savana arborizada	(9) Vegetação herbácea com árvore/arbusto Esparso	(90) Floresta perene ou decídua de folha agulhada (>5m) - esparsa (15-40%)	(90) Cobertura arbórea, tipo de folha mista (latifoliada e de folha agulhada)
(100) Neve e gelo permanente	(9) Savana	(10) Vegetação	(100) Floresta mista de folha agulhada e latifoliada (>5m) - densa à esparsa (>15%)	(100) Mosaico arbóreo e arbustivo (>50%)/ cobertura herbácea (<50%)
	(10) Pastagem	(11) Agricultura	(110) Mosaico de floresta ou arbusto (50-70%)/ pastagem (20-50%)	(110) Mosaico de cobertura herbácea (>50%)/ arbóreo e arbustivo (<50%)
	(11) Área permanentemente alagada	(12) Campo de arroz	(120) Mosaico de pastagem (50-70%)/ floresta ou arbusto (20-50%)	(120) Arbusto
	(12) Agricultura	(13) Mosaico de Agricultura/outra vegetação	(130) Arbusto (folha agulhada e latifoliada, perene ou decídua) (<5m) - densa à esparsa (>15%)	(130) Pastagem

Fonte: Chen et al. (2015), Friedl et al. (2010), Bontemps et al. (2011), Tateishi et al. (2014) e Defourny et al. (2017).

Tabela 10 - Legendas empregadas nos produtos globais de cobertura do solo GlobeLand 30, MODIS, GLCNMO, GlobCover e CCI.

(conclusão)

Globeland30	MODIS-IGBP	GLCNMO	GlobCover	CCI
	(13) Área urbana	(14) Mangue	(140) Vegetação herbácea (pastagem, savana ou musgo/líquen) - densa à esparsa (>15%)	(140) Líquen e musgo
	(14) Mosaico de agricultura com vegetação natural	(15) Área alagável	(150) Vegetação - esparsa (>15%)	(150) Vegetação esparsa (cobertura arbórea, arbustiva, herbácea) (<15%)
	(15) Neve e Gelo	(16) Área descoberta, consolidada (cascalho, rocha)	(160) Floresta latifoliada inundada regularmente- densa à esparsa (>15%)	(160) Cobertura arbórea, inundada, água fresca ou salobra
	(16) Área descoberta ou esparsamente vegetada	(17) Área descoberta, não consolidada (areia)	(170) Floresta latifoliada ou arbusto inundado permanentemente (Água Salina ou Salobra) - densa (>40%)	(170) Cobertura arbórea, inundada, água salina
		(18) Urbano	(180) Pastagem ou vegetação lenhosa em solos regularmente alagados ou inundados (Água fresca, salobra ou salgada) - densa à esparsa (>15%)	(180) Cobertura arbustiva ou herbácea, inundada, água fresca/salina/salobra
		(19) Neve/Gelo	(190) Superfície artificial e áreas associadas (Áreas urbanas >50%)	(190) Áreas Urbanas
		(20) Corpos d'água	(200) Área descoberta	(200) Área descoberta
			(210) Corpo d'água	(210) Corpo d'água

Fonte: Chen et al. (2015), Friedl et al. (2010), Bontemps et al. (2011), Tateishi et al. (2014) e Defourny et al. (2017).

GlobCover-2009 é um produto global de cobertura do solo desenvolvido pela Agência Espacial Europeia. Este conta com dados do sensor MERIS (resolução espacial de 300m) coletados entre janeiro e dezembro de 2009 - sensor a bordo do satélite ENVISAT (BONTEMPS et al., 2011). Os métodos de classificação adotados no mapeamento seguem duas metodologias distintas; primeiramente as classes urbano e área alagada foram definidas por meio de métodos supervisionados, em seguida os demais pixels foram determinados por meio de classificação não supervisionada (BONTEMPS et al., 2011). O GlobCover é composto por 22 classes de cobertura terrestre definidas com o sistema de classificação de cobertura da terra da Organização das Nações Unidas para Alimentação e Agricultura e tem Precisão Global de 67,5% (BONTEMPS et al., 2011).

Os produtos GlobeLand30 foram oferecidos às Nações Unidas pela Administração Nacional Chinesa de Topografia, Mapeamento e Geoinformação (*Chinese National Administration of Surveying, Mapping and Geoinformation* - NASG) e pertencem a um projeto para análise de dados de resolução fina (resolução espacial de 30m) (GREKOUSIS; MOUNTRAKIS; KAVOURAS, 2015). O GlobeLand30 desenvolvido com dados de 2010 foi produzido usando o método baseado em POK (*Pixel-Object-Knowledge-based*), uma combinação de classificação baseada em pixels e objetos, juntamente com a verificação manual (CHEN et al., 2015). O Produto distingue entre 10 classes de cobertura do solo e tem Precisão Global de 80,3% (CHEN et al., 2015).

O conjunto de dados GLCNMO (*Global Land Cover by National Mapping Organizations*) foi desenvolvido pelo *International Steering Committee for Global Mapping* (ISCGM) e possui três produtos de cobertura do solo, designados de versão 1, 2 e 3. A versão 3 tem resolução espacial de 500m, que é baseada em dados MODIS de reflectância ajustada (Função de Distribuição de Reflectância Bidirecional - FDRB) de 16 dias (MCD43A4) para 2013, e apresenta Precisão Global de 74,8% (KOBAYASHI et al., 2017). A classificação foi realizada através de métodos combinados; classificação supervisionada foi utilizada em quinze classes e classificações independentes foram realizadas para as cinco classes restantes (KOBAYASHI et al., 2017). Isto resultou em uma legenda de 20 classes, definidas sob o sistema de classificação de cobertura da terra da Organização das Nações Unidas para Alimentação e Agricultura (KOBAYASHI et al., 2017).

O conjunto de dados de cobertura do solo MODIS utiliza dados do sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*), a bordo dos satélites Aqua e Terra, e foi desenvolvido pela Universidade de Boston e é coordenado pela equipe da Administração

Nacional de Aeronáutica e Espaço (*National Aeronautics and Space Administration - NASA*) (GREKOUSIS; MOUNTRAKIS; KAVOURAS, 2015). A primeira versão do conjunto de dados foi desenvolvida para o ano de 2001 e, a partir de então, produtos foram gerados anualmente até 2013. O mapeamento MODIS-2013 foi produzido por meio de um algoritmo de classificação supervisionado baseado em árvore de decisão multitemporal (LP-DAAC, 2013). O produto final possui cinco esquemas de classificação, sendo o esquema primário de cobertura do solo fornecido pelo Programa Internacional de Geósfera-Biosfera (*International Geosphere-Biosphere Programme - IGBP*), composto por 17 classes e que atingiu Precisão Global de 74,8% (FRIEDL et al., 2010). O MODIS contém duas versões, MOD12Q1 (1 km) e MCD12Q1 (500 m), então foi escolhida a versão mais recente e de alta resolução, MCD12Q1.

Assim como o GlobCover, o CCI-LC (*Climate Change Initiative – Land Cover*) é um produto global de cobertura do solo desenvolvido pela Agência Espacial Europeia. O CCI-2015 faz parte da segunda fase de produtos de cobertura do solo desenvolvida pela CCI, sendo produzido com base em séries temporais do sensor *SPOT VEGETATION* e do PROBA-V (pequeno satélite para o monitoramento global da vegetação), gerando produtos globais de cobertura do solo com resolução de 300m (DEFOURNY et al., 2017). O processo de classificação deste produto é baseado em aprendizagem de máquina e algoritmos não supervisionados (ESA, 2017). O produto final conta com 22 classes de cobertura do solo definidas com base no Sistema de classificação de cobertura do solo da ONU (Organização das Nações Unidas) e tem Precisão Global de 71,1% (ESA, 2017).

Ambos os produtos globais de cobertura do solo foram obtidos gratuitamente e em formato GEOTIFF, re-projetados para o sistema de coordenadas geográficas SIRGAS-2000, re-escalados para 250m e cortados uniformemente através do perímetro da BHAPR. Como os produtos possuem legendas diferentes, uma legenda generalizada foi gerada para possibilitar a comparação entre eles (Tabela 11). Outros conjuntos de dados que compreendem a área de estudo não foram considerados nesta pesquisa por não estarem disponíveis ou devido ao dado disponibilizado não estar em formato GEOTIFF, caso, por exemplo, dos dados de uso e ocupação do solo do Instituto Brasileiro de Geografia e Estatística (IBGE), que estão disponíveis em formato vetorial. O FROM-GLC não foi considerado, pois é produzido com base em milhares de imagens Landsat durante o período de 1981 a 2011, assim, não é apropriado compará-lo com outros produtos em determinado ano.

Tabela 11 – Relação entre as classes geradas neste trabalho e classes de uso e ocupação do solo em escala global.

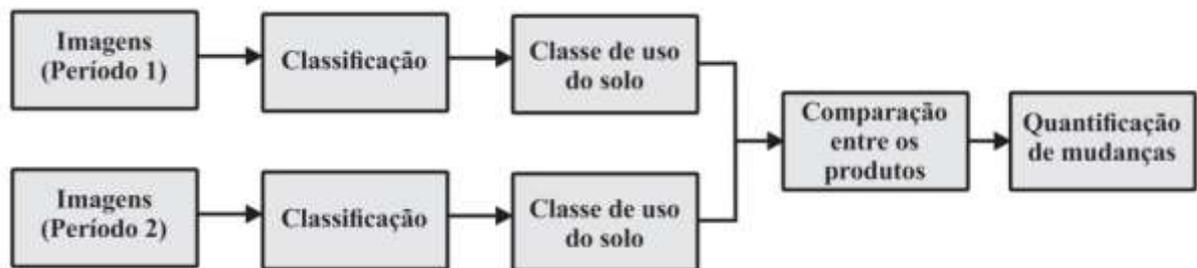
BHAPR 2015	MODIS-IGBP	GlobCover	Globeland30	GLCNMO	CCI
Floresta (10)	1, 2, 3, 4, 5	40, 50, 60, 70, 90, 100	20	1, 2, 3, 4, 5	50, 60, 70, 80, 90
Agricultura (20)	12, 14	11, 14, 20, 30	10	11, 12, 13	10, 20, 30, 40
Pastagem (30)	10	120, 140, 150	30	8	130
Água (40)	0	210	60	20	210
Urbano (50)	13	190	80	18	190
Solo exposto (60)	16	200	90	16, 17	150, 200
Cerrado/vegetação arbustiva (70)	6, 7, 8, 9	110, 130	40	6, 7, 9	100, 110, 120

Baseado em: Friedl et al. (2010), Capucim et al. (2015), Liang et al. (2015) e Yang et al. (2017).

4.4 DETECÇÃO DE MUDANÇAS

A abordagem utilizada para a detecção de alterações na cobertura do solo segue o esquema descrito no fluxograma da Figura 9, onde foi aplicada uma análise bi-temporal de mudança (Coppinet al., 2004). Neste sentido, as mudanças foram quantificadas através de contraste temático (classe) pós-classificação, metodologia amplamente utilizada em mapeamentos de grande área (HANSEN; LOVELAND, 2012).

Figura 9 – Metodologia aplicada à detecção de alterações de uso e ocupação do solo.



5 RESULTADOS E DISCUSSÕES

Para uma melhor organização da apresentação e discussão dos resultados, a Bacia Hidrográfica do Alto Rio Paraná (BHAPR) foi dividida em sub-bacias. A conveniência das sub-bacias leva em conta o tamanho, bem como a distribuição espacial no contexto físico da bacia, em particular a topografia e os tipos/subtipos climáticos. Considere-se ainda o fato de que esta dissertação se contextualiza como parte de uma abordagem mais ampla, que procura entender o comportamento das mudanças ocorridas ao longo das últimas décadas na BHAPR, na sua integralidade, mas a partir das contribuições individuais de suas sub-bacias.

A divisão por sub-bacias, apresentada na Figura 10, com cada sub-bacia (ou parte dela) recebendo um número de identificação, será usada nas seções deste capítulo. Não se pretende que o número substitua os nomes das sub-bacias ao longo do texto, mas apenas que facilite a localização pelo leitor de que parte da BHAPR a discussão se refere. Além disso, os produtos de cobertura do solo desenvolvidos serão, a partir daqui, nomeados de BHAPR-1985 e BHAPR-2015, referindo-se aos produtos gerados para o ano de 1985 e 2015, respectivamente, conforme metodologia apresentada. A estrutura deste Capítulo de resultados apresenta-se sequencialmente distribuída em três eixos temáticos: i) o produto e sua qualidade; ii) a análise comparativa com produtos existentes e; iii) avaliação das mudanças ocorridas no período de estudo.



1. Confluência entre os rios Grande e Paranaíba	13. Paraná, Feio ou Aguapeí	25. Rio Ivaí
2. Alto Iguaçu	14. Paraná, Guaçu, São Francisco Verdadeiro e outros	26. Rio Mogi-Guaçu
3. Alto Parapanema	15. Paraná, Iguatemi, Maracá, Amambai	27. Rio Pardo
4. Baixo rio Grande	16. Paraná, Laranjal e outros	28. Rio Paranaíba
5. Alto Tietê	17. Paraná, Meia Ponte	29. Rio Piquiri
6. Baixo Iguaçu	18. Paraná, Peixe e outros	30. Rio São Bartolomeu
7. Baixo Parapanema	19. Paraná, Preto	31. Rio Sapucaí
8. Alto rio Grande	20. Paraná, Quitéria, São José dos Dourados	32. Rio Sucuriú
9. Baixo Tietê	21. Rio Araguari ou das Velhas	33. Rio Tibagi
10. Médio rio Grande	22. Rio Claro	34. Rio Tijuco
11. Paraná, Samambaia e outros	23. Rio dos Bois	35. Rio Verde
12. Paraná, Aporé ou do Peixe, Corrente, Verde	24. Rio Invinheima	

Figura 10 – Delimitação das sub-bacias da BHAPR consideradas neste estudo.

5.1 MAPEAMENTO DA COBERTURA DO SOLO PARA A BHAPR

Conforme metodologia apresentada para esta pesquisa, foram mapeadas, através da interpretação visual e classificação de imagens, sete classes de cobertura do solo, sendo elas: Floresta, Agricultura, Pastagem, Água, Urbano, Solo exposto e Cerrado/vegetação arbustiva. Foram identificadas ainda três outras classes transitórias que impedem, no momento de captura da cena, a identificação da classe prevalente. Os produtos obtidos deste mapeamento, denominados cobertura do solo BHAPR-1985 e BHAPR-2015, serão apresentados na sequência.

5.1.1 Mapeamento da cobertura do solo para o ano de 1985

Para o mapeamento BHAPR-1985, as classes Agricultura e Pastagem foram identificadas como as classes dominantes e juntas cobrem mais da metade da área de estudo, aproximadamente 27,8% (249.765 km²) e 30,3% (272.236 km²), respectivamente (Figura 11). A classe Agricultura predomina nas áreas da porção sul da BHAPR, em particular na faixa que cobre a margem esquerda do lago de Itaipú, Baixo Iguaçu (6) e Rio Piquiri (29), prolongando-se por um eixo a nordeste que corta o Médio Ivaí (25), Baixo Tibagi (33) e Médio Paranapanema (3). Já a partir do Médio Paranapanema observa-se predominância de áreas agrícolas em uma faixa em direção ao norte da bacia que cobre o Alto Tietê (5), Mogi-Guaçu (26) e Médio Rio Grande (10). Duas outras manchas expressivas de áreas agrícolas são observadas ao norte, na sub-bacia do Rio dos Bois (23), microrregião do Meia Ponte (17) e áreas adjacentes dos rios Araguari (21) e Tijuco (34) e em uma faixa a sudoeste da BHAPR, nas cabeceiras dos rios Ivinhema (15) e Iguatemi, Maracaí e Amambaí (24). A classe Pastagem é observada predominantemente nas porções mais baixas de todas as sub-bacias da margem esquerda entre os rios Piquiri (29) e Baixo Rio Grande (4). Também são observadas áreas de pastagem nos tributários da margem direita, porém distribuídas de maneira mais fragmentada entre outras classes de cobertura, em especial nas sub-bacias Paraná – Iguatemi, Maracaí e Amambaí (15), Ivinhema (24), Paraná - Aporé ou do Peixe, Corrente e Verde (12), Paraná – Preto (19), Claro (22) e Tijuco (34).

Como terceira classe mais expressiva da BHAPR aparece o mosaico formado por Cerrado/vegetação arbustiva, que pode conter fragmentos de agricultura e pastagem, mas não de forma dominante na área. Esta classe representa 21,7% da área da BHAPR (195.067 km²), podendo ser encontrada principalmente na margem direita e norte da bacia, locais de prevalência do bioma Cerrado (MMA, 2007b). Na margem direita destaca-se ocorrência predominante nas cabeceiras dos rios Pardo (27), Sucuriú (32), Verde (35) e Paraná - Corrente, Aporé ou do Peixe (12). Ao norte da bacia a classe predomina nas sub-bacias dos rios Araguari ou das Velhas (21), Parnaíba (28) e São Bartolomeu (30).

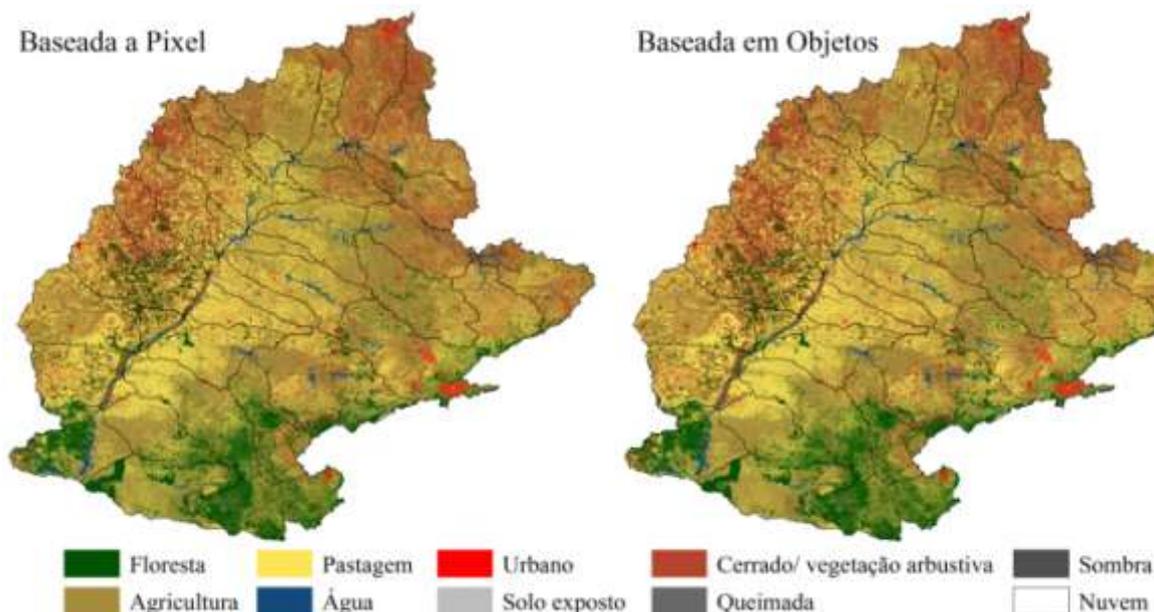


Figura 11 – Classificação da cobertura do solo baseada a pixel e em objetos para 1985.

Áreas de Floresta somam 16,4% (147.863 km²) da cobertura total da BHAPR e são caracterizadas principalmente por remanescentes do bioma Floresta Atlântica, ao sul e, em menor escala de ocorrência, em fragmentos nas cabeceiras dos rios da margem esquerda. Destaca-se ocorrência predominante em áreas mais elevadas das sub-bacias Guaçu, São Francisco Verdadeiro (14), Iguaçu (6), Piquiri (29), Ivaí (25), Tibagi (33) e Alto Paranapanema (3). Também são observados alguns fragmentos nas sub-bacias dos rios Pardo (27) e Verde (35), na margem direita.

As demais classes com alguma participação representativa são Água e Urbano, com cerca de 1,6% (13.922 km²) e 0,9% (8.356 km²) da área de estudo, respectivamente. A classe Água se mostra evidente ao longo da calha principal e afluentes da margem esquerda do Médio e Alto Paraná, com destaque para os rios Paranapanema (3, 7), Tietê (5, 9), Rio Grande (4, 8, 10, 23) e Paranaíba (17, 28). Nestas sub-bacias os espelhos d'água são evidentes devido a barramentos para geração de energia hidroelétrica. Já o tipo urbano é predominante nas cabeceiras dos principais afluentes da margem esquerda, com destaque para o Alto Iguaçu (2) e Alto Tietê (5), onde se localizam as regiões metropolitanas de Curitiba e São Paulo, respectivamente. Observa-se ainda a presença da classe Urbano ao norte da BHAPR, com destaque para o rio São Bartolomeu (30), onde se localiza Brasília. As demais classes identificadas na classificação somam 1,3% da área em estudo.

5.1.2 Mapeamento da cobertura do solo para o ano de 2015

Para o ano de 2015 (mapeamento BHAPR-2015), Agricultura e Pastagem continuam sendo as classes majoritárias, tal como observado para BHAPR-1985 (Figura 12). Todavia, a participação da classe Agricultura aumentou significativamente em comparação a 1985, passando a representar 46,0% (413.623 km²) da área de estudo, enquanto se observa uma pequena redução na classe Pastagem, que passa a cobrir 25,6% (230.348 km²) da área da BHAPR. Os eixos de ocupação de ambas as classes não se deslocam de forma significativa em relação a 1985, mas há mudanças que merecem ser consideradas. Observa-se um alargamento das áreas de Agricultura em direção à calha principal do rio Paraná, particularmente para as sub-bacias do Piquiri (29), Ivaí (25) Iguaçu (6) e Paranapanema (7), Tietê (9) e Grande (4), além de sub-bacias intermediárias entre os dois últimos. A classe Agricultura avança também em direção às cabeceiras dos rios Ivaí (25), Piquiri (29) e Paranapanema (3), além de Guaçu/São Francisco (14). Na margem direita observa-se presença expressiva nas sub-bacias Paraná – Iguatemi, Maracaí e Amambaí (15) e cabeceira do Ivinhema (24).

Áreas ocupadas pela classe Floresta aparecem como terceira maior participação, após Agricultura e Pastagem. Estão dispostas em 20,1% (180.504 km²) da área de estudo, sendo mais evidentes ao sul e sudeste da bacia. Nesta porção da BHAPR, destaca-se ocorrência predominante em áreas mais elevadas das sub-bacias, tal como observado para o mapeamento de 1985, porém, com redução na área de ocorrência para as sub-bacias Iguaçu (6), Piquiri (29), Ivaí (25) e Tibagi (33). Para a margem direita observa-se distribuição bastante fragmentada para as sub-bacias Paraná - Guaçu, São Francisco Verdadeiro (14), Pardo (27), Sucuriú (32) e Verde (35). Observa-se ainda a ocorrência generalizada de pequenos fragmentos, exceto para a porção mais central.

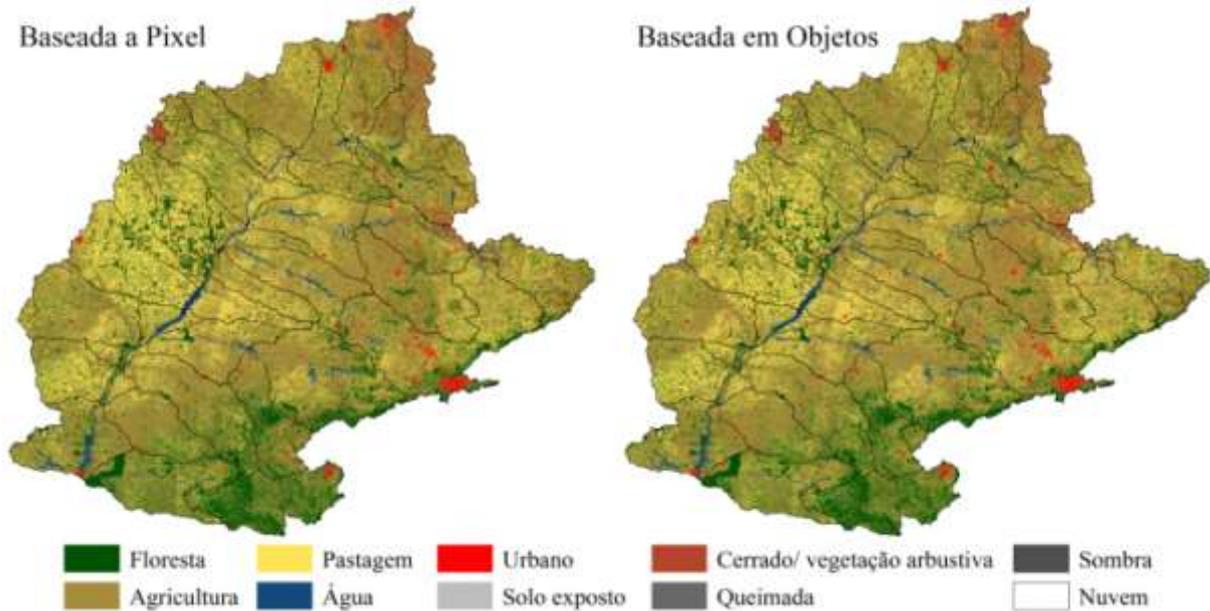


Figura 12 – Classificação da cobertura do solo baseada a pixel e em objetos para 2015.

A classe Cerrado/vegetação arbustiva, que em 1985 era a terceira classe mais expressiva da BHAPR, cobrindo mais de um quinto da área, cai acentuadamente para 45.125 km² (5,0% da BHAPR). Esta classe, que no mapeamento de 1985 é praticamente dominante sobre extensas áreas, tanto na margem direita quanto ao norte da bacia, no produto de 2015 se destaca apenas nas cabeceiras das sub-bacias Parnaíba (28) e São Bartolomeu (30), além de unidades de proteção ambiental, com destaque para o Parque Nacional da Serra da Canastra (entre as sub-bacias 10 e 21) e o Parque nacional das Emas (localizado na sub-bacia 12). A classe praticamente não aparece na margem direita da BHAPR, para as sub-bacias ao sul do Rio Grande (Figura 12).

Áreas cobertas pela classe Água aumentaram em relação ao mapeamento de 1985 e correspondem a 1,8% (16.430 km²) em 2015. Embora a participação seja pequena quando comparada às demais classes majoritárias, ressalta-se o tipo particularmente predominante de áreas alagadas, em geral associado a reservatórios de hidrelétricas, como observado para 1985. A classe Urbano também representa pouca participação no total da área da BHAPR. A participação desta classe também aumentou, saltando para 1,1% da área da BHAPR (10.266 km²). A presença da classe está associada às áreas urbanas predominantes nas cabeceiras dos principais afluentes da margem esquerda, conforme observado para o mapeamento de 1985, mas também se observa a presença em localidades interioranas, com destaque para Goiânia e os eixos paranaenses Londrina – Maringá e Cascavel – Foz do Iguaçu. As demais classes somam 0,3% da área total da bacia.

5.1.3 Avaliação dos métodos de classificação e acurácia

Quanto aos métodos de classificação aplicados, Baseada em Pixel (BP) e Baseada em Objeto (BO), não se observou divergência significativa, tanto visual quanto por área, para ambos os mapeamentos (Figura 13). Os produtos apresentaram valores de acurácia muito próximos entre si para 1985 - Precisão Global de 0,62 para BP e 0,63 para BO. As áreas associadas às classes de Floresta e Agricultura apresentam uma pequena diferença positiva para a classificação BP em relação a BO para o mapeamento de 1985, enquanto que o oposto se observa para as classes de Pastagem e Cerrado/Vegetação arbustiva. Para 2015 observa-se que houve melhora nos valores de acurácia - Precisão Global de 0,80 para BP e 0,78 para BO. A classificação BP apresentou uma área menor para a classe Agricultura, oposto ao que foi observado no mapeamento de 1985.

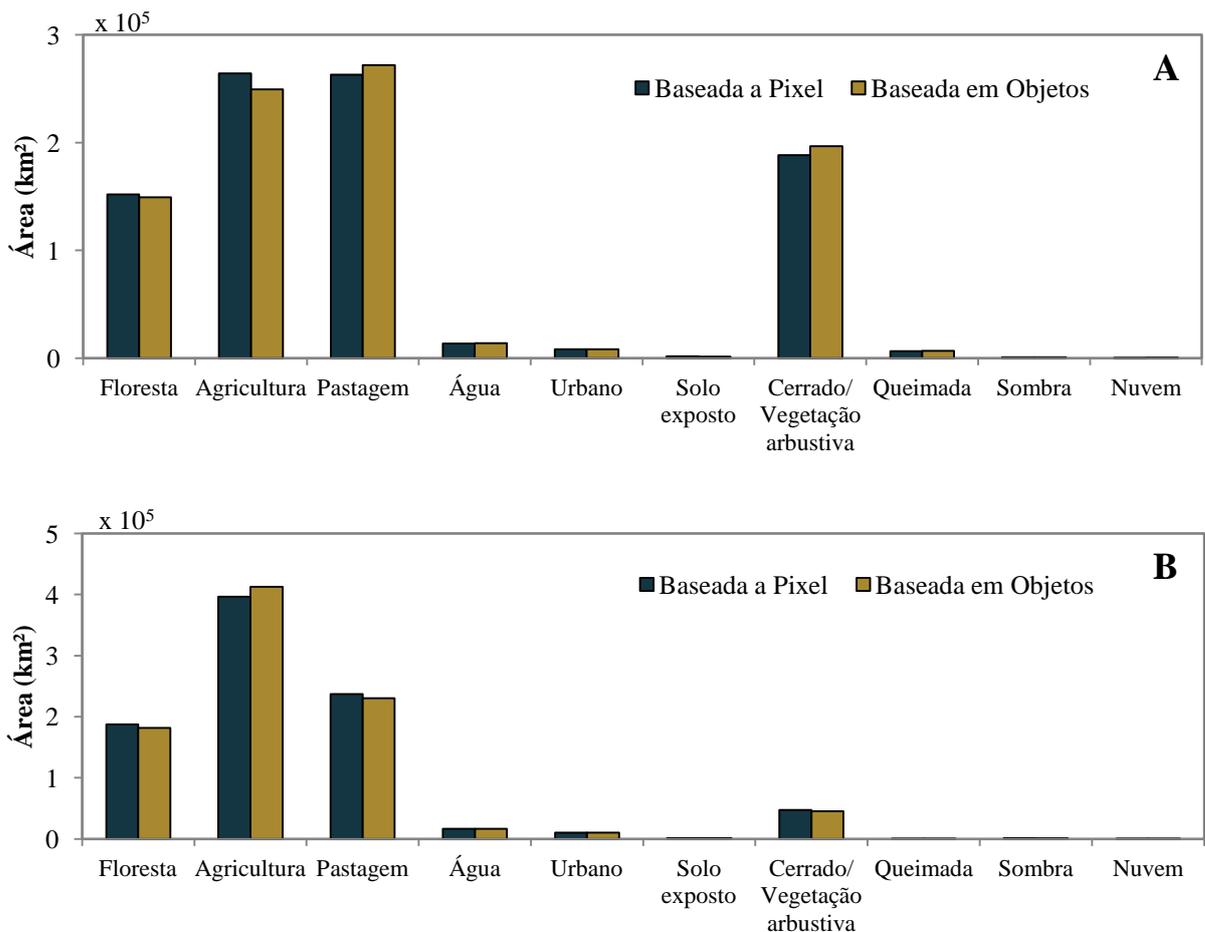


Figura 13 – Área das classes de cobertura do solo para os anos de 1985 (A) e 2015 (B).

Algumas considerações sobre como a quantidade de classes afeta os resultados da acurácia devem ser feitas aqui. Primeiramente, para facilitar o entendimento da distribuição espacial da acurácia, os índices de precisão (Precisão Global e Kappa) foram calculados para as sub-bacias (Apêndice 7). As matrizes de confusão, conteúdo acurácia do produtor (AP) e do usuário (AU), para os mapeamentos BHAPR-1985 e BHAPR-20015, são apresentadas nos Apêndices de 3 a 6.

Para o ano de 1985, o produto de cobertura do solo BO obteve valores de Precisão Global e Índice Kappa mais altos do que o BP (Tabela 12). Como resultado, foi observado um aumento na acurácia das classes mapeadas para o método BO, com destaque para a classe transitória Queimada, que teve um aumento de 6% na AU. Aqui observa-se um efeito conhecido na literatura como “salt-and-pepper”, comum às classificações BP de imagens de resolução espacial fina. Pixels individuais são classificados de forma diferente da área circundante, dificultando a geração de regiões homogêneas (BLASCHKE et al., 2000). Este efeito pode ter relação com a menor acurácia observada para o produto BP, tal como sugerido por Liu e Xia (2010).

Tabela 12 – Precisão Global e Índice Kappa para os produtos de cobertura do solo.

Método de classificação	1985		2015	
	Precisão Global	Kappa	Precisão Global	Kappa
Baseada a Pixel	0,62	0,52	0,80	0,73
Baseada em Objetos	0,63	0,53	0,78	0,70

Por outro lado, a classificação BP obteve maiores valores de acurácia global e Índice Kappa para o ano de 2015. Aumentos na AU estão associados principalmente às classes Água e Cerrado/vegetação arbustiva, onde foram observados ganhos de 11 e 17%, respectivamente. Distribuição heterogênea das classes Pastagem, Agricultura e Cerrado/vegetação, juntamente com características espectrais semelhantes das mesmas, podem estar relacionadas à dificuldade de representação do classificador BO. Uma vez que o método generaliza a informação espectral de pixels vizinhos, o processo de classificação pode incorporar pixels de classes diferentes em um único segmento (WANG; SOUSA; GONG, 2004).

Quanto aos valores de Índice Kappa, Yu et al. (2014) mostram que há uma relação inversa entre o tamanho da área de estudo e a acurácia do mapeamento. Esta relação também é observada em mapeamentos de cobertura do solo realizados anteriormente sobre regiões da América do Sul, como pode ser observado na Tabela 13.

Tabela 13 – Valores de Precisão Global (PG) e Índice Kappa para mapeamentos de cobertura do solo realizados no Brasil.

Região estudada	Área (km ² x10 ³)	Qnt. de classes	Tipo de classificador	PG	Kappa	Referência
América do Sul	17800	4	BP	0,98	0,79	Giri e Long (2014)
Amazônia Legal	5200	6	BO	0,77	0,67	Almeida et al. (2016)
Bioma Cerrado	2059	10	BO	0,70	0,68	MMA (2007b)
Bioma Cerrado	2047	6	BO	0,71	-	Sano et al. (2010)
Sudeste da Amazônia brasileira	387	15	BO	0,60	-	Walker et al. (2010)
		10		0,72		
		7		0,90		
		6		0,93		
		2		0,95		
Paraná	199,3	1	BP	2008 – 0,93	2008 – 0,77	Araújo et al. (2011)
				2007 – 0,91	2007 – 0,75	
				2006 – 0,91	2006 – 0,70	
Sudeste do Mato Grosso	15,55	3	BO	2005 – 0,86	2005 – 0,79	Grecchi et al. (2013)
				1995 – 0,80	1995 – 0,69	

Nota: BP – Baseado a Pixel; BO – Baseado em objetos; PG - Precisão Global.

Outro fator que interfere nos valores de acurácia refere-se à quantidade de classes de cobertura do solo utilizadas no mapeamento (YU et al., 2014a; MA et al., 2017). Walker et al. (2010) estudaram uma região no sudeste da Amazônia brasileira e verificaram aumentos na acurácia do produto quando classes similares foram aglomeradas; Precisão Global de 0,6 aumentou para 0,95 quando o número de classes passou de 15 para 2. Outro exemplo claro da melhora da acurácia pela generalização de classes é dada por Grecchi et al. (2013), que relatou um aumento de 0,79 para 0,87 no Índice Kappa quando as classes Agricultura e Pastagem foram agregadas. Quando esta abordagem é aplicada no presente estudo, os valores do Índice Kappa das classificações BP e BO passam de 0,52 e 0,53 para 0,6 e 0,61, respectivamente, no mapeamento BHAPR-1985. Para o produto BHAPR-2015, os valores do Índice Kappa passam de 0,7 e 0,73 para 0,85 e 0,87, respectivamente associados a BP e BO.

Espacialmente é possível observar baixo valor de acurácia para as sub-bacias Alto Rio Grande (8) e Rio Araguari (21) no produto BHAPR-1985, apresentando valores de Kappa de 0,1 e 0,2, respectivamente. O mapeamento é dificultado em locais onde as classes Cerrado, Agricultura e Pastagem se encontram distribuídas em terrenos com alta rugosidade. A Figura 14 apresenta os Índices Kappa para a BHAPR (maiores valores de Kappa por sub-bacia, extraídos do Apêndice 7). É possível observar valores de acurácia mais elevados ao sul e menores ao nordeste da bacia para o produto BHAPR-1985. Para o ano de 2015, apenas as sub-bacias 11, 12, 22 e 25 apresentaram níveis Kappa moderados (Kappa entre 0,4 e 0,6). A grande maioria das sub-bacias apresentou concordâncias boas (0,6-0,8) ou muito boas (0,8-1).

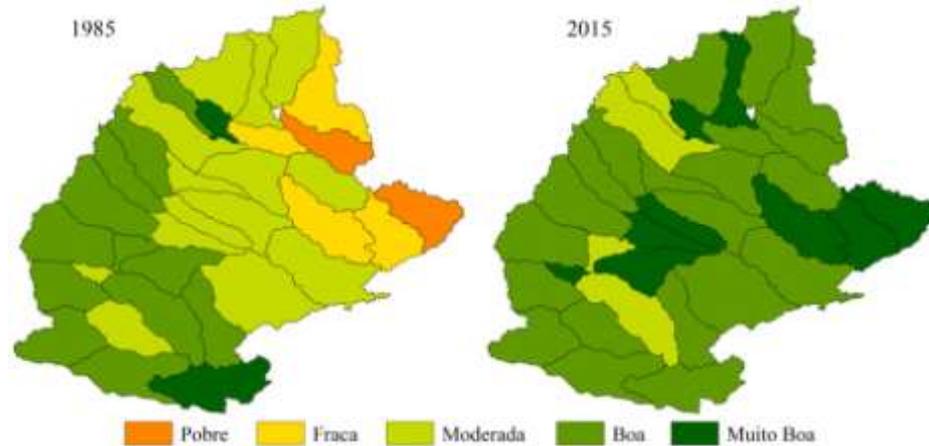


Figura 14 – Concordância dos produtos por sub-bacia, considerando-se os intervalos descritos na tabela 9.

Embora ambos os métodos de classificação (BP e BO) gerem produtos de cobertura do solo com indicadores de qualidade muito próximos, a metodologia baseada em objetos parece eliminar o efeito "*sal-and-pepper*", através da segmentação de pixels. Isso contribui para aumentar a acurácia dos mapeamentos, embora possa não ocorrer em alguns casos específicos, como observado por Phiri e Morgenroth (2017). Em alguns casos, a redução nos valores da classificação BO pode estar associada a falhas nos métodos de coleta de amostras de validação. Whiteside, Boggs e Maier (2011) indicam que, ao usar o método de avaliação de precisão "tradicional" (baseado em pontos) a precisão espacial dos objetos classificados não é considerada, uma vez que o método avalia pixels em uma classificação baseada em pixels e pontos específicos dentro dos objetos em uma classificação baseada em objetos.

5.2 COMPARAÇÃO ENTRE BHAPR-2015 E OUTROS PRODUTOS

Embora cada mapeamento da cobertura do solo tenha suas especificidades, o produto em todos os casos é uma caracterização do que efetivamente cobre (ou não) a superfície da Terra. Portanto, exceto por alguma diferença temporal razoável entre produtos, eles devem ser minimamente comparáveis em suas classes. Considerando que a maioria dos produtos disponíveis para a BHAPR são recentes, o mapeamento BHAPR-2015 será considerado na comparação com outros mapeamentos disponíveis na literatura, cujas bases de dados são de livre acesso. Primeiramente o produto BHAPR-2015 foi comparado aos totais de área obtidos dos dados globais MODIS (FRIEDL et al., 2010), GlobCover (SOPHIE; PIERRE; ERIC, 2010), Globeland30 (CHEN et al., 2015), GLCNMO (TATEISHI et al., 2014) e CCI (KIRCHES et al., 2016) (Valores de área descritos no Apêndice 8). A Figura 15 apresenta os

conjuntos de dados re-mapeados para a legenda adotada no mapeamento BHAPR-2015. A comparação por área foi separada de acordo com as seguintes classes de cobertura do solo generalizadas: Floresta, Agricultura, Pastagem, Água, Urbano, Cerrado/Vegetação arbustiva e Solo exposto.

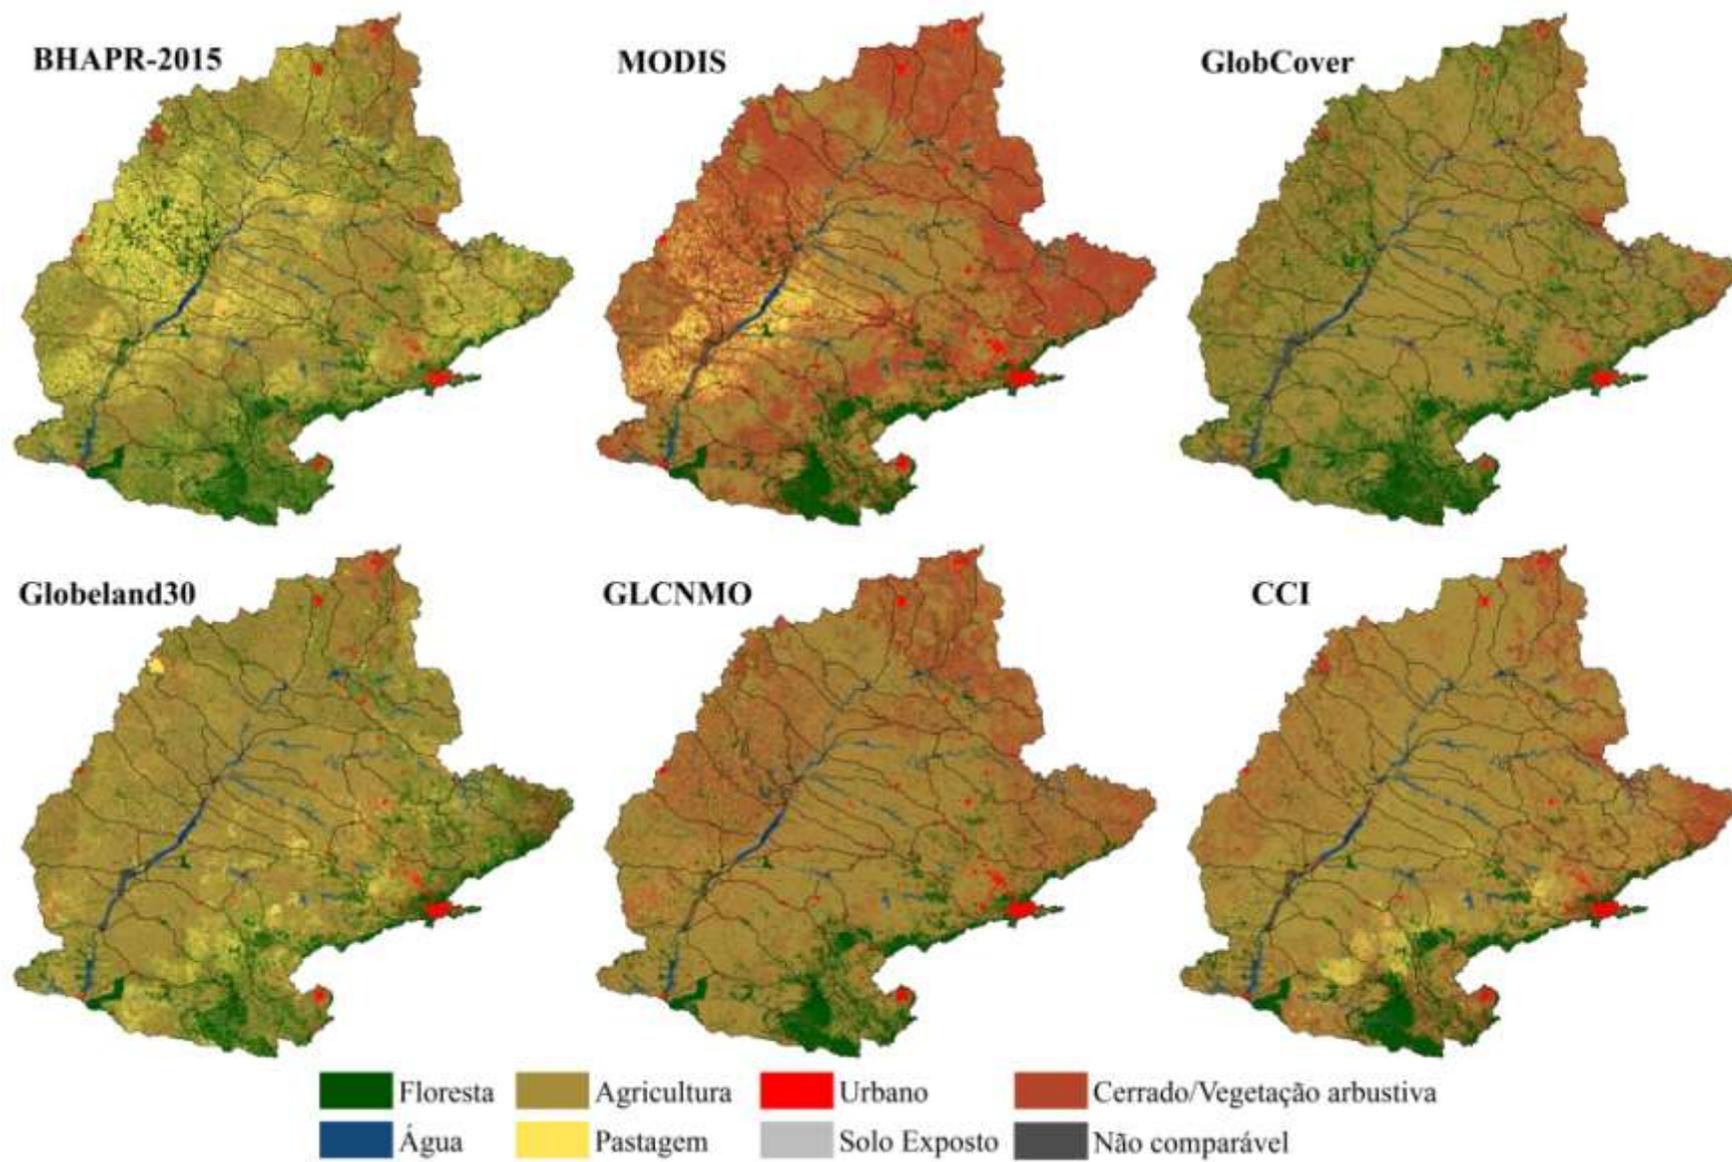


Figura 15 – Produtos de cobertura do solo com legenda generalizada através da Tabela 11.

5.2.1 Floresta

Todos os produtos mostram Floresta como uma classe representativa para a região de estudo, variando entre 9 e 20% da área total da Bacia, dependendo do produto. Os valores da área coberta por floresta encontrados para o produto BHAPR-2015 são mais próximos do produto GlobCover, cobrindo 20,1% e 19,1%, respectivamente. Ambos apresentaram os maiores valores de participação da classe Floresta. O produto Globeland 30 apresenta a terceira maior área para a classe (17,1%), entretanto, observa-se que, em relação a BHAPR-2015, o mapeamento subestima áreas de floresta na margem direita e ao sul da BHAPR e superestima a leste. Os produtos MODIS e CCI apresentaram os menores valores de área para a classe Floresta, com 8,7% e 8,8%, respectivamente. As regiões onde se observa alguma concordância entre os produtos estão localizadas ao sul e sudeste da BHAPR.

Diferenças entre áreas cobertas pela classe Floresta também foram observadas em estudos semelhantes, podendo ser ainda maiores quando as classes florestais não são agregadas (PÉREZ-HOYOS; GARCÍA-HARO; SAN-MIGUEL-AYANZ, 2012; CAPUCIM et al., 2015; YANG et al., 2017). Por exemplo, Capucim et al. (2015) estudaram as classes de cobertura do solo dos produtos MODIS e GlobCover para a América do Sul e encontraram diferenças expressivas nas classes florestais para todos os estados localizados na BHAPR. Os autores identificaram que no Paraná (porção sul da BHAPR) as frações de cobertura da classe Floresta eram muito próximas entre MODIS e GlobCover. Por outro lado, nos estados de Goiás e Mato Grosso do Sul, ambos com partes significativas de suas áreas dentro da BHAPR, a participação da classe Floresta era praticamente nula para o produto MODIS, enquanto que representava cerca de 17% para o produto GlobCover.

5.2.2 Agricultura

A Agricultura é a classe de cobertura do solo dominante na BHAPR, exceto para o produto MODIS. Os valores de participação da classe em cada mapeamento são: GlobCover (71,2%), CCI (67,8%), Globeland30 (59,2%), GLCNMO (57,0%) e MODIS (33,8%). Em nenhum dos produtos a fração de cobertura se compara ao mapeamento apresentado neste estudo (46,0%). De qualquer forma, é possível perceber algum exagero nos produtos que indicam fração majoritária da BHAPR para a classe Agricultura (GlobCover e CCI), assim como para o MODIS, que subestimou a classe. Dada a grande diferença, a discordância é

generalizada na bacia e não há como apontar regiões de convergência entre BHAPR-2015 e esses três produtos.

O produto Globeland30 é o que oferece uma melhor concordância com BHAPR-2015 para a classe Agricultura. Em relação a estudos prévios, Pérez-Hoyos et al. (2017) compararam 9 conjuntos de cobertura do solo globais para monitoramento de terras cultivadas, verificando a maior acurácia do produto Globeland30 para alguns países da América do Sul (Precisão Global de 0,8), incluindo o Brasil. Os autores também compararam os dados globais com estatísticas da Organização das Nações Unidas para Alimentação e Agricultura (*Food and Agriculture Organization - FAO*), no qual o produto GLCNMO se mostrou mais representativo, enquanto que o produto Globcover, além de baixa acurácia, superestimou a participação da classe Agricultura.

Embora o Produto Globeland30 tenha sido caracterizado como um bom indicador de agricultura por Pérez-Hoyos et al. (2017), comparações com o conjunto de dados TerraClass sobre a Amazônia brasileira indicam que a classe Agricultura no produto GlobeLand30 inclui quantidades notáveis de pastagem (PENDRILL; MARTIN PERSSON, 2017).

Em relação à percepção de que há certo exagero nas estimativas de alguns mapeamentos disponíveis, em particular para GlobCover e CCI, deve-se considerar o fato de que as estimativas para áreas agrícolas no Brasil apontam para cerca de 600.000 km² (FAO, 2016), o que corresponde a cerca de 2/3 da área da BHAPR. Portanto, os percentuais associados aos produtos GlobCover e CCI indicam que há mais áreas agrícolas dentro da BHAPR do que no Brasil como um todo, o que é incoerente. A BHAPR é reconhecida pela forte presença de atividades agrícolas, mas ela representa pouco mais de 10% do território brasileiro e muito provavelmente não concentra mais do que 50% das áreas agrícolas do país.

5.2.3 Pastagem

O produto BHAPR-2015 apresentou o maior valor de área para a classe Pastagem (25,6%), seguido dos produtos Globeland30 (12,9%) e MODIS (7,8%). Os demais produtos apresentaram valores muito baixos de pastagem, CCI (4,1%), GLCNMO (2,9) e GlobCover (0,0008%). Considerando que a Bacia é também reconhecida por seu grande potencial pecuário (SRH/MMA, 2006), é razoável considerar que os produtos com participação minoritárias devem estar subestimando a participação da classe Pastagem.

O produto de pastagem disponibilizado pelo LAPIG (MALAQUIAS et al., 2017) indica que 30% da área total da bacia corresponde a pastagem, valor relativamente próximo

ao encontrado pelo produto BHAPR-2015. As áreas de pastagem tanto no produto BHAPR-2015 (Figura 15), quanto no produto disponibilizado pelo LAPIG são mais evidentes nas áreas do Bioma Cerrado (margem direita da bacia). O bioma é caracterizado como uma região heterogênea contendo manchas de florestas, arbustos, pastagens e terras agrícolas mescladas (YU et al., 2014a), o que explicaria a subestimação dos produtos devido ao mapeamento complexo.

5.2.4 Água

Embora represente participação minoritária, não se observou diferenças expressivas entre os produtos para a classe Água. Os resultados do mapeamento proposto neste trabalho (BHAPR-2015) apontam para 1,8 % da área, valor comparável aos produtos Globeland30 (2%) e CCI (1,9%), que apresentaram os maiores valores da classe, seguidos por GlobCover (1,6%) e GLCNMO (1,3%). Entretanto, o produto MODIS apresentou a menor contribuição para a classe Água, com apenas 0,9% da área. Como esperado, produtos de baixa resolução tiveram maior dificuldade para o mapeamento da classe Água, muito provavelmente pela dificuldade em reconhecer áreas de pequena extensão. O produto CCI apresentou altos valores para a classe água, mesmo com resolução espacial de 300m, isto se deve a utilização de dados ASAR⁶, com resolução de 150 m, para o mapeamento da classe água ao invés de imagens com base em sensores ópticos (YANG et al., 2017).

5.2.5 Urbano

O mapeamento BHAPR-2015, com 10.265km² de áreas urbanizadas, pouco mais de 1% da área da bacia, ficou próximo dos valores dos produtos CCI (9.483km²) e Globeland30 (12.000km²). O produto MODIS apresentou o maior valor de área para a classe Urbano (17.160km²), enquanto o GlobCover apresentou o valor mais baixo (2.130km²). Os baixos valores de área da classe Urbano para o produto GlobCover também foram observados por Potere et al., (2009), que identificaram altas taxas de omissão do produto. Capucim et al. (2015) mostra que enquanto as áreas urbanas são identificadas para a quase totalidade dos municípios da sub-bacia do Ivaí (25) no produto MODIS, o GlobCover é praticamente incapaz de identificar a presença da classe na sub-bacia.

⁶ Advanced Synthetic Aperture Radar (ASAR) é o sensor a bordo do satélite ENVISAT, que gera séries temporais da intensidade de retrodifusão em resolução espacial de 150m (ESA, 2014).

Os métodos empregados para extração da área urbana são diferentes entre os mapas. Por exemplo, os produtos MODIS e CCI utilizam a classe urbano desenvolvida em estudos distintos, Schneider, Friedl e Potere (2009) e Schneider, Friedl e Potere (2010), respectivamente. Os produtos foram gerados com dados coletados entre 2001 e 2002, o que pode explicar os valores um pouco abaixo para o CCI em relação a BHAPR-2015, mas reforça o fato de que o produto MODIS pode estar superestimando a área coberta pela classe Urbano. Esta possibilidade de superestimação também é observada nos trabalhos de Potere et al., (2009) e (Klotz) et al. (2016).

5.2.6 Solo exposto

De forma geral, a classe Solo exposto não foi representativa para a região em estudo. Dos produtos analisados, Globeland30 (490km²) foi o que apresentou a maior área, bastante inferior aos cerca de 1.000km² identificados no mapeamento BHAPR-2015. É importante considerar que as áreas com solo exposto mudam ao longo do tempo e do espaço com alta frequência. Neste sentido, variação expressiva entre os produtos pode ser esperada para esta classe.

5.2.7 Cerrado/Vegetação arbustiva

A classe Cerrado, com 45.125km², representa cerca de 5% da área da bacia na classificação BHAPR-2015 e foi a que apresentou as maiores divergências em relação aos produtos existentes. O produto MODIS chega a ser 10 vezes maior que o produto BHAPR-2015, que apresentou os menores valores da classe. Outros produtos, como o GLCNMO e o CCI, também apresentam contribuição elevada para a classe.

O mapeamento de áreas de cerrado brasileiro tem grandes divergências devido à complexidade de mapeamento (MÜLLER et al., 2015). Além da modificação constante da vegetação natural, semelhanças espectrais entre agricultura, pastagem e cerrado complicam a diferenciação do tipo de cobertura do solo do Cerrado brasileiro (SANO et al., 2010; GRECCHI et al., 2013). Todavia, as informações econômicas existentes para a BHAPR indicam que a presença da cobertura original do Cerrado é muito pequena nos dias atuais, sugerindo que a participação da classe nos valores encontrados no produto MODIS podem de fato estar superestimados.

A Figura 16 mostra a comparação da área total dos 5 conjuntos de dados agregados e comparados com o produto BHAPR-2015, conforme discutido nas seções anteriores. Os variados níveis de concordância apresentados na discussão ficam evidentes na figura e facilitam o entendimento, não apenas da variabilidade entre produtos, mas também da participação de cada classe na BHAPR.

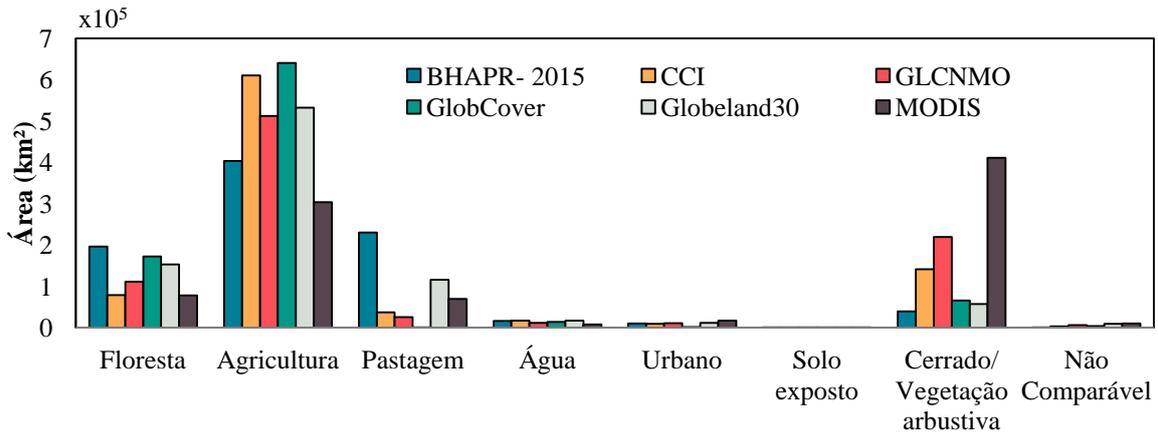


Figura 16 - Comparação de áreas entre e produtos de cobertura do solo para a BHARP.

5.2.8 Avaliação espacial comparativa

A avaliação espacial foi feita através da comparação por pixel. A Figura 17 mostra as áreas de concordância entre os diferentes produtos de cobertura do solo considerados para efeito de comparação, incluindo o próprio mapeamento produzido neste trabalho. Concordância entre os seis mapeamentos foi observada em apenas 18% da área de estudo. Se o número de mapeamentos é reduzido para cinco, o nível de concordância sobe para 35,5% da área de estudo. Não surpreendentemente, regiões de floresta e agricultura tiveram uma maior concordância, em consonância com o que se observa na Figura 15. É possível observar na Figura 17 que há um eixo central de concordância total, de sudoeste para nordeste e que depois vira a noroeste, identificando áreas de intensa atividade agrícola, como demonstrado no estudo de Araújo et al. (2011). Áreas de concordância total são observadas ao sul e sudoeste da bacia, onde estão principalmente remanescentes florestais da Mata Atlântica.

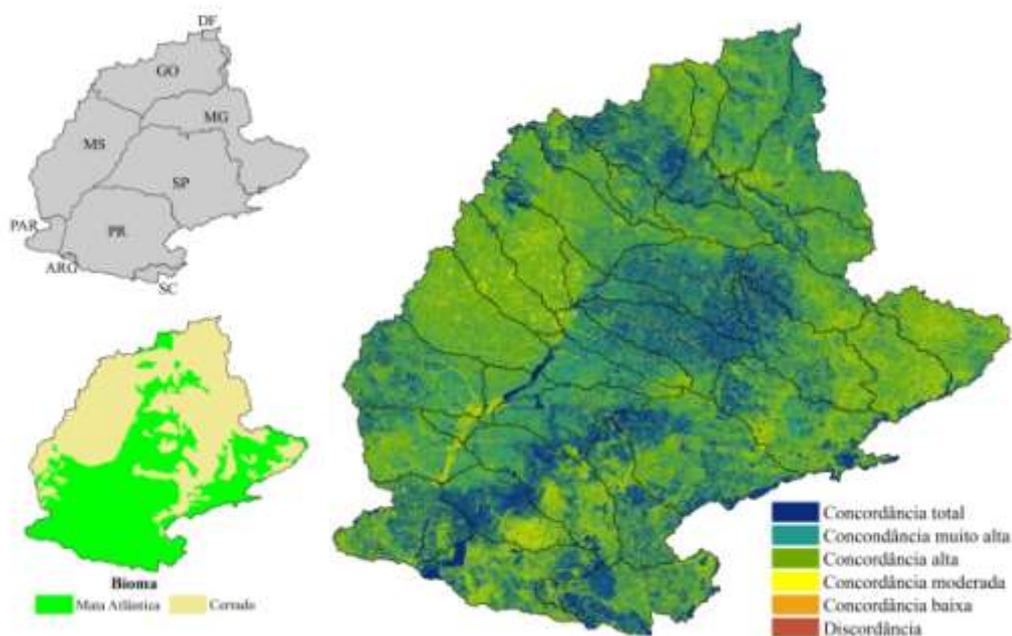


Figura 17 - Concordância espacial entre conjuntos de dados com legenda generalizada. O grau de acordo é definido como: Concordância total – os seis conjuntos de dados são consistentes; Concordância muito alta - cinco conjuntos de dados são consistentes; Concordância alta quatro conjuntos de dados são consistentes. Concordância moderada - três conjuntos de dados são consistentes. Concordância baixa - dois conjuntos de dados são consistentes. Discordância – não há relação entre os conjuntos de dados.

Áreas com concordância entre quatro (36,7%) e três (8,6%) produtos são observadas, em especial, para o bioma Cerrado. Essas áreas foram tipicamente classificadas como Agricultura (Globeland30, GlobCover e CCI) e Cerrado (MODIS e GLCNMO). No entanto, estudos anteriores demonstram uma prevalência da classe pastagem para a região (SANO; BARCELLOS; BEZERRA, 2002; MMA, 2007b, 2015; SANO et al., 2010), em consonância com o produto BHAPR-2015. Outros estudos têm apontado para a existência de discrepâncias entre os produtos globais para regiões de Savana/Cerrado (HEROLD et al., 2008; SEXTON et al., 2016), devido principalmente à mistura entre diferentes categorias de cobertura do solo ou dominância de classes de transição, incluindo arbustos ou vegetação herbácea (PÉREZ-HOYOS; GARCÍA-HARO; SAN-MIGUEL-AYANZ, 2012). Com o objetivo de reduzir o efeito devido à baixa resolução de sensores como o MODIS, estudos regionais recentes têm feito uso de imagens Landsat em mapeamentos de regiões de savana heterogênea (SCHMIDT et al., 2012; GRECCHI et al., 2013; GAO et al., 2015).

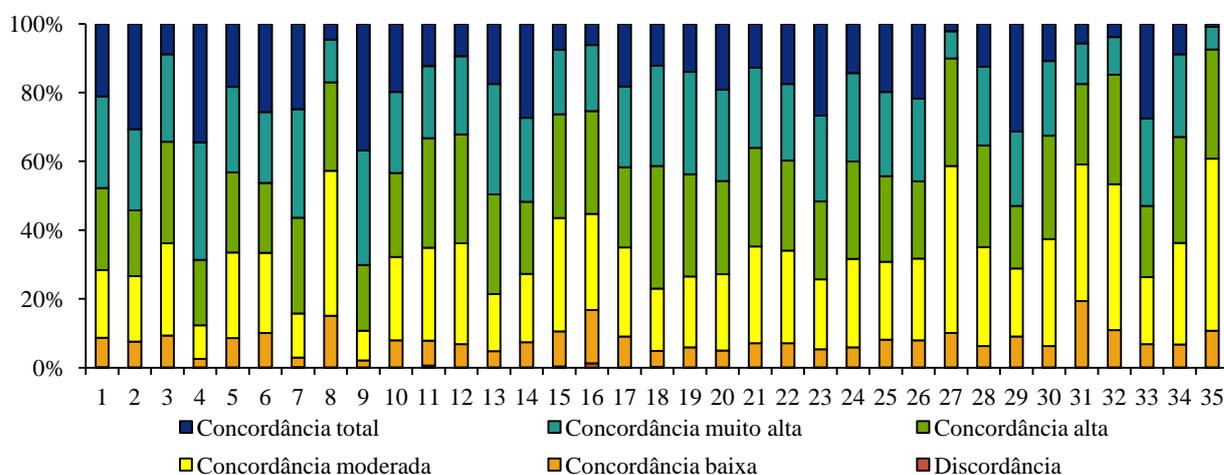
Classes com baixa ou nenhuma concordância somam uma parcela muito baixa (0,3%), embora a concordância global entre os produtos tenha sido relativamente baixa (Tabela 14). Isto se deve à concordância espacial ser realizada por pixel, podendo haver uma variabilidade entre os produtos que concordam para pixels específicos.

Tabela 64 - Concordância global entre os mapas de cobertura do solo para a BHAPR.

	BHAPR-2015	MODIS	GlobCover	CCI	GLCNMO	Globeland30
BHAPR-2015	1,00					
MODIS	0,39	1,00				
GlobCover	0,50	0,41	1,00			
CCI	0,49	0,49	0,70	1,00		
GLCNMO	0,47	0,52	0,59	0,61	1,00	
Globeland30	0,50	0,38	0,61	0,65	0,54	1,00

A Figura 18 mostra o resultado da avaliação dos níveis de concordância por sub-bacias. Os melhores níveis de concordância foram identificados para as sub-bacias: Baixo Tietê (9), Rio Piquiri (29) e Alto Iguaçu (2), que apresentaram concordância total em 36,8%, 31,3% e 20,7% de suas respectivas áreas. As sub-bacias 9 e 29 caracterizam-se por intensa atividade agrícola, enquanto que a sub-bacia 33 apresenta, além de agricultura, área florestal expressiva. Portanto, ambas as sub-bacias 9 e 29 estão localizadas em regiões mais homogêneas, facilitando o mapeamento.

As maiores discordâncias foram identificadas para as sub-bacias: Rio Verde (35), Rio Pardo (27) e Rio Sucuriú (32), que apresentaram concordância total em apenas 0,9%, 2,2% e 3,9% de suas áreas, respectivamente. Estas sub-bacias são compostas por pixels de classe mista com alta variabilidade, como já fora discutido anteriormente. É importante mencionar que, mesmo apresentando baixas consistências entre os produtos, as sub-bacias 35 e 27 mostraram bons valores de Índices Kappa para o produto BHAPR-2015 (ambos 0,68), o que reafirma a qualidade do produto em áreas de Cerrado e demonstra a importância de mapeamentos de resolução espacial elevada para estudos regionais.

**Figura 18** - Concordância espacial entre os conjuntos de dados por sub-bacia.

5.3 MUDANÇAS NA COBERTURA DO SOLO DA BHAPR

A qualidade dos mapeamentos produzidos neste trabalho, em particular as vantagens apontadas em relação a outros mapeamentos disponíveis para a região de estudo, fornece garantia para o uso dos mesmos na avaliação de mudanças recentes na cobertura do solo da BHAPR. Portanto, esta seção traz uma discussão sobre as mudanças que ocorreram na cobertura do solo da BHAPR entre o período de 1985 e 2015. Seguindo o mesmo procedimento dado às seções anteriores, a discussão será realizada por sub-bacias. Resultados específicos estão disponíveis no Apêndice 9. Na Figura 19 é mostrada a distribuição espacializada das alterações de cada classe a ser discutida na sequência. Para a análise de mudanças foram utilizados os mapas gerados a partir da classificação segmentada, devido à maior acurácia para o ano de 1985.

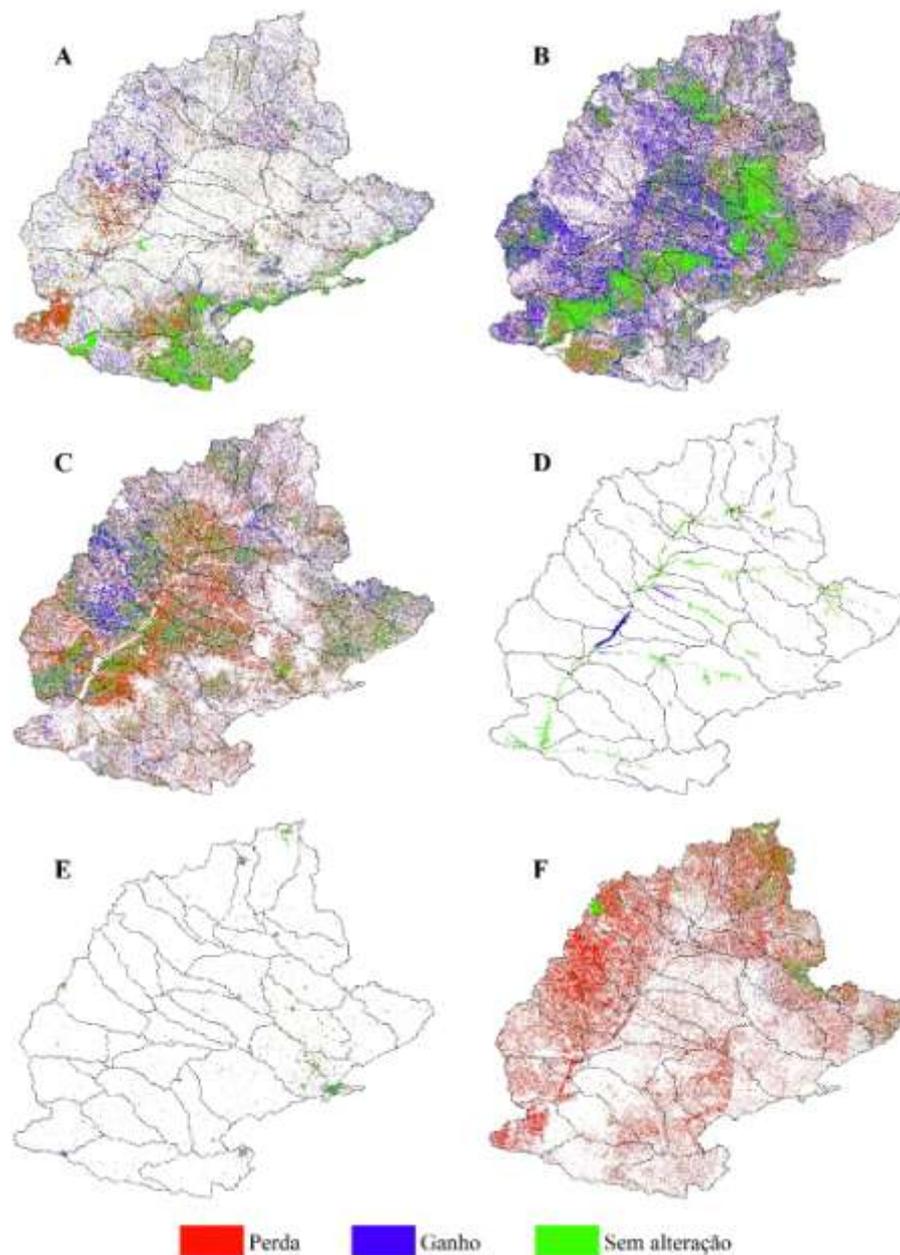


Figura 19 – Distribuição espacial de perdas e ganhos para as classes Floresta (A), Agricultura (B), Pastagem (C), Água (D), Urbano (E) e Cerrado (F).

5.3.1 Alteração de área e distribuição por classes

As diferenças observadas em cada classe na comparação entre os mapeamentos BHAPR-1985 e BHAPR-1985 não é capaz de mostrar toda a dinâmica envolvida nas atividades de uso e ocupação do solo. Por exemplo, o fato de não haver diferenças significativas entre as áreas ocupadas por uma determinada classe não significa que a mesma não tenha passado por mudanças. Além de mudanças estruturais que eventualmente podem não ser detectadas no âmbito de um tipo tão generalizado (por exemplo, Floresta), resta ainda

o fato de que há uma dinâmica espacial de mudanças que pode produzir totais muito próximos, porém, deslocados no espaço. Todavia, os mapas elaborados oferecem uma perspectiva única de aplicação por parte de gestores e usuários de informações sobre a cobertura do solo. Espera-se que nesta seção essa perspectiva de uso da informação se torne mais evidente.

Essa perspectiva mais realista de aplicação em relação às classificações anteriores decorre principalmente do maior refinamento espacial considerado, tanto na fase de obtenção de amostras quanto na elaboração do mapeamento em si. Os valores absolutos das mudanças na área para cada classe de cobertura do solo para o período de 1985 a 2015 estão mostrados na Figura 20. Observa-se na figura que a mudança mais expressiva é o aumento na classe Agricultura e a diminuição nas áreas da classe Cerrado/Vegetação arbustiva. Todavia, elementos intrínsecos dessas mudanças de grande escala serão revelados nos próximos parágrafos através de uma análise individual das principais classes.

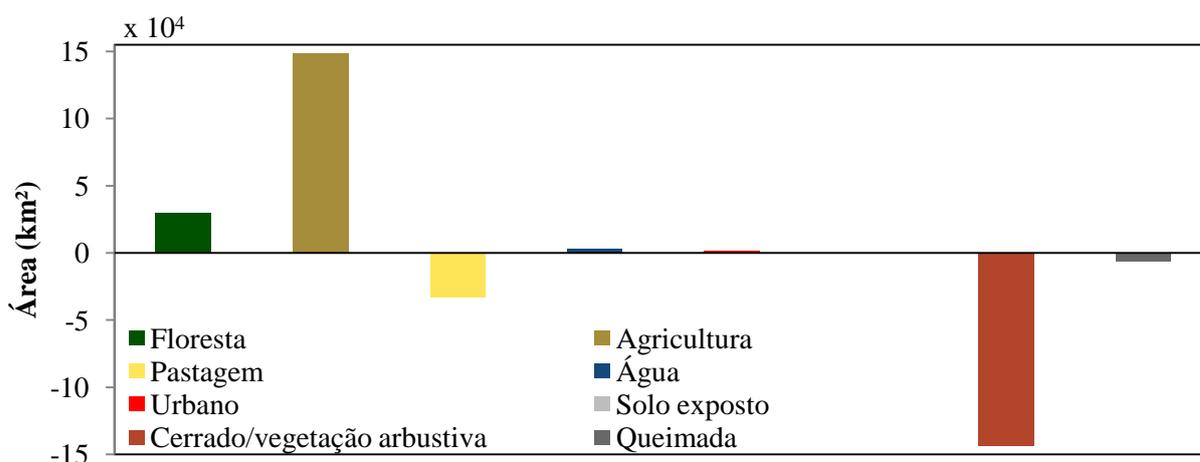


Figura 20 – Valores absolutos de mudanças na área para as classes de cobertura do solo para o período de 1985 a 2015.

As áreas identificadas como Floresta aumentaram de 147.863 km² (16,4%) em 1985 para 180.504 km² (20,1%). Entretanto, além do aumento na totalidade da classe, observou-se intensa dinâmica espacial, com fragmentos de vegetação nativa desaparecendo em algumas sub-bacias e áreas de florestamento e/ou reflorestamento surgindo em outras. As sub-bacias com maiores reduções nas áreas de Floresta foram Paraná – Guaçu, São Francisco Verdadeiro (14), Ivaí (25), Paraná – Samambaia (11) e Alto Iguaçu (2), com perdas de 5.748 km², 1.624 km², 801 km² e 756 km², respectivamente. A redução nas áreas de Floresta na sub-bacia 14 representa cerca de 19% da área da sub-bacia, ou 49% de sua cobertura florestal original. Por outro lado, nota-se ganho em áreas de Floresta na maioria das sub-bacias, com destaque para

Sucuriú (32), Alto Rio Grande (8), Rio Verde (35), Rio Claro (22) e Rio Tijuco (34), todos apresentando aumento acima de 10% da área da sub-bacia.

É importante observar que mesmo as sub-bacias que apresentaram pouca variação podem ter sofrido intensa mudança nas suas áreas de Floresta. Este é o caso da sub-bacia Rio Pardo (27), que apresenta uma redução de apenas 1% na classe, mas muito pouco de sua área de Floresta observada em 2015, cerca de 18% (6.592 km²), coincide com as áreas de 1985. Perdas e ganhos na cobertura florestal também foram observados em outros estudos, que indicam uma redução nas taxas de desmatamento de áreas inseridas na BHAPR (HANSEN et al., 2013; MARTINELLI; PERES; FERREIRA, 2014; BEUCHLE et al., 2015).

A classe Agricultura acumulou aumento expressivo entre 1985 e 2015, saltando de 249.765 km² (27,8%) para 413.623 km² (46,0%). A grande maioria das sub-bacias apresentaram aumentos expressivos na participação da classe Agricultura, com destaque para Alto Parapanema (3), Baixo Tietê (9), Paraná - Aporé ou do Peixe, Corrente e Verde (12), e Ivinhema (24), com aumentos acima de 10.000 km² nas áreas agrícolas entre 1985 e 2015. Enquanto que em 1985 apenas a sub-bacia Mogi-Guaçú (26) apresentava mais de 50% da área coberta por Agricultura, em 2015 o número de sub-bacias saltou para 13. As reduções nesta classe foram pouco significativas e se concentram nas sub-bacias Alto Rio Grande (8) e Baixo Iguaçu (6), com perdas de apenas 739 km² e 120 km². Entretanto, dada a baixa acurácia da sub-bacia 8, a redução neste caso deve ser vista com cautela.

Entre 1985 e 2015 as áreas classificadas como Pastagem passaram de 272.237 km² (30,3%) para 230.348 km² (25,6%). Todavia, associado a esta mudança da classe na BHAPR está uma redução de 62.170 km² e o surgimento de 20.281 km² em novas áreas de pastagem. As sub-bacias mais afetadas pela redução nas áreas de pastagem foram Baixo Tietê (9), Ivaí (25), Ivinhema (24), Baixo Parapanema (7), Piquiri (29) e Alto Parapanema (3), todos apresentando reduções acima de 4.000 km² na área de cobertura da classe. No total, 24 sub-bacias apresentaram redução nas áreas de pastagem, em alguns casos chegando a mais de um quarto da área da sub-bacia. Por outro lado, 11 sub-bacias apresentaram ganho para a classe, com destaque para as sub-bacias Sucuriú (32), Verde (35) e Pardo (27), todas com ganhos acima 3.000 km² nas áreas de pastagem.

De um modo geral o que se observa é um avanço das áreas de pastagem nas sub-bacias da margem direita e redução na margem esquerda. Neste caso, a redução da classe Pastagem nas sub-bacias da margem esquerda coincide com o avanço da classe Agricultura naquela região, conforme observado anteriormente. Embora essa dinâmica Pastagem-Agricultura tenha sido generalizada, ela foi muito mais intensa nessa faixa que acompanha a margem

esquerda da BHAPR. A exceção ocorre para a sub-bacia do Rio Ivinhema (24) que, localizado na margem direita, apresenta redução acentuada na classe Pastagem e aumento igualmente acentuado na classe Agricultura. Note que a participação da classe Pastagem nesta sub-bacia diminuiu de 40,2% para 24,0% da área, enquanto que as áreas da classe Agricultura saltam de 26,0% para 62,2%.

O Cerrado foi a classe que sofreu a maior mudança entre 1985 e 2015, com redução generalizada em toda BHAPR. A classe despencou de 195.067 km² (21,7%) para 45.125 km² (5,0%). As sub-bacias com as reduções mais acentuadas foram Rio Pardo (27), Paraná - Aporé ou do Peixe (12), Verde (35) e Sucuriú (32), todas com reduções acima de 10.000 km² em suas áreas. A classe Cerrado nestas sub-bacias ocupava mais de 50% da área em 1985 e despencou para valores de alguns poucos percentuais em 2015. Além disso, mapeamentos realizados no bioma Cerrado identificaram ganhos florestais em regiões localizadas na BHAPR (estados de Mato Grosso do Sul, São Paulo, Minas Gerais e Goiás) (BEUCHLE et al., 2015). O estudo de Grecchi et al. (2014) também demonstrou altas taxas de perda de cerrado em detrimento do aumento de áreas de agropecuária entre 1985 e 2005. Há também reduções significativas em sub-bacias localizadas mais ao norte da BHAPR, com destaque para São Bartolomeu (30), Parnaíba (28), Araguari ou das Velhas (21), Alto Rio Grande (8) e Sapucaí (31). Entretanto, o Índice Kappa no caso dessas sub-bacias está entre pobre e moderado para o mapeamento de 1985, o que requer certa precaução com os valores encontrados para a variação de área da classe Cerrado ao norte da BHAPR.

Em relação à classe Água, é importante considerar que há grande confusão entre a classe Água e outras classes de cobertura do solo, para o mapeamento de 1985. Este aspecto se concentra principalmente em pixels dispersos na área de cada sub-bacia e possui um efeito menor nos espelhos de água maiores. Por outro lado, deve ser considerado que há uma fração considerável de água, principalmente nos pequenos e médios afluentes do rio principal de cada sub-bacia, que não aparece no mapeamento.

Feitas as ressalvas anteriores, observa-se que a classe Água subiu de 13.922 km² para 16.430 km², com uma redução de 1.153 km² em áreas existentes em 1985 e surgimento de 3.662 km² em áreas novas da classe. Houve aumento expressivo nas áreas da classe Água principalmente nas sub-bacias Paraná - Samambaia (11), Paraná - Peixe (18), Baixo Tietê (9) e Rio Pardo (27), com aumentos entre 400 km² e 650 km². Nota-se que no período 1985-2015 houve instalação de um número significativo de novos conjuntos hidroelétricos na BHAPR, dois dos quais com área expressiva e associados às usinas Porto Primavera (sub-bacias 11, 18 e 27) e Três irmãos (sub-bacia 9). Novos espelhos d'água também são observados nas sub-

bacias Baixo Paranapanema (7), Paraná – Guaçu, São Francisco Verdadeiro (14), Rio Parnaíba (28), Araguari ou das velhas (21) e São Bartolomeu (30).

As reduções na classe Água predominaram na porção norte da BHAPR, com destaque para as sub-bacias Alto Rio Grande (8), Baixo Rio Grande (4) e Rio Sapucaí (13), todas com perdas acima de 150 km². Observa-se que reduções ocorrem em várias outras sub-bacias. Todavia, devido ao surgimento de novas áreas alagadas, tais sub-bacias aparecem com um saldo positivo na área da classe Água, situação das sub-bacias 21, 28 e 30 mencionadas anteriormente. Embora a qualidade da classificação seja inferior para as sub-bacias localizadas ao norte da BHAPR, a redução observada é consistente com o período de estiagem pelo qual a região passou entre os anos de 2014 e 2016.

A classe Urbano aumentou de 8.356 km² (0,93%) em 1985 para 10.266 km² (1,14%). Os maiores aumentos da classe foram observados nas sub-bacias Paraná – Guaçu, São Francisco Verdadeiro (14), Paraná – Meia Ponte (17), Alto Iguaçu (2), Rio Tibagi (33) e Alto Tietê (5), que apresentaram aumentos de área acima de 120 km². Para essas sub-bacias com aumentos mais expressivos nota-se a presença de cidades que têm apresentado intenso crescimento populacional nas últimas décadas, em particular a região da tríplice fronteira entre Brasil, Argentina e Paraguai (sub-bacia 14), Goiânia (sub-bacia 17) e regiões metropolitanas de Curitiba (sub-bacia 2) e São Paulo (sub-bacia 5). Embora parte do aumento observado na sub-bacia Rio Tibagi (33) esteja realmente associado à expansão de suas áreas urbanas, o valor pode estar subestimado, uma vez que a cidade de Londrina não aparece representada no mapeamento de 1985. As poucas áreas com alguma redução na classe Urbano também podem estar associadas à confusão na classificação do mapeamento de 1985.

5.3.2 Padrão de perdas e ganhos entre classes

A dinâmica de mudança individual das classes discutida nos parágrafos anteriores pode ser observada na Tabela 15, através dos percentuais líquidos de mudança (em relação à área total da BHAPR) associados a cada classe. Na diagonal principal estão os percentuais da área que se mantiveram os mesmos entre 1985 e 2015. Nas demais células entenda-se como o percentual da classe que migrou de 1985 (linhas) para 2015 (colunas). Por exemplo as classes que mantiveram os maiores percentuais de área sem alteração foram a Agricultura (18,5%), seguida por Pastagem (12,4%) e Floresta (9,6%). Por outro lado, a classe com maior perda de área foi Cerrado, com uma redução equivalente a 18,9% da BHAPR, seguida por Pastagem,

com redução de 17,8% da BHAPR. Agricultura foi a classe que mais recebeu áreas convertidas tanto da classe Pastagem quanto das coberturas originais de Cerrado e Floresta.

Tabela 75 – Matriz de mudanças para o período de 1985 a 2015, área em porcentagem.

'de' 1895	'para' 2015							
	10	20	30	40	50	60	70	80
10	9,63	4,22	2,21	0,11	0,03	0,04	0,31	0,00
20	3,00	18,51	5,04	0,15	0,29	0,03	0,70	0,00
30	2,52	14,21	12,40	0,08	0,13	0,05	0,85	0,00
40	0,04	0,15	0,03	1,28	0,00	0,00	0,03	0,00
50	0,01	0,24	0,04	0,00	0,63	0,00	0,01	0,00
60	0,04	0,07	0,05	0,00	0,00	0,00	0,01	0,00
70	4,75	8,18	5,66	0,18	0,05	0,04	3,00	0,01
80	0,12	0,32	0,15	0,03	0,00	0,00	0,11	0,00

 Sem alteração	 Agricultura para Pastagem/ Pastagem para Agricultura	 Cerrado para Pastagem	 Cerrado para Agricultura
 Floresta para Pastagem	 Floresta para Agricultura	 Cerrado para Floresta	 Agricultura e Pastagem para Floresta

O impacto das mudanças sobre a cobertura original é outro aspecto de grande importância que deve ser avaliado. Os remanescentes da cobertura original dos biomas dos quais a BHAPR faz parte são essencialmente Cerrado e Floresta Atlântica. A distribuição espacial desta mudança pode ser observada na Figura 21 e, de acordo com dados da Tabela 15, soma 25,8 % da área da BHAPR. Conforme já observado na análise individual do comportamento das classes, as maiores taxas de alteração na cobertura original ocorreram ao longo da margem direita (Floresta Atlântica e Cerrado) e ao norte da bacia (predominantemente Cerrado). São áreas onde a intensificação da agricultura aconteceu depois de 1985 (SRH/MMA, 2006; MMA, 2007b; Ruhoff et al., 2014). Conforme observado neste estudo, as sub-bacias localizadas principalmente ao longo da margem direita foram as mais impactadas. Este aspecto tem sido confirmado por aumentos expressivos nas taxas de ocupação por agricultura e pastagem naquela parte da BHAPR (SANO et al., 2010).

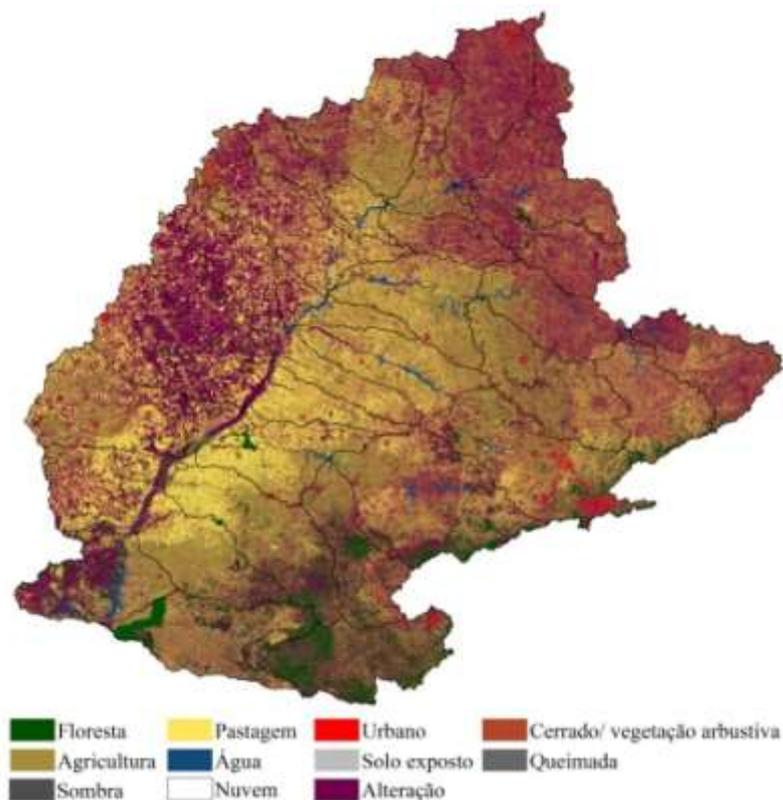


Figura 21 – Mudanças em relação à cobertura do solo original entre 1985 e 2015.

Dos resultados apresentados conclui-se que o percentual da área da BHAPR que se manteve inalterado entre 1985 e 2015 é de 45,5%. Portanto, as alterações na cobertura do solo afetaram mais da metade da área total da Bacia. Se consideradas as alterações por sub-bacias, o percentual pode atingir valores muito mais expressivos, dependendo do tipo de cobertura predominante em 1985. Este é o caso da sub-bacia Paraná - Guaçu, São Francisco Verdadeiro (14), indicada na Figura 22.

A sub-bacia perdeu quase metade de sua cobertura florestal natural, que foi convertida principalmente para área de agricultura. Atualmente a região é utilizada principalmente para a produção de soja e milho, em geral associada a grandes propriedades, que representam 80% da área (HUANG et al., 2007; DA PONTE et al., 2017). A sub-bacia 14, que faz parte do Paraguai, manteve grande parte da Floresta Atlântica intacta até a década de 1950. Já entre 1973 e 2000 o Paraguai perdeu quase dois terços das áreas associadas a este bioma. A sub-bacia 14 aparece como um portal para o avanço da atividade agrícola sobre áreas de floresta neste país e hoje a região conta com menos de 10% de sua cobertura original (HUANG et al., 2007; DA PONTE et al., 2017). Deve ser ressaltado ainda que a construção da barragem de Itaipu, entre 1973 e 1982, teve contribuições duradouras para a perda de florestas, através da

intensificação da economia nacional paraguaia, duplicando o crescimento de décadas anteriores e aumentando a demanda agrícola (DEWA, 2004).

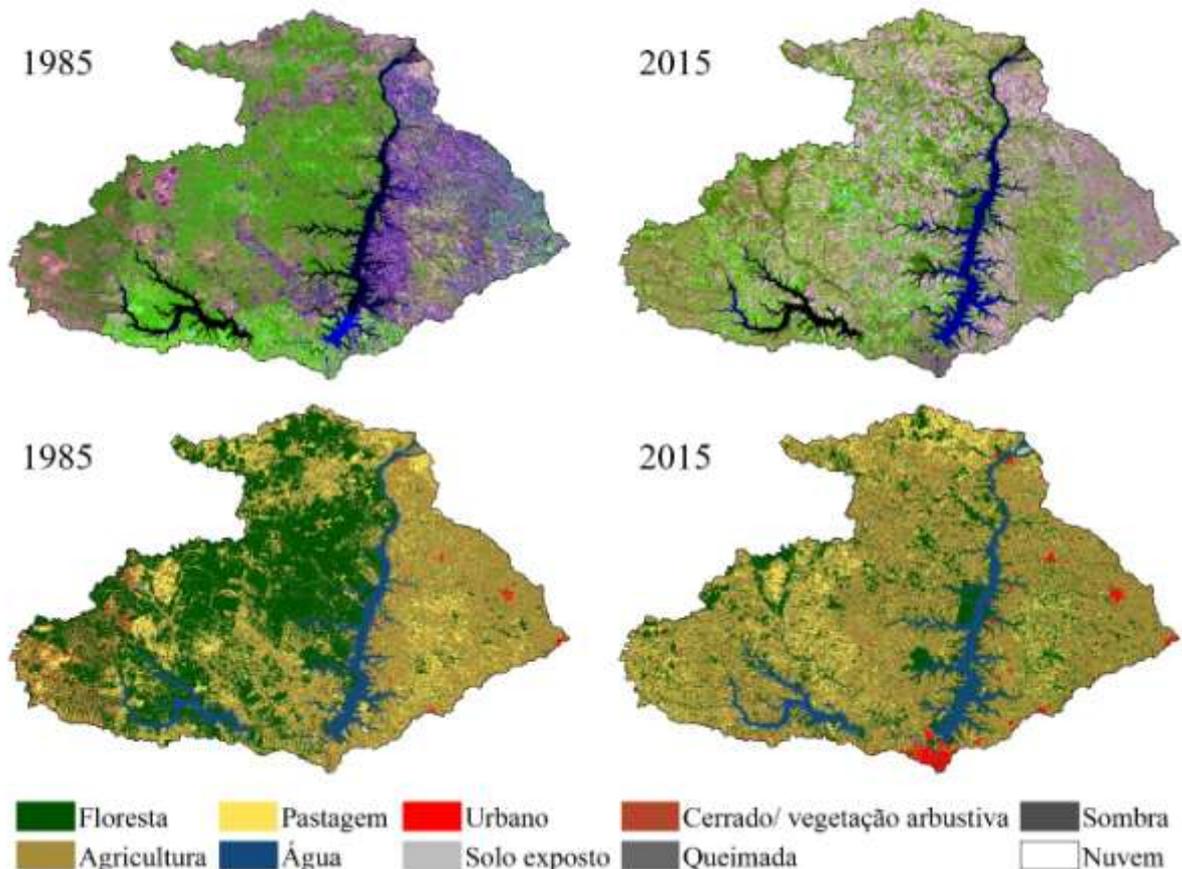


Figura 22 – mapeamento das mudanças na cobertura do solo para a sub-bacia Paraná, Guaçu, São Francisco Verdadeiro e outros.

Para efeito de um melhor entendimento da dinâmica entre classes, a Figura 23 apresenta um diagrama de fluxos para as mudanças na cobertura do solo ocorridas na sub-bacia 14 entre 1985 e 2015. Embora o diagrama retrate apenas as informações registradas nas tabelas e já discutidas nos parágrafos anteriores, ele permite uma percepção única da complexidade pela qual passou a cobertura do solo na BHAPR nas últimas três décadas. Para além disso, os resultados reforçam as conclusões de estudos anteriores, mas o faz de maneira mais assertiva, indicando onde mais precisamente houve avanços ou recuos das classes de cobertura do solo. Somente análises com o nível de refinamento espacial apresentado neste estudo são capazes de subsidiar avanços na compreensão de temas mais profundos e de extrema relevância para a sociedade, em particular a questão de mudanças climáticas e o impacto no ciclo hidrológico.

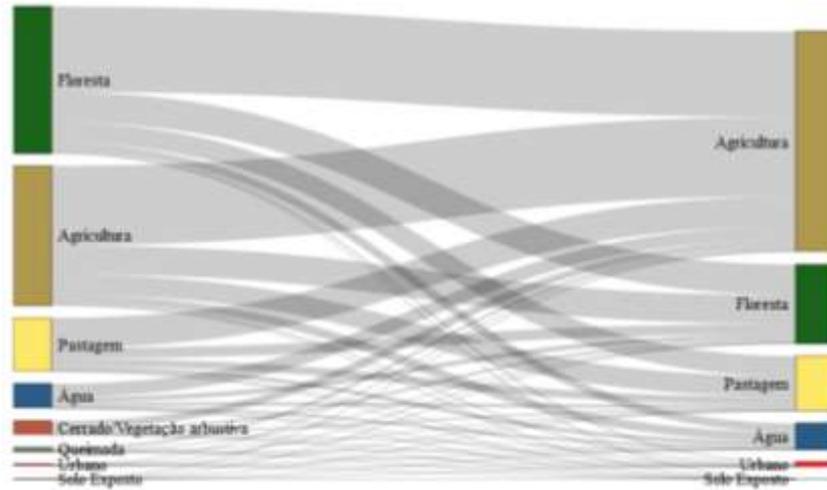


Figura 23 – Diagrama de mudanças para a sub-bacia Paraná, Guaçu, São Francisco Verdadeiro e outros para o período de 1985 a 2015.

6 CONCLUSÃO

No presente trabalho avaliou-se a dinâmica da cobertura do solo da Bacia Hidrográfica do Alto Rio Paraná entre os anos de 1985 e 2015, bem como a análise regionalizada por sub-bacia para o mesmo período. A avaliação foi desenvolvida a partir da realização do mapeamento bitemporal da cobertura do solo com dados dos sensores Landsat TM (*Thematic Mapper*) e OLI (*Operational Land Imager*). Desta forma os produtos obtidos foram avaliados quanto à acurácia, em relação a estatísticas de validação e pela comparação com outros produtos tradicionalmente em uso, e quanto a mudanças na cobertura terrestre.

As principais conclusões do trabalho são apresentadas a seguir:

- 1) De acordo com os critérios estatísticos adotados na literatura para avaliação de acurácia, Índice Kappa e Precisão Global, concluiu-se que o desempenho do classificador SVM pode ser considerado moderado para o ano de 1985 e bom para o ano de 2015, tanto para a classificação baseada em pixel quanto para a baseada a objetos. Para o ano de 1985 a classificação baseada a objetos apresentou os maiores valores de acurácia (Kappa de 0,53 e Precisão Global de 0,63), já para o ano de 2015 a classificação baseada a pixel foi a que apresentou os melhores resultados (Kappa de 0,73 e Precisão Global de 0,8).
- 2) Espacialmente observou-se maiores valores de acurácia para as sub-bacias ao sul e menores ao nordeste da bacia para o produto BHAPR-1985. As sub-bacias Alto Rio Grande e Rio Araguari apresentaram os menores valores de acurácia no produto BHAPR-1985, apresentando Kappas de 0,1 e 0,2, respectivamente. Tal particularidade pode estar relacionada ao terreno montanhoso da região, juntamente com a distribuição de mosaicos de Cerrado, Agricultura e Pastagem, que apresentam alta confusão espectral. Para o ano de 2015, apenas as sub-bacias 11, 12, 22 e 25 apresentaram níveis Kappa moderados (Kappa entre 0,4 e 0,6). A maioria das sub-bacias apresentou concordâncias boas (0,6-0,8) ou muito boas (0,8-1).
- 3) A comparação entre o produto RHAPR-2015 e produtos globais (MODIS, GlobCover, CCI, GLC, GLCNMO e Globeland30) demonstrou que Floresta e Agricultura são as classes de maior concordância, tanto em área quanto espacialmente. Quando comparados ao produto RHAPR-2015, os produtos globais mais acurados foram o Globeland30 e o GlobCover, apresentando concordância espacial em 50% da área. Em contrapartida o produto MODIS foi o menos acurado, com concordância em apenas 39% da área. O produto MODIS também demonstrou baixa correlação com os demais produtos globais. Tal constatação deve ser particularmente observada, uma vez que este é amplamente empregado para representar a cobertura do solo em simulações numéricas (BROXTON et al., 2014).

4) A comparação entre os produtos globais por sub-bacia também evidenciou maior concordância em áreas caracterizadas por intensa atividade agrícola e de área florestal expressiva, em especial para as sub-bacias do Baixo Tietê, Rio Piquiri e Alto Iguaçu. Em contrapartida, as sub-bacias com maior discordância entre os produtos foram a Rio Verde, Rio Pardo e Rio Sucuriú, que apresentaram concordância total em apenas 0,9%, 2,2% e 3,9% de suas áreas, respectivamente. A alta discordância pode estar relacionada principalmente a alta variabilidade espacial da vegetação na região.

5) Quanto às modificações na cobertura terrestre, a mudança mais expressiva refere-se ao aumento na classe Agricultura e a diminuição nas áreas da classe Cerrado/Vegetação arbustiva. Cerrado foi a classe que sofreu a maior mudança entre 1985 e 2015, com redução generalizada em toda BHAPR, a classe representava 22% da área da bacia em 1985 e passou para apenas 5%. As sub-bacias com as reduções mais acentuadas foram Rio Pardo (27), Paraná - Aporé ou do Peixe (12), Verde (35) e Sucuriú (32), todas com reduções acima de 10.000 km² em suas áreas. A classe Cerrado nestas sub-bacias ocupava mais de 50% da área em 1985 e despencou para valores de alguns poucos percentuais em 2015.

REFERÊNCIAS

- AGOSTINHO, A. A.; PELICICE, F. M.; PETRY, A. C.; GOMES, L. C.; COLOMBO, A. Fish diversity in the upper Paraná River basin: habitats, fisheries, management and conservation. **Aquatic Ecosystem Health & Management**, v. 10, n. 2, p. 174–186, 2007.
- ALMEIDA, C. A. de; COUTINHO, A. C.; ESQUERDO, J. C. D. M.; ADAMI, M.; VENTURIERI, A.; DINIZ, C. G.; DESSAY, N.; DURIEUX, L.; GOMES, A. R. High spatial resolution land use and land cover mapping of the Brazilian Legal Amazon in 2008 using Landsat-5/TM and MODIS data. **Acta Amazonica**, v. 46, n. 3, p. 291–302, 2016.
- ANIEKAN EYOH; OLAYINKA, D. N.; NWILO, P.; OKWUASHI, O.; ISONG, M.; UDOUDO, D. Modelling and Predicting Future Urban Expansion of Lagos, Nigeria from Remote Sensing Data Using Logistic Regression and GIS. **International Journal of Applied Science and Technology**, v. 2, n. 5, p. 116–124, 2012.
- ARAÚJO, G. K. D.; ROCHA, J. V.; LAMPARELLI, R. A. C.; ROCHA, A. M. MAPPING OF SUMMER CROPS IN THE STATE OF PARANÁ, BRAZIL, THROUGH THE 10-DAY SPOT VEGETATION NDVI COMPOSITES. **Engenharia Agrícola**, v. 31, n. 4, p. 760–770, 2011.
- ARINO, O.; BICHERON, P.; ACHARD, F.; LATHAM, J.; WITT, R.; WEBER, J. Globcover: The most detailed portrait of Earth. **European Space Agency Bulletin**, v. 36, p. 24–31, 2008.
- AVITABILE, V.; HEROLD, M.; HEUVELINK, G. B. M.; LEWIS, S. L.; PHILLIPS, O. L.; ASNER, G. P.; ARMSTON, J.; ASHTON, P. S.; BANIN, L.; BAYOL, N.; BERRY, N. J.; BOECKX, P.; DE JONG, B. H. J.; DEVRIES, B.; GIRARDIN, C. A. J.; KEARSLEY, E.; LINDSELL, J. A.; LOPEZ-GONZALEZ, G.; LUCAS, R.; MALHI, Y.; MOREL, A.; MITCHARD, E. T. A.; NAGY, L.; QIE, L.; QUINONES, M. J.; RYAN, C. M.; FERRY, S. J. W.; SUNDERLAND, T.; LAURIN, G. V.; GATTI, R. C.; VALENTINI, R.; VERBEECK, H.; WIJAYA, A.; WILLCOCK, S. An integrated pan-tropical biomass map using multiple reference datasets. **Global Change Biology**, v. 22, n. 4, p. 1406–1420, 2016.
- AYOADE, J. O. **Introdução à climatologia para os trópicos**. 4^a edição ed. Rio de Janeiro: Bertrand Brasil, 1996.
- BAI, Y.; FENG, M.; JIANG, H.; WANG, J.; ZHU, Y.; LIU, Y. Assessing consistency of five global land cover data sets in China. **Remote Sensing**, v. 6, n. 9, p. 8739–8759, 2014.
- BANKO, G. **A review of assessing the accuracy of classifications of remotely sensed data and of methods including remote sensing data in forest inventory**. Laxenburg: IIASA, 1998a.
- BANKO, G. **A review of assessing the accuracy of classifications of remotely sensed data and of methods including remote sensing data in forest inventory**. Laxenburg: IIASA, 1998b.
- BARNETT, T. P.; PIERCE, D. W.; HIDALGO, H. G.; BONFILS, C.; SANTER, B. D.; DAS, T.; BALA, G.; WOOD, A. W.; NOZAWA, T.; MIRIN, A. A.; CAYAN, D. R.; DETTINGER, M. D. Human-Induced Changes in the Hydrology of the Western United States. **SCIENCE**,

v. 319, p. 1080–1083, 2008.

BARSI, J. A.; LEE, K.; KVARAN, G.; MARKHAM, B. L.; PEDELTY, J. A. The spectral response of the Landsat-8 operational land imager. **Remote Sensing**, v. 6, p. 10232–10251, 2014.

BARTHOLOME, E.; BELWARD, A. GLC2000: a new approach to global land cover mapping from Earth observation data. **International Journal of Remote Sensing**, v. 26, n. 9, p. 1959–1977, 2005.

BIRDSEY, R.; ANGELES-PEREZ, G.; KURZ, W. A.; LISTER, A.; OLGUIN, M.; PAN, Y.; WAYSON, C.; WILSON, B.; JOHNSON, K. Approaches to monitoring changes in carbon stocks for REDD+. **Carbon Management**, v. 4, n. 5, p. 519–537, 2013.

BLANCO, P. D.; COLDITZ, R. R.; LÓPEZ SALDAÑA, G.; HARDTKE, L. A.; LLAMAS, R. M.; MARI, N. A.; FISCHER, A.; CARIDE, C.; ACEÑOLAZA, P. G.; DEL VALLE, H. F.; LILLO-SAAVEDRA, M.; CORONATO, F.; OPAZO, S. A.; MORELLI, F.; ANAYA, J. A.; SIONE, W. F.; ZAMBONI, P.; ARROYO, V. B. A land cover map of Latin America and the Caribbean in the framework of the SERENA project. **Remote Sensing of Environment**, v. 132, p. 13–31, 2013.

BODART, C.; EVA, H.; BEUCHLE, R.; RAŠI, R.; SIMONETTI, D.; STIBIG, H. J.; BRINK, A.; LINDQUIST, E.; ACHARD, F. Pre-processing of a sample of multi-scene and multi-date Landsat imagery used to monitor forest cover changes over the tropics. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 5, p. 555–563, 2011.

BOLCH, T. Climate change and glacier retreat in northern Tien Shan (Kazakhstan/Kyrgyzstan) using remote sensing data. **Global and Planetary Change**, v. 56, n. 1–2, p. 1–12, 2007.

BONTEMPS, S.; DEFOURNY, P.; BOGAERT, E. Van; KALOGIROU, V.; PEREZ, J. R. **GLOBCOVER 2009 Products Description and Validation Report**. Disponível em: <<http://www.webcitation.org/6ewikBY3L>>. Acesso em: 7 jan. 2018.

BROXTON, P. D.; ZENG, X.; SULLA-MENASHE, D.; TROCH, P. A. A global land cover climatology using MODIS data. **Journal of Applied Meteorology and Climatology**, v. 53, n. 6, p. 1593–1605, 2014.

CAMPBELL, J. B.; WYNNE, R. H. **Introduction to remote sensing**. 5. ed. New York: Guilford Press, 2011.

CÂNDIDO, L. A. **Impacto da condição inicial de água no solo na previsão de verão da américa do sul**. 2002. Instituto Nacional de Pesquisas Espaciais, 2002.

CANTY, M. J. **Image analysis, classification, and change detection in remote**. 2. ed. Boca Raton: CRC Press, 2009.

CAPUCIM, M. N.; BRAND, V. S.; MACHADO, C. B.; MARTINS, L. D.; ALLASIA, D. G.; HOMANN, C. T.; DE FREITAS, E. D.; DA SILVA DIAS, M. A. F.; ANDRADE, M. F.; MARTINS, J. A. South America land use and land cover assessment and preliminary analysis

of their impacts on regional atmospheric modeling studies. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 8, n. 3, p. 1185–1198, 2015.

CARVALHO, L. M. T. de; LOUZADA, J. N. C.; SCOLFORO, J. R.; OLIVEIRA, A. D. de. FLORA. In: SCOLFORO, J. R.; CARVALHO, L. M. T. DE; OLIVEIRA, A. D. DE (Ed.). **Zoneamento Ecológico-Econômico do estado de Minas Gerais: Componentes geofísico e biótico**. 1. ed. Lavras: UFLA, 2008. p. 137–150.

CHANDER, G.; MARKHAM, B. L.; HELDER, D. L. Summary of Current Radiometric Calibration Coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI Sensors. **Remote Sensing of Environment**, v. 113, n. 5, p. 893–903, 2009.

CHEN, J.; CHEN, J.; LIAO, A.; CAO, X.; CHEN, L.; CHEN, X.; HE, C.; HAN, G.; PENG, S.; LU, M.; ZHANG, W.; TONG, X.; MILLS, J. Global land cover mapping at 30 m resolution: A POK-based operational approach. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 103, p. 7–27, 2015.

CHEN, X.; ZHAO, H.; LI, P.; YIN, Z. Remote sensing image-based analysis of the relationship between urban heat island and land use/cover changes. **Remote Sensing of Environment**, v. 104, p. 133–146, 2006.

CHENG, Y.; USTIN, S. L.; RIAÑO, D.; VANDERBILT, V. C. Water content estimation from hyperspectral images and MODIS indexes in Southeastern Arizona. **Remote Sensing of Environment**, v. 112, p. 363–374, 2008.

COGNARD-PLANCQ, A.; MARC, V.; DIDON-LESCOT, È.; NORMAND, M. The role of forest cover on streamflow down sub-Mediterranean mountain watersheds : a modelling approach. **Journal of Hydrology**, v. 254, p. 229–243, 2001.

COHEN, W. B.; GOWARD, S. N. Landsat ' s Role in Ecological Applications of Remote Sensing. **BioScience**, v. 54, n. 6, p. 535–545, 2004.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35–46, 1991.

COSTA, M. H.; BOTTA, A.; CARDILLE, J. A. Effects of large-scale changes in land cover on the discharge of the Tocantins River , Southeastern Amazonia. **Journal of Hydrology**, v. 283, p. 206–217, 2003.

DA PONTE, E.; KUENZER, C.; PARKER, A.; RODAS, O.; OPPELT, N.; FLECKENSTEIN, M. Forest cover loss in Paraguay and perception of ecosystem services: A case study of the Upper Parana Forest. **Ecosystem Services**, v. 24, p. 200–212, 2017.

DE MORISSON VALERIANO, M.; DE FÁTIMA ROSSETTI, D. Topodata: Brazilian full coverage refinement of SRTM data. **Applied Geography**, v. 32, n. 2, p. 300–309, 2012.

DEFOURNY, P.; BONTEMPS, S.; LAMARCHE, C.; BROCKMANN, C.; BOETTCHER, M.; WEVERS, J.; KIRCHES, G.; SANTORO, M. **Land Cover CCI PRODUCT USER GUIDE - VERSION 2.0**. Disponível em: <http://maps.elie.ucl.ac.be/CCI/viewer/download/ESACCI-LC-Ph2-PUGv2_2.0.pdf>. Acesso

em: 1 jul. 2018.

DEFRIES, R.; HANSEN, M.; TOWNSHEND, J. Global discrimination of land cover types from metrics derived from AVHRR pathfinder data. **Remote Sensing of Environment**, v. 54, n. 3, p. 209–222, 1995.

DOYLE, M. E.; BARROS, V. R. Attribution of the river flow growth in the Plata Basin. **International Journal of Climatology**, v. 31, p. 2234–2248, 2011.

ELSAYED, S.; RISCHBECK, P.; SCHMIDHALTER, U. Comparing the performance of active and passive reflectance sensors to assess the normalized relative canopy temperature and grain yield of drought-stressed barley cultivars. **Field Crops Research**, v. 177, p. 148–160, 2015.

ENVI. **Rule-Based Classification**. Disponível em:

<file:///D:/Exelis/envi51/help/ENVIHelp.htm#cshid=RULESELECTINPUT>. Acesso em: 25 jan. 2018a.

ENVI. **Extract Segments Only**. Disponível em:

<file:///D:/Exelis/envi51/help/ENVIHelp.htm#cshid=SEGMENTSEGMENT>. Acesso em: 20 set. 2017b.

ESA, (European Space Agency). **Land Cover Climate Change Initiative (CCI) – Product User Guide Version 2.0**. Disponível em:

<http://maps.elie.ucl.ac.be/CCI/viewer/download/ESACCI-LC-PUG-v2.4.pdf>. Acesso em: 19 dez. 2017.

ESA, (European Space Agency). **CCI—Climate Change Initiative**. Disponível em:

<https://www.esa-landcover-cci.org/index.php?q=webfm_send/88>. Acesso em: 28 jan. 2018.

ESCH, T.; MARCONCINI, M.; FELBIER, A.; ROTH, A.; HELDENS, W.; HUBER, M.; SCHWINGER, M.; TAUBENBOCK, H.; MULLER, A.; DECH, S. Urban footprint processor-Fully automated processing chain generating settlement masks from global data of the TanDEM-X mission. **IEEE Geoscience and Remote Sensing Letters**, v. 10, n. 6, p. 1617–1621, 2013.

ESCH, T.; TAUBENBÖCK, H.; ROTH, A.; HELDENS, W.; FELBIER, A.; THIEL, M.; SCHMIDT, M.; MÜLLER, A.; DECH, S. TanDEM-X mission—new perspectives for the inventory and monitoring of global settlement patterns. **Journal of Applied Remote Sensing**, v. 6, n. 1, p. 617021–6170221, 2012.

EVA, H. D.; BELWARD, A. S.; DE MIRANDA, E. E.; DI BELLA, C. M.; GOND, V.; HUBER, O.; JONES, S.; SGRENZAROLI, M.; FRITZ, S. A land cover map of South America. **Global Change Biology**, v. 10, n. 5, p. 731–744, 2004.

FAO, (Food and Agriculture Organization of the United Nations). **FAOSTAT - Country Indicators**. Disponível em: <http://www.fao.org/faostat/en/#country/21>. Acesso em: 9 mar. 2018.

FARR, T. G.; KOBRICK, M. Shuttle radar topography mission produces a wealth of data.

Eos, v. 81, n. 48, p. 583–585, 2000.

FINDELL, K. L.; SHEVLIAKOVA, E.; MILLY, P. C. D.; STOUFFER, R. J. Modeled Impact of Anthropogenic Land Cover Change on Climate. **JOURNAL OF CLIMATE**, v. 20, p. 3621–3635, 2007.

FLORENZANO, teresa gallotti. **Imagens de Satélite para Estudos Ambientais Oficina de Textos** São Paulo Oficina de Texto, , 2002.

FOLEY, J. A.; DEFRIES, R.; ASNER, G. P.; BARFORD, C.; BONAN, G.; CARPENTER, S. R.; CHAPIN, F. S.; COE, M. T.; DAILY, G. C.; GIBBS, H. K.; HELKOWSKI, J. H.; HOLLOWAY, T.; HOWARD, E. A.; KUCHARIK, C. J.; MONFREDA, C.; PATZ, J. A.; PRENTICE, I. C.; RAMANKUTTY, N.; SNYDER, P. K. Global Consequences of Land Use. **SCIENCE**, v. 309, n. 2005, p. 570–574, 2005.

FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, v. 80, n. 1, p. 185–201, 2002.

FRIEDL, M. A.; SULLA-MENASHE, D.; TAN, B.; SCHNEIDER, A.; RAMANKUTTY, N.; SIBLEY, A.; HUANG, X. MODIS Collection 5 global land cover: Algorithm refinements and characterization of new datasets. **Remote Sensing of Environment**, v. 114, n. 1, p. 168–182, 2010.

GAO, F.; HILKER, T.; ZHU, X.; ANDERSON, M.; MASEK, J.; WANG, P.; YANG, Y. Fusing Landsat and MODIS Data for Vegetation Monitoring. **IEEE Geoscience and Remote Sensing Magazine**, v. 3, n. 3, p. 47–60, 2015.

GASCON, L. H.; EVA, H. D.; GOBRON, N.; SIMONETTI, D.; FRITZ, S. The application of medium resolution MERIS satellite data for continental land cover mapping over South America – results and caveats. In: GIRI, C. P. . (Ed.). **Remote Sensing of Land Use and Land Cover -Principles and Applications**. 1. ed. [s.l.] CRC Press, 2012. p. 325–338.

GIRI, C.; LONG, J. Land Cover Characterization and Mapping of South America for the Year 2010 Using Landsat 30 m Satellite Data. **Remote sensing**, v. 6, p. 9494–9510, 2014.

GITAS, I.; MITRI, G.; VERAVERBEKE, S.; POLYCHRONAKI, A. Advances in Remote Sensing of Post-Fire Vegetation Recovery Monitoring – A Review. In: FATOYINBO, T. (Ed.). **Remote Sensing of Biomass - Principles and Applications**. 1. ed. [s.l.: s.n.]p. 334.

GONG, P.; WANG, J.; YU, L.; ZHAO, Y.; ZHAO, Y.; LIANG, L.; NIU, Z.; HUANG, X.; FU, H.; LIU, S.; LI, C.; LI, X.; FU, W.; LIU, C.; XU, Y.; WANG, X.; CHENG, Q.; HU, L.; YAO, W.; ZHANG, H.; ZHU, P.; ZHAO, Z.; ZHANG, H.; ZHENG, Y.; JI, L.; ZHANG, Y.; CHEN, H.; YAN, A.; GUO, J.; YU, L.; WANG, L.; LIU, X.; SHI, T.; ZHU, M.; CHEN, Y.; YANG, G.; TANG, P.; XU, B.; GIRI, C.; CLINTON, N.; ZHU, Z.; CHEN, J.; CHEN, J. Finer resolution observation and monitoring of global land cover: first mapping results with Landsat TM and ETM+ data. **International Journal of Remote Sensing**, v. 34, n. 7, p. 2607–2654, 2013.

GRECCHI, R. C.; GWYN, Q. H. J.; BÉNIÉ, G. B.; FORMAGGIO, A. R. Assessing the spatio-temporal rates and patterns of land-use and land- cover changes in the Cerrados of

southeastern Mato Grosso , Brazil. **International Journal of Remote Sensing**, v. 34, n. 15, p. 5369–5392, 2013.

GREKOUSIS, G.; MOUNTRAKIS, G.; KAVOURAS, M. An overview of 21 global and 43 regional land-cover mapping products. **International Journal of Remote Sensing**, v. 36, n. 21, p. 5309–5335, 2015.

HANSEN, M. C.; DEFRIES, R. S.; TOWNSHEND, J. R. G.; SOHLBERG, R. A. Global land cover classification at 1 km spatial resolution using a classification tree approach. **International Journal of Remote Sensing**, v. 21, n. 6–7, p. 1331–1364, 2000.

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

HANSEN, M. C.; POTAPOV, P. V.; MOORE, R.; HANCHER, M.; TURUBANOVA, S. A.; TYUKAVINA, A.; THAU, D.; STEHMAN, S. V.; GOETZ, S. J.; LOVELAND, T. R.; KOMMAREDDY, A.; EGOROV, A.; CHINI, L.; JUSTICE, C. O.; TOWNSHEND, J. R. G.; QUANTIFICATION. High-Resolution Global Maps of 21st-Century Forest Cover Change. **SCIENCE**, v. 342, p. 850–853, 2013.

HEROLD, M.; MAYAUX, P.; WOODCOCK, C. E.; BACCINI, A.; SCHMULLIUS, C. Some challenges in global land cover mapping: An assessment of agreement and accuracy in existing 1 km datasets. **Remote Sensing of Environment**, v. 112, n. 5, p. 2538–2556, 2008.

HOERLING, M.; HURRELL, J.; EISCHEID, J.; PHILLIPS, A. Detection and attribution of twentieth-century northern and southern African rainfall change. **Journal of Climate**, v. 19, n. 16, p. 3989–4008, 2006.

HOUGHTON, R. A.; HOUSE, J. I.; PONGRATZ, J.; VAN DER WERF, G. R.; DEFRIES, R. S.; HANSEN, M. C.; LE QUÉRÉ, C.; RAMANKUTTY, N. Carbon emissions from land use and land-cover change. **Biogeosciences**, v. 9, n. 12, p. 5125–5142, 2012.

HUANG, C.; KIM, S.; ALTSTATT, A.; TOWNSHEND, J. R. G.; DAVIS, P.; SONG, K.; TUCKER, C. J.; RODAS, O.; YANOSKY, A.; CLAY, R.; MUSINSKY, J. Rapid loss of Paraguay's Atlantic forest and the status of protected areas - A Landsat assessment. **Remote Sensing of Environment**, v. 106, n. 4, p. 460–466, 2007.

HUGHES, M. J.; HAYES, D. J. Automated detection of cloud and cloud shadow in single-date Landsat imagery using neural networks and spatial post-processing. **Remote Sensing**, v. 6, p. 4907–4926, 2014.

IBGE, (Instituto Brasileiro de Geografia e Estatística). **Monitoramento da cobertura e uso da terra do brasil: 2000 - 2010 - 2012 - 2014**. Rio de Janeiro: IBGE, 2017.

IPCC. **Climate change 2013: the physical science basis. contribution of working group I to the fifth assessment report of the intergovernmental panel on climate change**. Cambridge, United Kingdom and New York, NY, USA.: Cambridge University Press, 2013.

ITCG, (INSTITUTO DE TERRAS, C. e G. do P. **Uso e Cobertura da Terra**. Disponível em: <<http://www.itcg.pr.gov.br/modules/faq/category.php?categoryid=9>>. Acesso em: 1 ago.

2018.

JHA, M. K.; CHOWDHURY, A.; CHOWDARY, V. M.; PEIFFER, S. Groundwater management and development by integrated remote sensing and geographic information systems: Prospects and constraints. **Water Resources Management**, v. 21, n. 2, p. 427–467, 2007.

KALNAY, E.; CAI, M. Impact of urbanization and land-use change on climate. **Nature**, v. 423, n. MAY, p. 528–531, 2003.

KE, Y.; IM, J.; LEE, J.; GONG, H.; RYU, Y. Characteristics of Landsat 8 OLI-derived NDVI by comparison with multiple satellite sensors and in-situ observations. **Remote Sensing of Environment**, v. 164, p. 298–313, 2015.

KERR, J.; KERR, J. T.; OSTROVSKY, M. ecological applications for remote sensing . From space to species : ecological applications for remote sensing. **TRENDS in Ecology and Evolution**, v. 18, n. 6, p. 299–305, 2003.

KHATAMI, R.; MOUNTRAKIS, G. Implications of classification of methodological decisions in flooding analysis from Hurricane Katrina. **Remote Sensing**, v. 4, n. 12, p. 3877–3891, 2012.

KHATAMI, R.; MOUNTRAKIS, G.; STEHMAN, S. V. A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes : General guidelines for practitioners and future research. **Remote Sensing of Environment**, v. 177, p. 89–100, 2016.

KHORRAM, S.; VAN DER WIELE, C. F.; KOCH, F. H.; NELSON, S. A. C.; POTTS, M. D. **Principles of applied remote sensing**. New York: Springer, 2016.

KINDU, M.; SCHNEIDER, T.; TEKETAY, D.; KNOKE, T. Land use/land cover change analysis using object-based classification approach in Munessa-Shashemene landscape of the ethiopian highlands. **Remote Sensing**, v. 5, n. 5, p. 2411–2435, 2013.

KIRCHES, G.; BROCKMANN, C.; BOETTCHER, M.; PETERS, M.; BONTEMPS, S.; LAMARCHE, C.; SCHLERF, M.; SANTORO, M.; DEFOURNY, P. **CCI-LC Product User Guide 2.5**. Disponível em: <<http://maps.elie.ucl.ac.be/CCI/viewer/download/ESACCI-LC-PUG-v2.5.pdf>>. Acesso em: 15 jan. 2018.

KLOTZ, M.; KEMPER, T.; GEIS, C.; ESCH, T.; TAUBENBÖCK, H. How good is the map? A multi-scale cross-comparison framework for global settlement layers: Evidence from Central Europe. **Remote Sensing of Environment**, v. 178, p. 191–212, 2016.

KNORN, J.; RABE, A.; RADELOFF, V. C.; KUEMMERLE, T.; KOZAK, J.; HOSTERT, P. Land cover mapping of large areas using chain classification of neighboring Landsat satellite images. **Remote Sensing of Environment**, v. 113, n. 5, p. 957–964, 2009.

KOBAYASHI, T.; TATEISHI, R.; ALSAAIDEH, B.; SHARMA, R. C.; WAKAIZUMI, T.; MIYAMOTO, D.; BAI, X.; LONG, B. D.; GEGENTANA, G.; MAITINIYAZI, A.; CAHYANA, D.; HAIRETI, A.; MORIFUJI, Y.; ABAKE, G.; PRATAMA, R.; ZHANG, N.;

ALIFU, Z.; SHIRAHATA, T.; MI, L.; IIZUKA, K.; YUSUPUJIANG, A.; RINAWAN, F. R.; BHATTARAI, R.; PHONG, D. X. Production of Global Land Cover Data – GLCNMO2013. **Journal of Geography and Geology**, v. 9, n. 3, p. 1–15, 2017.

KREPPER, C. M.; VENTURINI, V. Assessing interannual water balance of La Plata river basin. **Atmosfera**, v. 22, n. 4, p. 387–398, 2009.

LAPIG, (Laboratório de Processamento de Imagens e Geoprocessamento). **Mapa Síntese da Área de Pastagem (MSP) para o território brasileiro**. Disponível em: <<https://www.lapig.iesa.ufg.br/lapig/index.php/novos-dados-e-ferramentas/719-disponivel-sexta-versao-do-mapa-sintese-da-area-de-pastagem-msp-para-o-territorio-brasileiro>>. Acesso em: 20 jan. 2017.

LEHNER, B.; VERDIN, K.; JARVIS, A. New global hydrography derived from spaceborne elevation data. **Eos**, v. 89, n. 10, p. 93–94, 2008.

LI, Z. L.; TANG, R.; WAN, Z.; BI, Y.; ZHOU, C.; TANG, B.; YAN, G.; ZHANG, X. A review of current methodologies for regional Evapotranspiration estimation from remotely sensed data. **Sensors**, v. 9, n. 5, p. 3801–3853, 2009.

LIANG, D.; ZUO, Y.; HUANG, L.; ZHAO, J.; TENG, L.; YANG, F. Evaluation of the Consistency of MODIS Land Cover Product (MCD12Q1) Based on Chinese 30 m GlobeLand30 Datasets: A Case Study in Anhui Province, China. **ISPRS International Journal of Geo-Information**, v. 4, n. 4, p. 2519–2541, 2015.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote sensing and image interpretation**. 7. ed. [s.l.] John Wiley & Sons, 2014.

LIU, D.; XIA, F. Assessing object-based classification: Advantages and limitations. **Remote Sensing Letters**, v. 1, n. 4, p. 187–194, 2010.

LOOSVELT, L. **Assessment of uncertainty in land surface characterization and implications for spatially distributed hydrological modelling**. 2013. Ghent University, 2013.

LOVELAND, T. R.; REED, B. C.; BROWN, J. F.; OHLEN, D. O.; ZHU, Z.; YANG, L.; MERCHANT, J. W. Development of a global land cover characteristics database and IGBP DISCover from 1 km AVHRR data. **International Journal of Remote Sensing**, v. 21, n. 6–7, p. 1303–1330, 2000.

LP-DAAC, (Land Processes Distributed Active Archive Center). **User Guide for the MODIS Land Cover Type Product (MCD12Q1)**. Disponível em: <https://lpdaac.usgs.gov/sites/default/files/public/modis/docs/MCD12Q1_UserGuide_07302013.pdf>. Acesso em: 29 jan. 2018.

LYONS, E.; SHENG, Y. LakeTime: Automated Seasonal Scene Selection for Global Lake Mapping Using Landsat ETM+ and OLI. **Remote Sensing**, v. 10, n. 54, p. 2–23, 2017.

MA, L.; LI, M.; MA, X.; CHENG, L.; DU, P.; LIU, Y. A review of supervised object-based land-cover image classification. **ISPRS Journal of Photogrammetry and Remote Sensing**,

v. 130, p. 277–293, 2017.

MACEDO, R. C.; MOREIRA, M. Z.; DOMINGUES, E.; GAMA, Â. M. R. C.; SANSON, F. E. G.; TEIXEIRA, F. W.; DIAS, F. P.; YAMAGUCHI, F. Y.; JACINTHO, L. R. C. LUCC (Land Use and Cover Change) and the Environmental-Economic Accounts System in Brazil. **Journal of Earth Science and Engineering**, v. 4, p. 73–78, 2013.

MAHMOUD, M. I.; DUKER, A.; CONRAD, C.; THIEL, M.; AHMAD, H. S. Analysis of settlement expansion and urban growth modelling using geoinformation for assessing potential impacts of urbanization on climate in Abuja City, Nigeria. **Remote Sensing**, v. 8, n. 3, 2016.

MALAQUIAS, F. S. S.; TEIXEIRA, L. M. S.; SANTIAGO, R. B. S.; PARENTE, L. L.; FERREIRA, L. G. Pastagem.org: dados e informações para uma compreensão ambiental, econômica e social sobre a última fronteira agrícola do Brasil. In: XVIII Simpósio Brasileiro de Sensoriamento Remoto -SBSR, Santos. **Anais...** Santos: INPE, 2017.

MATHEUSSEN, B.; KIRSCHBAUM, R. L.; GOODMAN, I. A.; O'DONNELL, G. M.; LETTENMAIER, D. P. Effects of land cover change on streamflow in the interior Columbia River Basin (USA and Canada). **Hydrological Processes**, v. 14, n. July, p. 867–885, 2000.

MENDELSON, R.; DINAR, A.; WILLIAMS, L. The distributional impact of climate change on rich and poor countries. **Environment and Development Economics**, v. 11, p. 159–178, 2006.

MICIJEVIC, E.; HAQUE, M. O.; MISHRA, N. Radiometric calibration updates to the Landsat collection. In: Earth Observing Systems XXI, **Anais...**International Society for Optics and Photonics, 2016.

MMA, (Ministério do Meio Ambiente). **REVISÃO ÁREAS PRIORITÁRIAS PARA CONSERVAÇÃO DA BIODIVERSIDADE (PRIORIDADE DE AÇÃO) - 2007**. Disponível em: <<http://mapas.mma.gov.br/geonetwork/srv/br/metadata.show?id=409>>. Acesso em: 25 jan. 2017a.

MMA, (Ministério do Meio Ambiente). **Mapeamento de Cobertura Vegetal do Bioma Cerrado - Edital Probio 02/2004**. Disponível em: <http://mapas.mma.gov.br/geodados/brasil/vegetacao/vegetacao2002/cerrado/documentos/relatorio_final.pdf>. Acesso em: 20 jan. 2017b.

MMA, (Ministério do Meio Ambiente). **UNIDADES DE CONSERVAÇÃO DO BRASIL**. Disponível em: <<http://mapas.mma.gov.br/geonetwork/srv/br/metadata.show?id=1250>>. Acesso em: 25 jan. 2017.

MMA, (Ministério do Meio Ambiente). **Mapeamento do Uso e Cobertura do Cerrado: Projeto TerraClass Cerrado 2013**. Disponível em: <http://www.dpi.inpe.br/tccerrado/Metodologia_TCCerrado_2013.pdf>. Acesso em: 10 fev. 2018.

MOBLEY, C. D. **Remotely sensed data characterization, classification, and accuracies**. Boca Raton: CRC Press, 2016. v. 1

- MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 3, p. 247–259, 2011.
- MÜLLER, H.; RUFIN, P.; GRIFFITHS, P.; BARROS SIQUEIRA, A. J.; HOSTERT, P. Mining dense Landsat time series for separating cropland and pasture in a heterogeneous Brazilian savanna landscape. **Remote Sensing of Environment**, v. 156, p. 490–499, 2015.
- MÜLLER, I. I.; KRUGER, C. M.; KAVISKI, E. Análise de estacionariedade de séries hidrológicas na bacia incremental de Itaipu. **Revista Brasileira de Recursos Hídricos**, v. 3, n. 4, p. 51–71, 1998.
- NIEHOFF, D.; FRITSCH, U.; BRONSTERT, A. Land-use impacts on storm-runoff generation : Scenarios of land-use change and simulation of hydrological response in a meso-scale catchment in SW-Germany. **Journal of Hydrology**, v. 267, n. October, p. 80–93, 2002.
- NITZE, I.; GROSSE, G.; JONES, B. M.; ARP, C. D.; ULRICH, M.; FEDOROV, A.; VEREMEEVA, A. Landsat-based trend analysis of lake dynamics across Northern Permafrost Regions. **Remote Sensing**, v. 9, n. 640, p. 1–28, 2017.
- NOVO, E. M. L. D. M. **Sensoriamento remoto: princípios e aplicações**. 4. ed. São Paulo: Edgard Blücher, 2010.
- OLTHOF, I. Mapping seasonal inundation frequency (1985-2016) along the St-John River, New Brunswick, Canada using the landsat archive. **Remote Sensing**, v. 9, n. 2, p. 2–16, 2017.
- PENDRILL, F.; MARTIN PERSSON, U. Combining global land cover datasets to quantify agricultural expansion into forests in Latin America: Limitations and challenges. **PLoS ONE**, v. 12, n. 7, p. 1–21, 2017.
- PÉREZ-HOYOS, A.; GARCÍA-HARO, F. J.; SAN-MIGUEL-AYANZ, J. Conventional and fuzzy comparisons of large scale land cover products: Application to CORINE, GLC2000, MODIS and GlobCover in Europe. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 74, p. 185–201, 2012.
- PÉREZ-HOYOS, A.; REMBOLD, F.; KERDILES, H.; GALLEGO, J. Comparison of global land cover datasets for cropland monitoring. **Remote Sensing**, v. 9, n. 11, p. 1–24, 2017.
- PETTORELLI, N.; LAURANCE, W. F.; O'BRIEN, T. G.; WEGMANN, M.; NAGENDRA, H.; TURNER, W. Satellite remote sensing for applied ecologists: Opportunities and challenges. **Journal of Applied Ecology**, v. 51, n. 4, p. 839–848, 2014.
- PHIRI, D.; MORGENROTH, J. Developments in Landsat land cover classification methods: A review. **Remote Sensing**, v. 9, n. 9, p. 2–25, 2017.
- POHL, C.; VAN GENDEREN, J. L. Review article Multisensor image fusion in remote sensing: Concepts, methods and applications. **International Journal of Remote Sensing**, v. 19, n. 5, p. 823–854, 1998.
- POTERE, D.; SCHNEIDER, A.; ANGEL, S.; CIVCO, D. L. Mapping urban areas on a global

scale: Which of the eight maps now available is more accurate? **International Journal of Remote Sensing**, v. 30, n. 24, p. 6531–6558, 2009.

RICHARDS, J. A.; RICHARDS, J. A. **Remote sensing digital image analysis**. 4. ed. Berlin: Springer, 2006.

ROUSE JR, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring Vegetation Systems in the Great Plains with Ertis. In: Earth Resources Technology Satellite-1 Symposium, United States. **Anais...** United States: NASA, 1973.

ROY, D. P.; WULDER, M. A.; LOVELAND, T. R.; C.E., W.; ALLEN, R. G.; ANDERSON, M. C.; HELDER, D.; IRONS, J. R.; JOHNSON, D. M.; KENNEDY, R.; SCAMBOS, T. A.; SCHAAF, C. B.; SCHOTT, J. R.; SHENG, Y.; VERMOTE, E. F.; BELWARD, A. S.; BINDSCHADLER, R.; COHEN, W. B.; GAO, F.; HIPPLE, J. D.; HOSTERT, P.; HUNTINGTON, J.; JUSTICE, C. O.; KILIC, A.; KOVALSKYY, V.; LEE, Z. P.; LYMBURNER, L.; MASEK, J. G.; MCCORKEL, J.; SHUAI, Y.; TREZZA, R.; VOGELMANN, J.; WYNNE, R. H.; ZHU, Z. Landsat-8: Science and product vision for terrestrial global change research. **Remote Sensing of Environment**, v. 145, p. 154–172, 2014.

SABINS, F. F. **Remote sensing: principles and applications**. 3. ed. Illinois: Waveland Press, 2007.

SANO, E. E.; BARCELLOS, A. O.; BEZERRA, H. S. **Assessing the spatial distribution of cultivated pastures in the Brazilian savannaPasturas Tropicales**, 2002.

SANO, E. E.; ROSA, R.; BRITO, J. L. S.; FERREIRA, L. G. Land cover mapping of the tropical savanna region in Brazil. **Environ Monit Assess**, v. 166, p. 113–124, 2010.

SCHMIDT, M.; UDELHOVEN, T.; GILL, T.; RÖDER, A. Long term data fusion for a dense time series analysis with MODIS and Landsat imagery in an Australian Savanna. **Journal of Applied Remote Sensing**, v. 6, n. 1, p. 1–18, 2012.

SCHNEIDER, A.; FRIEDL, M. A.; POTERE, D. A new map of global urban extent from MODIS satellite data. **Environmental Research Letters**, v. 4, p. 11, 2009.

SCHNEIDER, A.; FRIEDL, M. A.; POTERE, D. Mapping global urban areas using MODIS 500-m data: New methods and datasets based on “urban ecoregions”. **Remote Sensing of Environment**, v. 114, n. 8, p. 1733–1746, 2010.

SCHOWENGERDT, R. A. **Remote sensing: models and methods for image processing**. 3. ed. Burlington: Elsevier, 2007.

SCHULZ, J.-P.; DÜMENIL, L.; POLCHER, J. On the Land Surface – Atmosphere Coupling and Its Impact in a Single-Column Atmospheric Model. **JOURNAL OF APPLIED METEOROLOGY**, v. 40, p. 642–663, 2001.

SCHWALM, C. R.; WILLIAMS, C. A.; SCHAEFER, K.; BALDOCCHI, D.; BLACK, T. A.; GOLDSTEIN, A. H.; LAW, B. E.; OECHEL, W. C.; PAW U, K. T.; SCOTT, R. L. Reduction in carbon uptake during turn of the century drought in western North America.

Nature Geoscience, v. 5, n. 8, p. 551–556, 2012.

SERTEL, E.; ROBOCK, A.; ORMECI, C. Impacts of land cover data quality on regional climate. **INTERNATIONAL JOURNAL OF CLIMATOLOGY**, v. 30, p. 1942–1953, 2010.

SEXTON, J. O.; NOOJIPADY, P.; SONG, X. P.; FENG, M.; SONG, D. X.; KIM, D. H.; ANAND, A.; HUANG, C.; CHANNAN, S.; PIMM, S. L.; TOWNSHEND, J. R. Conservation policy and the measurement of forests. **Nature Climate Change**, v. 6, n. 2, p. 192–196, 2016.

SHI, L.; LING, F.; GE, Y.; FOODY, G. M.; LI, X.; WANG, L.; ZHANG, Y.; DU, Y. Impervious surface change mapping with an uncertainty-based spatial-temporal consistency model: A case study in Wuhan City using landsat time-series datasets from 1987 to 2016. **Remote Sensing**, v. 9, n. 11, p. 1–19, 2017.

SHUKLA, J.; MINTZ, Y. Influence of Land-Surface Evapotranspiration on the Earth's Climate. **SCIENCE**, v. 215, p. 1498–1501, 1982.

SIEGEL, S.; CASTELLAN, N. **Nonparametric statistics for the behavioral sciences**. New York: McGraw-Hill, 1988.

SMA, (Secretaria de Meio Ambiente do Estado de São Paulo). **Cobertura da Terra do Estado de São Paulo - Ano 2010**. Disponível em: <http://datageo.ambiente.sp.gov.br/app/?title=Unidades+de+Conserva%25C3%25A7%25C3%25A3o+Federais&uuid=%257B0DC82494-9CE4-4DC0-B082-171EB42A5931%257D&layer=UC_Federais_MMA&resource=wms%253Ahttp%253A%252F%252Fdatageo.ambiente.sp.gov.br%252Fgeoserver%252Fdata>. Acesso em: 1 ago. 2018.

SOPHIE, B.; PIERRE, D.; ERIC, V. B. GLOBCOVER 2009 Products Report Description and Authors. **Control**, p. 1–30, 2010.

SOUZA, D. C. De; OYAMA, M. D. Climatic consequences of gradual desertification in the semi-arid area of Northeast Brazil. **Theor Appl Climatol**, v. 103, p. 345–357, 2011.

SRH/MMA. **Paraná caderno da região hidrográfica**. BRASÍLIA – DF: MINISTÉRIO DO MEIO AMBIENTE - SECRETARIA DE RECURSOS HÍDRICOS, 2006.

STEVAUX, J. C. Climatic events during the Late Pleistocene and Holocene in the Upper Parana River: Correlation with NE Argentina and South-Central Brazil. **Quaternary International**, v. 72, p. 73–85, 2000.

STONE, T. A.; SCHLESINGER, P.; HOUGHTON, R. A.; WOODWELL, G. M. A Map of the Vegetation of South America Based on Satellite Imagery. **Photogrammetric Engineering and Remote Sensing**, v. 60, n. 4, p. 541–551, 1994.

STORY, M.; CONGALTON, R. G. Accuracy assessment: a user's perspective. **Photogrammetric Engineering & Remote Sensing**, v. 52, n. 3, p. 397–399, 1986.

STRAHLER, A.; MUCHONEY, D.; BORAK, J.; FRIEDL, M.; GOPAL, S.; LAMBIN, E.;

MOODY, A. **Modis land cover product algorithm theoretical basis document (atbd)**. Boston: Boston University, 1999.

SUDERHSA, (SUDERHSA). **RELATÓRIO FINAL - Sistema de Informações Geográficas para Gestão de Recursos Hídricos no Alto Iguaçu**. Disponível em: <http://www.aguasparana.pr.gov.br/arquivos/File/rel_final_sig.pdf>. Acesso em: 1 set. 2018.

TATEISHI, R.; HOAN, N. T.; KOBAYASHI, T.; ALSAAIDEH, B.; TANA, G.; PHONG, D. X. Production of Global Land Cover Data – GLCNMO2008. **Journal of Geography and Geology**, v. 6, n. 3, p. p99, 2014.

TATEISHI, R.; URIYANGQAI, B.; AL-BILBISI, H.; GHAR, M. A.; TSEND-AYUSH, J.; KOBAYASHI, T.; KASIMU, A.; HOAN, N. T.; SHALABY, A.; ALSAAIDEH, B.; ENKHZAYA, T.; GEGENTANA; SATO, H. P. Production of global land cover data - GLCNMO. **International Journal of Digital Earth**, v. 4, n. 1, p. 22–49, 2011.

TOL, R. S. J. The economic effects of climate change. **Journal of Economic Perspectives**, v. 23, n. 2, p. 29–51, 2009.

TOTH, C.; JÓZKÓW, G. Remote sensing platforms and sensors: A survey. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 115, p. 22–36, 2016.

TUCCI, C. E. . **Impactos da variabilidade climática e do uso do solo nos recursos hídricos**. Brasília: ANA - Agência Nacional da Água, 2002.

TUCCI, C. E. M. Variabilidade climática e o uso do solo na bacia brasileira do Prata. In: TUCCI, C. E. M.; BRAGA JUNIOR, B. P. F. (Ed.). **Clima e Recursos Hídricos no Brasil**. Porto Alegre: Associacion Brasileira de Recursos Hidricos, 2003. p. 163–242.

USGS, (U.S. Geological Survey). **Landsat 1-5 Multispectral Scanner (MSS) Level-1 Data Products**. Disponível em: <<https://lta.cr.usgs.gov/MSS>>. Acesso em: 1 jan. 2017.

USGS, (U.S. Geological Survey). **PRODUCT GUIDE: LANDSAT 4-7 SURFACE REFLECTANCE (LEDAPS) PRODUCT**. Disponível em: <https://landsat.usgs.gov/sites/default/files/documents/ledaps_product_guide.pdf>. Acesso em: 9 dez. 2017.

VRIELING, A. Satellite remote sensing for water erosion assessment: A review. **Catena**, v. 65, n. 1, p. 2–18, 2006.

WALKER, W. S.; STICKLER, C. M.; KELLNDORFER, J. M.; KIRSCH, K. M.; NEPSTAD, D. C. Large-Area Classification and Mapping of Forest and Land Cover in the Brazilian Amazon: A Comparative Analysis of ALOS/PALSAR and Landsat Data Sources. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 3, n. 4, p. 594–604, 2010.

WANG, J.; ZHAO, Y.; LI, C.; YU, L.; LIU, D.; GONGA, P.; A. Mapping global land cover in 2001 and 2010 with spatial-temporal consistency at 250 m resolution. **Journal of Photogrammetry and Remote Sensing**, v. 103, p. 38–47, 2015.

WANG, L.; SOUSA, W. P.; GONG, P. Integration of object-based and pixel-based classification for mapping mangroves with IKONOS imagery. **International Journal of Remote Sensing**, v. 25, n. 24, p. 5655–5668, 2004.

WEGEHENKEL, M.; HEINRICH, U.; UHLEMANN, S.; DUNGER, V.; MATSCHULLAT, J. The impact of different spatial land cover data sets on the outputs of a hydrological model - a modelling exercise in the Ucker catchment, North-East Germany. **Physics and Chemistry of the Earth**, v. 31, n. 17, p. 1075–1088, 2006.

WENG, Q. Thermal infrared remote sensing for urban climate and environmental studies: Methods, applications, and trends. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 64, n. 4, p. 335–344, 2009.

WHITESIDE, T. G.; BOGGS, G. S.; MAIER, S. W. Comparing object-based and pixel-based classifications for mapping savannas. **International Journal of Applied Earth Observation and Geoinformation**, v. 13, n. 6, p. 884–893, 2011.

WILKINSON, G. G. Results and Implications of a Study of Fifteen Years of Satellite Image Classification Experiments. **TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING**, v. 43, n. 3, p. 433–440, 2005.

WINGATE, V. R.; PHINN, S. R.; KUHN, N.; BLOEMERTZ, L.; DHANJAL-ADAMS, K. L. Mapping decadal land cover changes in the woodlands of North Eastern Namibia from 1975 to 2014 using the landsat satellite archived data. **Remote Sensing**, v. 8, n. 8, p. 1–20, 2016.

WINSEMIUS, H. C.; JONGMAN, B.; VELDKAMP, T. I. E.; HALLEGATTE, S.; BANGALORE, M.; WARD, P. J. Disaster Risk, Climate Change, and Poverty: Assessing the Global Exposure of Poor People to Floods and Droughts. **Policy Research Working Paper**, v. 7480, n. November 2015, 2015.

WULDER, M. A.; FRNKLIN, S. E. **Remote sensing of forest environments: concepts and case studies**. 1. ed. New York: Springer Science+Business Media, 2003.

WWF BRASIL, (World Wide Fund for Nature). **Memorial Descritivo do Mapa de Regiões Fisionômicas e Uso da Terra**. Disponível em: <http://www.sieg.gov.br/downloads/Unidades_Fitofisionomica.pdf>. Acesso em: 1 maio. 2018.

XIONG, J.; THENKABAIL, P. S.; TILTON, J. C.; GUMMA, M. K.; TELUGUNTLA, P.; OLIPHANT, A.; CONGALTON, R. G.; YADAV, K.; GORELICK, N. Nominal 30-m cropland extent map of continental Africa by integrating pixel-based and object-based algorithms using Sentinel-2 and Landsat-8 data on google earth engine. **Remote Sensing**, v. 9, n. 10, p. 1–27, 2017.

XU, H. Modification of Normalized Difference Water Index (NDWI) to Enhance Open Water Features in Remotely Sensed Imagery. **International Journal of Remote Sensing**, v. 27, n. July, p. 3025–3033, 2006.

XU, H. A new index for delineating built-up land features in satellite imagery. **International**

Journal of Remote Sensing, v. 29, n. 14, p. 4269–4276, 2008.

YAN, G.; MAS, J. F.; MAATHUIS, B. H. P.; XIANGMIN, Z.; VAN DIJK, P. . comparison of pixel-based and object-oriented image classification approaches - a case study in a coal fire area, Wuda, Inner Mongolia, China. **International Journal of Remote Sensing**, v. 27, n. 18, p. 4039–4055, 2006.

YANG, Y.; XIAO, P.; FENG, X.; LI, H. Accuracy assessment of seven global land cover datasets over China. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 125, p. 156–173, 2017.

YU, L.; LIANG, L.; WANG, J.; ZHAO, Y.; CHENG, Q.; HU, L.; LIU, S.; YU, L.; WANG, X.; ZHU, P.; LI, X.; XU, Y.; LI, C.; FU, W.; LI, X.; LI, W.; LIU, C.; CONG, N.; ZHANG, H.; SUN, F.; B, X.; XIN, Q.; LI, D.; YAN, D.; ZHU, Z.; GOODCHILD, M. F.; GONG, P. Meta-discoveries from a synthesis of satellite- based land-cover mapping research. **International Journal of Remote Sensing**, v. 35, n. 13, p. 4573–4588, 2014a.

YU, L.; WANG, J.; GONG, P. Improving 30 m global land-cover map FROM-GLC with time series MODIS and auxiliary data sets: a segmentation-based approach. **International Journal of Remote Sensing**, v. 34, n. 16, p. 5851–5867, 2013.

YU, L.; WANG, J.; LI, X.; LI, C.; ZHAO, Y.; GONG, P. A multi-resolution global land cover dataset through multisource data aggregation. **Science China Earth Sciences**, v. 57, n. 10, p. 2317–2329, 2014b.

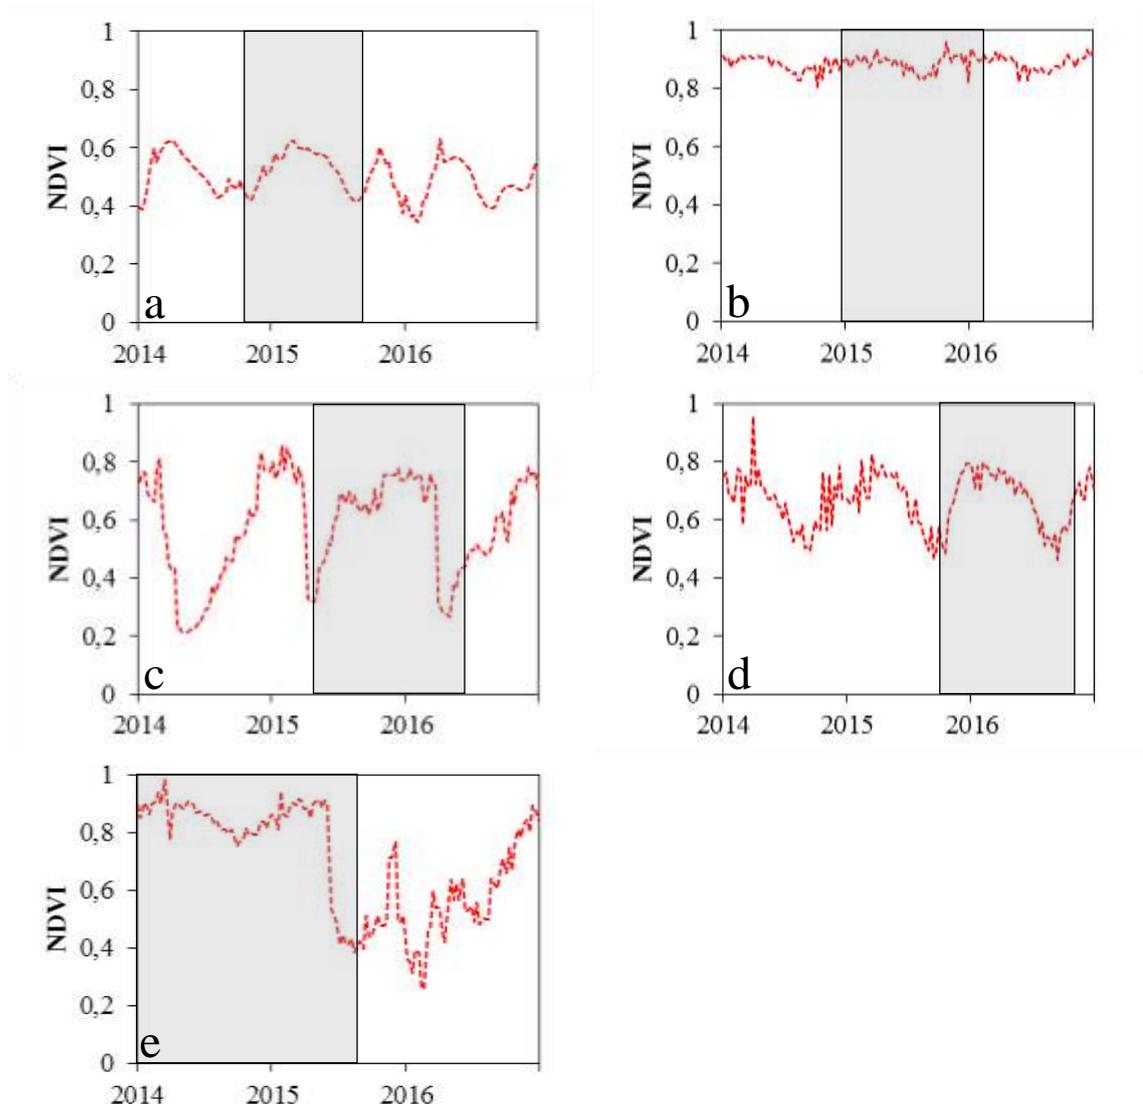
ZHU, C.; LU, D.; VICTORIA, D.; DUTRA, L. V. Mapping fractional cropland distribution in Mato Grosso, Brazil using time series MODIS enhanced vegetation index and Landsat Thematic Mapper data. **Remote Sensing**, v. 8, n. 22, p. 1–14, 2016.

ZHU, Z.; WOODCOCK, C. E. Continuous change detection and classification of land cover using all available Landsat data. **Remote Sensing of Environment**, v. 144, p. 152–171, 2014.

ZOUNGRANA, B.; CONRAD, C.; AMEKUDZI, L.; THIEL, M.; DA, E.; FORKUOR, G.; LÖW, F. Multi-Temporal Landsat Images and Ancillary Data for Land Use/Cover Change (LULCC) Detection in the Southwest of Burkina Faso, West Africa. **Remote Sensing**, v. 7, n. 9, p. 12076–12102, 2015.

APÊNDICES

Apêndice 1 - Perfis NDVI característicos das classes pastagem (a), floresta (b), agricultura (c), cerrado (d) e desmatamento (e).



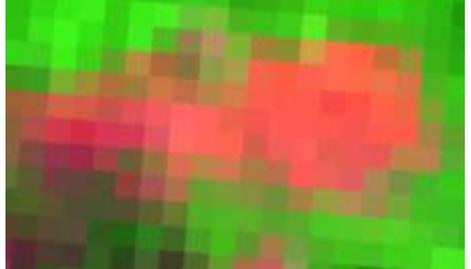
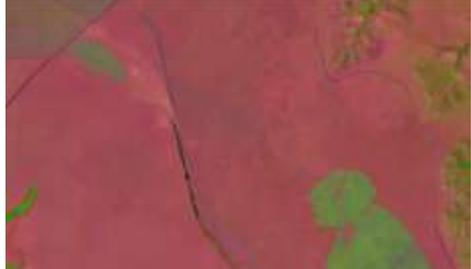
Apêndice 2 – Exemplos de amostras de treinamento mapeadas na Bacia Hidrográfica do Alto Rio Paraná.

(continua)

Classe Mapeada	Landsat OLI - RGB (654)	Google Earth
(10) Floresta		
(11) Floresta plantada		
(20) Agricultura		
(21) Agricultura em transição.		
(22) Campos de arroz		
(23) Vegetação frutífera		

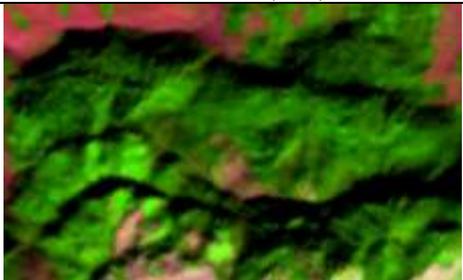
Apêndice 2 – Exemplos de amostras de treinamento mapeadas na Bacia Hidrográfica do Alto Rio Paraná.

(continuação)

Classe Mapeada	Landsat OLI - RGB (654)	Google Earth
(30) Pastagem		
(40) Água		
(60) Solo exposto		
(61) áreas arenosas/ mineração		
(70) Cerrado/ vegetação arbustiva		
(80) Queimada		

Apêndice 2 - Exemplos de amostras de treinamento mapeadas na Bacia Hidrográfica do Alto Rio Paraná.

(conclusão)

Classe Mapeada	Landsat OLI - RGB (654)	Google Earth
(888) Sombra		
(999) Nuvem		

Apêndice 3 – Matriz de confusão para BHAPR-1985 baseado a pixel.

Classes reais	Classes atribuídas pelo classificador										Total	AU
	10	20	30	40	50	60	70	90	888	999		
10	186	12	12	20	0	0	13	0	19	1	263	0,71
20	8	194	13	26	0	0	5	0	19	0	265	0,73
30	10	84	267	65	0	0	59	1	22	0	508	0,53
40	1	1	1	25	0	0	0	0	1	0	29	0,86
50	0	2	1	0	9	0	0	0	1	0	13	0,69
60	1	0	0	0	0	0	0	0	0	0	1	0,00
70	17	26	18	23	0	0	138	2	21	0	245	0,56
90	0	3	0	2	0	0	4	6	1	0	16	0,38
888	0	0	0	0	0	0	0	0	0	0	0	-
999	0	0	0	0	0	0	0	0	0	0	0	-
Total	223	322	312	161	9	0	219	9	84	1	-	-
AP	0,83	0,60	0,86	0,16	1,00	-	0,63	0,67	0,00	0,00	-	-

Nota: AU – Acurácia do Usuário; AP – Acurácia do Produtor.

Apêndice 4 – Matriz de confusão para BHAPR-1985 baseado em objetos.

Classes reais	Classes atribuídas pelo classificador										Total	AU
	10	20	30	40	50	60	70	90	888	999		
10	184	16	8	19	0	0	16	12	5	0	260	0,71
20	6	198	12	18	0	2	7	18	2	0	263	0,75
30	11	81	274	26	0	1	58	53	3	0	507	0,54
40	1	1	0	23	0	0	1	2	0	0	28	0,82
50	0	2	1	1	9	0	0	0	0	0	13	0,69
60	1	0	0	0	0	0	0	0	0	0	1	0,00
70	22	22	19	18	0	0	141	17	3	0	242	0,58
90	0	3	0	1	0	0	5	7	0	0	16	0,44
888	0	0	0	0	0	0	0	0	0	0	0	-
999	0	0	0	0	0	0	0	0	0	0	0	-
Total	225	323	314	106	9	3	228	109	13	0	-	-
AP	0,82	0,61	0,87	0,22	1,00	0,00	0,62	0,06	0,00	-	-	-

Nota: AU – Acurácia do Usuário; AP – Acurácia do Produtor.

Apêndice 5 – Matriz de confusão para BHAPR-2015 baseado a pixel.

Classes reais	Classes atribuídas pelo classificador										Total	AU
	10	20	30	40	50	60	70	90	888	999		
10	208	32	4	0	0	0	2	0	1	0	247	0,84
20	10	260	25	0	0	1	2	0	0	0	298	0,87
30	5	73	227	0	0	0	9	0	0	0	314	0,72
40	0	0	0	18	0	0	0	0	1	0	19	0,95
50	0	0	0	0	13	0	0	0	0	0	13	1,00
60	0	0	0	0	0	0	0	0	0	0	0	-
70	8	12	2	0	0	0	39	0	0	0	61	0,64
90	0	0	0	0	0	0	0	0	0	0	0	-
888	0	0	0	0	0	0	0	0	0	0	0	-
999	0	0	0	0	0	0	0	0	0	0	0	-
Total	231	377	258	18	13	1	52	0	2	0	-	-
AP	0,90	0,69	0,88	1,00	1,00	0,00	0,75	-	0,00	-	-	-

Nota: AU – Acurácia do Usuário; AP – Acurácia do Produtor.

Apêndice 6 – Matriz de confusão para BHAPR-2015 baseado em objetos.

Classes reais	Classes atribuídas pelo classificador										Total	AU
	10	20	30	40	50	60	70	90	888	999		
10	202	40	0	1	0	0	4	0	0	0	247	0,82
20	5	263	27	0	0	1	2	0	0	0	298	0,88
30	5	78	222	0	0	1	8	0	0	0	314	0,71
40	0	2	0	16	0	0	0	0	1	0	19	0,84
50	0	0	0	0	13	0	0	0	0	0	13	1,00
60	0	0	0	0	0	0	0	0	0	0	0	-
70	12	17	4	0	0	0	29	0	0	0	62	0,47
90	0	0	0	0	0	0	0	0	0	0	0	-
888	0	0	0	0	0	0	0	0	0	0	0	-
999	0	0	0	0	0	0	0	0	0	0	0	-
Total	224	400	253	17	13	2	43	0	1	0	-	-
AP	0,90	0,66	0,88	0,94	1,00	0,00	0,67	-	0,00	-	-	-

Nota: AU – Acurácia do Usuário; AP – Acurácia do Produtor.

Apêndice 7 – Número de pontos de validação (PV), Precisão Global (PG) e Índice Kappa dos mapeamentos da cobertura solo de 1985 e 2015 para as sub-bacias da BHAPR.

Nº	Sub-bacia	1985					2015				
		Baseada a Pixel			Baseada em Objetos		Baseada a Pixel			Baseada em Objetos	
		PV	PG	Kappa	PG	Kappa	PV	PG	Kappa	PG	Kappa
	Confluência entre os rios Grande e										
1	Parnaíba	1	1	-	1	-	-	-	-	-	
2	Alto Iguazu	38	0,92	0,78	0,95	0,85	35	0,83	0,54	0,89	0,69
3	Alto Parapanema	90	0,60	0,48	0,61	0,49	55	0,78	0,70	0,73	0,63
4	Baixo rio Grande	45	0,53	0,35	0,58	0,41	29	0,79	0,65	0,79	0,65
5	Alto Tietê	69	0,55	0,42	0,55	0,42	47	0,83	0,74	0,77	0,63
6	Baixo Iguazu	60	0,70	0,61	0,67	0,56	34	0,79	0,66	0,88	0,79
7	Baixo Parapanema	33	0,70	0,59	0,73	0,63	27	0,96	0,93	0,85	0,71
8	Alto rio Grande	40	0,20	0,10	0,20	0,10	30	0,97	0,95	0,93	0,90
9	Baixo Tietê	41	0,71	0,59	0,71	0,59	32	0,81	0,70	0,72	0,56
10	Médio rio Grande	39	0,46	0,34	0,54	0,41	30	0,80	0,72	0,77	0,67
11	Paraná, Samambaia e outros	14	0,79	0,66	0,79	0,67	7	0,71	0,53	0,71	0,53
12	Paraná, Aporé ou do Peixe, Corrente, Verde	58	0,62	0,50	0,69	0,58	39	0,72	0,53	0,67	0,48
13	Paraná, Feio ou Aguapeí	25	0,64	0,50	0,68	0,55	11	0,91	0,84	1,00	1,00
14	Paraná, Guaçu, São Francisco Verdadeiro e outro	48	0,73	0,63	0,71	0,61	9	0,89	0,80	0,89	0,80
15	Paraná, Iguatemi, Maracaí, Amambaí	30	0,70	0,62	0,67	0,57	27	0,78	0,62	0,78	0,62
16	Paraná, Laranjal e outros	3	0,67	0,57	0,67	0,57	3	1,00	1,00	1,00	1,00
17	Paraná, Meia Ponte	22	0,64	0,49	0,64	0,50	21	0,90	0,88	0,86	0,82
18	Paraná, Peixe e outros	18	0,72	0,57	0,72	0,58	20	0,80	0,72	0,90	0,85
19	Paraná, Preto	14	0,86	0,81	0,86	0,81	8	1,00	1,00	0,75	0,62
20	Paraná, Quitéria, São José dos Dourados	18	0,61	0,48	0,61	0,47	16	0,69	0,52	0,81	0,71
21	Rio Araguari ou das Velhas	37	0,27	0,11	0,19	0,02	21	0,81	0,75	0,76	0,69
22	Rio Claro	25	0,76	0,71	0,68	0,61	16	0,75	0,60	0,75	0,54
23	Rio dos Bois	53	0,68	0,58	0,64	0,53	40	0,73	0,57	0,75	0,62
24	Rio Invinheima	45	0,82	0,75	0,82	0,75	39	0,82	0,69	0,74	0,56
25	Rio Ivaí	57	0,74	0,64	0,72	0,61	42	0,67	0,50	0,67	0,50
26	Rio Mogi-Guaçu	55	0,455	0,20	0,60	0,40	42	0,83	0,73	0,95	0,91
27	Rio Pardo	51	0,75	0,65	0,75	0,65	42	0,76	0,59	0,79	0,60
28	Rio Parnaíba	69	0,45	0,31	0,48	0,35	41	0,73	0,64	0,68	0,57
29	Rio Piquiri	34	0,676	0,54	0,68	0,54	28	0,86	0,78	0,86	0,79
30	Rio São Bartolomeu	40	0,53	0,27	0,63	0,40	38	0,79	0,72	0,82	0,76
31	Rio Sapucaí	38	0,39	0,26	0,34	0,23	29	0,86	0,80	0,72	0,62
32	Rio Sucuriú	32	0,84	0,78	0,84	0,78	24	0,79	0,68	0,75	0,62
33	Rio Tibagi	33	0,76	0,67	0,76	0,67	27	0,85	0,76	0,78	0,63
34	Rio Tijuco	22	0,41	0,26	0,41	0,26	18	0,78	0,70	0,61	0,46
35	Rio Verde	28	0,79	0,63	0,79	0,63	25	0,80	0,68	0,68	0,54

Apêndice 8 – Comparação de áreas (km²) entre os produtos de cobertura do solo para a BHARP.

Classe	BHAPR	CCI	GLCNMO	GlobCover	Globeland30	MODIS
Floresta	196314,0	79205,7	111896,7	172175,3	153466,9	78205,4
Agricultura	403701,8	610339,2	512554,9	640631,0	532090,0	304149,3
Pastagem	230292,8	37298,0	25679,3	6,7	116482,1	69815,6
Água	16662,8	17106,6	11597,2	14277,8	17691,0	7917,2
Urbano	10377,6	9483,0	11003,6	2130,5	12077,0	17157,6
Solo exposto	999,4	146,3	1,3	75,7	485,4	4,4
Cerrado/ Vegetação arbustiva	39849,4	141957,2	219375,9	65725,5	57127,7	411082,5
Não Comparável	678,1	3339,7	6766,8	3853,1	9451,2	10543,7

Apêndice 9 – Área (km²) e variação de área (km²) para as 10 classes de cobertura do solo mapeadas para as sub-bacias da BHAPR.

(continua)

Classe	Período	Sub-bacia											
		1	2	3	4	5	6	7	8	9	10	11	12
10	1985	65,2	21680,0	11677,1	2251,3	7500,7	9470,6	1795,8	3385,0	1506,7	2028,2	1692,7	3336,8
	2015	94,3	20923,7	14002,3	2365,4	8596,6	11317,2	2219,4	7029,8	1666,7	3354,5	891,8	6324,4
	Variação	29,1	-756,3	2325,3	114,1	1095,9	1846,6	423,6	3644,7	160,0	1326,3	-800,9	2987,6
20	1985	281,4	4148,8	18098,0	12566,0	18698,5	13649,7	8083,9	4493,4	9311,7	9587,4	1168,5	4120,1
	2015	255,6	7826,8	28145,6	17440,6	24039,1	13529,7	14317,9	3754,8	19412,9	11623,9	3312,3	15715,1
	Variação	-25,8	3678,0	10047,6	4874,6	5340,6	-120,1	6234,0	-738,6	10101,2	2036,5	2143,9	11595,0
30	1985	94,1	6497,0	13283,1	11015,7	10736,0	6844,1	12764,5	7791,2	12348,9	4820,7	3647,1	14526,3
	2015	294,2	4846,1	9077,1	8409,7	7301,8	6449,7	7172,2	10112,7	4993,0	5310,9	3327,2	11754,2
	Variação	200,0	-1650,9	-4206,1	-2606,0	-3434,2	-394,5	-5592,3	2321,5	-7355,9	490,1	-319,8	-2772,2
40	1985	136,6	259,4	988,4	1185,6	628,2	427,6	439,3	650,0	877,2	679,1	391,3	465,9
	2015	102,4	350,4	1052,3	1030,3	592,3	551,6	677,8	445,8	1318,8	627,5	1031,6	492,8
	Variação	-34,2	91,0	63,9	-155,2	-35,9	124,1	238,5	-204,3	441,7	-51,7	640,3	26,9
50	1985	4,6	369,1	311,9	255,9	2931,9	161,7	180,3	114,6	281,2	232,4	9,4	32,0
	2015	6,5	519,3	336,8	330,8	3054,5	159,6	211,6	172,4	286,2	305,7	10,0	58,9
	Variação	1,9	150,2	24,9	74,9	122,6	-2,1	31,3	57,7	5,0	73,2	0,6	26,9
60	1985	1,5	106,4	303,6	0,0	60,0	184,3	0,3	1,1	6,2	2,0	2,3	40,3
	2015	2,3	332,3	273,0	0,0	137,6	12,8	3,0	169,8	0,5	1,0	13,5	0,0
	Variação	0,8	225,9	-30,5	0,0	77,6	-171,5	2,7	168,6	-5,7	-0,9	11,1	-40,3
70	1985	209,0	2003,9	8165,5	2735,5	2834,2	1260,7	1361,3	9588,4	3367,7	7617,9	1743,8	14284,5
	2015	42,8	481,6	486,5	468,4	201,1	151,6	85,1	4410,0	72,7	3898,8	117,5	2867,3
	Variação	-166,2	-1522,3	-7679,0	-2267,0	-2633,0	-1109,1	-1276,2	-5178,4	-3295,0	-3719,1	-1626,3	-11417,2
80	1985	5,5	123,5	499,4	32,5	317,9	90,2	59,9	163,2	48,7	104,2	47,9	401,0
	2015	0,0	2,4	23,9	0,0	0,0	0,0	0,0	0,0	0,0	52,1	0,0	0,0
90	1985	0,0	235,0	12,9	0,1	75,8	164,4	0,2	34,9	0,0	114,1	0,0	20,8
	2015	0,0	152,3	11,3	0,2	4,0	152,8	0,8	127,4	0,0	14,0	0,0	19,6
100	1985	0,0	16,0	91,7	0,0	201,9	68,9	0,0	0,0	0,1	0,0	0,0	0,0
	2015	0,0	4,4	13,1	0,0	2,6	0,5	0,0	0,0	0,0	0,0	0,0	0,0

Apêndice 11 – Área (km²) e variação de área (km²) para as 10 classes de cobertura do solo mapeadas para as sub-bacias da BHAPR.

(conclusão)

Classe	Período	Sub-bacia										
		25	26	27	28	29	30	31	32	33	34	35
10	1985	10386,6	3795,1	6970,7	3293,7	4977,1	2496,7	3378,2	1995,6	8502,7	1876,0	2789,6
	2015	8762,5	4413,7	6592,1	6102,5	4920,9	5661,8	4734,2	5530,5	9642,7	3582,1	5476,3
	Variação	-1624,1	618,7	-378,5	2808,9	-56,1	3165,1	1356,1	3534,9	1140,0	1706,1	2686,6
20	1985	12120,1	20708,0	2707,5	8891,6	11237,8	6907,0	5383,6	2636,2	8592,3	3787,1	1817,7
	2015	21392,8	23238,2	10130,2	15238,7	15893,6	12669,8	9207,7	6109,4	11818,3	5314,7	5271,7
	Variação	9272,7	2530,1	7422,7	6347,1	4655,8	5762,8	3824,1	3473,2	3226,1	1527,6	3454,0
30	1985	13260,6	7115,4	11422,6	7288,0	7888,4	4750,1	10002,9	8597,3	4507,0	4298,1	5448,6
	2015	6582,3	6128,0	17049,6	7297,8	3654,4	6554,9	9560,5	12091,6	3208,1	4210,6	10298,1
	Variação	-6678,3	-987,4	5626,9	9,8	-4233,9	1804,8	-442,3	3494,2	-1298,9	-87,5	4849,5
40	1985	142,4	174,2	81,7	493,8	81,8	223,9	625,4	114,5	181,7	90,5	12,0
	2015	130,8	129,1	471,6	619,2	76,3	482,8	474,2	158,5	277,1	73,6	43,4
	Variação	-11,6	-45,1	389,8	125,4	-5,4	258,9	-151,2	44,0	95,4	-16,9	31,4
50	1985	169,9	682,8	172,6	116,7	93,9	741,6	153,3	3,8	142,0	39,8	1,3
	2015	219,4	775,3	184,5	159,8	150,7	776,6	234,9	10,2	272,2	40,7	3,9
	Variação	49,5	92,4	11,8	43,0	56,8	35,1	81,6	6,4	130,1	1,0	2,6
60	1985	0,5	31,9	69,6	85,6	0,0	26,7	24,5	104,9	12,1	8,6	195,6
	2015	14,5	6,5	127,0	16,9	1,2	7,8	58,6	20,4	75,1	3,7	127,8
	Variação	14,0	-25,5	57,4	-68,7	1,2	-19,0	34,1	-84,5	63,1	-4,9	-67,8
70	1985	957,1	2899,1	15191,1	15865,0	363,2	17366,6	5866,2	11136,1	3436,5	4356,8	11901,1
	2015	44,6	969,0	2341,6	6884,4	36,6	6873,0	1172,2	863,7	140,8	1280,5	1059,0
	Variação	-912,5	-1930,1	-12849,5	-8980,6	-326,6	-10493,6	-4694,0	-10272,4	-3295,7	-3076,3	-10842,1
80	1985	140,9	218,5	276,5	290,2	63,9	598,6	37,5	198,1	102,1	45,2	115,0
	2015	0,8	1,8	0,0	10,7	0,0	86,7	0,0	0,0	30,6	0,0	0,0
90	1985	55,8	41,8	0,0	0,6	47,6	1,2	45,3	5,1	25,9	3,5	0,0
	2015	130,9	27,8	0,1	0,0	21,8	2,7	81,5	10,2	40,8	0,9	1,9
100	1985	47,8	19,4	0,0	0,0	0,0	0,0	4,2	0,0	1,6	0,0	0,0
	2015	6,5	0,2	0,0	0,0	0,3	0,0	0,1	0,0	0,0	0,0	0,0

