

**Universidade de Brasília – UnB**  
**Faculdade UnB Planaltina – FUP**  
**Programa de Pós-Graduação em Ciências Ambientais– PPGCA**  
**Área de Concentração – Manejo e Conservação de Recursos Naturais**

---

**APLICAÇÃO DE MÉTODOS DE CLASSIFICAÇÃO  
SUPERVISIONADA EM IMAGENS DO SENTINEL-2, COMO  
SUPORTE AO CADASTRO AMBIENTAL RURAL**

**RAPHAEL ALBERTO FUHR SOLARI**

Brasília/ DF  
Outubro de 2017

**Universidade de Brasília – UnB**  
**Faculdade UnB Planaltina – FUP**  
**Programa de Pós-Graduação em Ciências Ambientais– PPGCA**  
**Área de Concentração – Manejo e conservação de recursos naturais**

---

**APLICAÇÃO DE MÉTODOS DE CLASSIFICAÇÃO  
SUPERVISIONADA EM IMAGENS DO SENTINEL-2, COMO  
SUPORTE AO CADASTRO AMBIENTAL RURAL**

**RAPHAEL ALBERTO FUHR SOLARI**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Ambientais (PPGCA) da Faculdade UnB Planaltina (FUP) como parte dos requisitos para obtenção do título de Mestre em Ciências Ambientais, sob orientação do prof. Dr. Rômulo José da Costa Ribeiro

Brasília/ DF  
Outubro de 2017

**Universidade de Brasília – UnB**  
**Faculdade UnB Planaltina – FUP**  
**Programa de Pós-Graduação em Ciências Ambientais– PPGCA**  
**Área de Concentração – Manejo e conservação de recursos naturais**

---

**Título:** APLICAÇÃO DE MÉTODOS DE CLASSIFICAÇÃO SUPERVISIONADA EM IMAGENS DO SENTINEL-2, COMO SUPORTE AO CADASTRO AMBIENTAL RURAL

Mestrando: Raphael Alberto Fuhr Solari

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Ambientais (PPGCA) da Faculdade UnB Planaltina (FUP) como parte dos requisitos para obtenção do título de Mestre em Ciências Ambientais.

Brasília, 31 de outubro de 2017.

---

Rômulo José da Costa Ribeiro – Orientador  
Professor Adjunto da Universidade de Brasília  
Doutor em Arquitetura e Urbanismo pela Universidade de Brasília

---

Gustavo Macedo de Mello Baptista - Membro  
Professor Adjunto da Universidade de Brasília  
Doutor em Geologia pela Universidade de Brasília

---

Rejane Ennes Cicerelli - Membro  
Professora Adjunta da Universidade de Brasília  
Doutora em Ciências Cartográficas pela Universidade Estadual de São Paulo

**Brasília/ DF**  
**Outubro de 2017**

Fuhr Solari, Raphael Alberto

FAP642a APLICAÇÃO DE MÉTODOS DE CLASSIFICAÇÃO SUPERVISIONADA EM IMAGENS DO SENTINEL-2, COMO SUPORTE AO CADASTRO AMBIENTAL RURAL / Raphael Alberto Fuhr Solari; orientador Rômulo José da Costa Ribeiro. -- Brasília, 2017.

150 p.

Dissertação (Mestrado - Mestrado em Ciências Ambientais)  
- Universidade de Brasília, 2017.

1. métodos de classificação supervisionada. 2. Sentinel  
2. 3. Cadastro Ambiental Rural. 4. Mato Grosso. 5. Assentamentos. I.  
Ribeiro, Rômulo José da Costa , orient.  
II. Título.

Ficha catalográfica elaborada automaticamente, com  
os dados fornecidos pelo(a) autor(a)

## AGRADECIMENTOS

Ao grande professor Rômulo José da Costa Ribeiro, que por anos vêm acreditando no meu potencial e me auxiliando, enriquecendo o meu conhecimento. Pela sua ajuda, sabedoria, paciência, dedicação e incentivo, trazendo conforto nas horas necessárias e broncas nas horas oportunas.

Agradecimentos ao Projeto “Regularização Ambiental e Diagnóstico dos Sistemas Agrários dos Assentamentos da Região Norte do estado do Mato Grosso”, financiado pelo Instituto Nacional de Colonização e Reforma Agrária (Incra), em colaboração com a Universidade de Brasília (UnB), que foi fundamental para o desenvolvimento deste trabalho. Muito obrigado a todos os professores doutores que integram esse rico Projeto e que, em suas mais distintas áreas, puderam contribuir para meu aprendizado.

Agradeço à minha família, em particular minha mãe, que esteve ao meu lado em todos os momentos, que nunca desistiu de confiar naquilo que acreditava e também sempre teve paciência com meus infinitos questionamentos durante a escola. Ao meu pai, homem íntegro e exemplo de ser humano. Aos meus irmãos que sempre me apoiaram. À minha avó, pelas conversas construtivas, pelo apoio e pela preocupação.

A minha namorada, Hikari, por ter me auxiliado de diversas formas durante esse momento, me auxiliando nas pesquisas enquanto já não encontrava nada mais, por compreender minha ausência, por simplesmente estar ao meu lado nos momentos que precisava e quando apenas sua presença me bastava. Obrigado por não desistir de mim.

Aos professores Rejane Ennes Cicerelli e Gustavo Macedo de Mello Baptista por prontamente terem aceitado em participar da minha banca e pelas riquíssimas contribuições ao longo do trabalho.

Aos meus amigos, Carla Silva e Liniker Guimarães, por terem me apoiado no decorrer da dissertação, pelas conversas motivadoras durante a noite, pelos auxílios durante a escrita, pela tia mãe do Liniker, que tão prontamente fez os cafés que foram fundamentais para a elaboração deste texto, muito obrigado.

Aos colegas de trabalho do Projeto RADIS, que de uma maneira ou outra contribuíram para o desenvolvimento desta pesquisa.

À Universidade de Brasília pelo ambiente de aprendizado e ao Programa de Ciências Ambientais, docentes e colegas, por todo o conhecimento, pelas amizades e pela experiência adquirida.

## RESUMO

O Cadastro Ambiental Rural (CAR) é uma ferramenta de controle da situação ambiental rural nacional, principalmente para Áreas de Preservação Permanentes (APP) e Reservas Legais (RL). Nas análises de uso e ocupação do solo realizadas durante a elaboração do CAR, são utilizadas imagens de satélites, como não há um procedimento definido para extração de dados, esta dissertação visa avaliar seis métodos de classificação supervisionada: *Spectral Angler Mapper* (Mapeamento pelo Ângulo Espectral) (SAM), *Spectral Correlation Mapper* (Mapeamento pela Correlação Espectral) (SCM), *Máxima Verossimilhança* (Maxver), *Minimum Distance* (Distância Mínima), *Mahalanobis Distance* (Distância Mahalanobis), *Feature Space* (Feição Espacial), a partir de imagens do satélite *Sentinel-2*, em vinte assentamentos localizados no norte do estado do Mato Grosso. A fim de identificar o método que melhor se adequa para dar suporte ao CAR. A classificação de cada assentamento foi extraída separadamente da classificação global. Tais resultados foram analisados por meio da Matriz de Confusão, Índice *Kappa*, *Accuracy Assessment*, (Avaliação de Precisão) e *Image Difference* (Diferença entre Imagens), para avaliar o nível de acurácia de cada método em todos os assentamentos. Todos os métodos demonstraram ótimos resultados no nível de acurácia e Índice *Kappa*, mas, para suporte ao CAR, o método que apresentou melhor acurácia e variância mínima entre as classes foi o SCM.

.

Palavras chaves: métodos de classificação supervisionada, Sentinel-2, Cadastro Ambiental Rural, Mato Grosso, Assentamentos.

## **ABSTRACT**

The Environmental Rural Registry (CAR, in Portuguese) is a tool to control the national rural environmental situation, mainly for Permanent Preservation Areas (PPA) and Legal Reserves (LR). In the analysis of land use and occupation made during the elaboration of the CAR, satellite images are used. As there is no set procedure for this, this dissertation aims to test the application of six methods of supervised classification: Spectral Angle Mapper (SAM), Spectral Correlation Mapper (SCM), Maximum Likelihood (Maxver), Minimum Distance, Mahalanobis Distance, Feature Space, in images of the Sentinel-2 satellite, in twenty settlements located in the north of the state of Mato Grosso. To obtain the level of accuracy of each method, in all the individual settlements, the results were analyzed through the Confusion Matrix, Kappa Index, Accuracy Assessment, Image Difference. All methods demonstrated good averages in the Accuracy Assessment and Kappa Index. However, to be the method that gives better support to the CAR, it is necessary to present a minimum variance between the classes used in this work (vegetation and anthropized area) and to have consistent results throughout the study area. Under these conditions, the methods that obtained the best result were the Mahalanobis Distance and the SCM.

**Keywords:** Environmental Rural Registry, supervised classification methods, Sentinel-2, Confusion Matrix, Kappa Index, Accuracy Assessment, Image Difference, Mahalanobis Distance, SCM.

## SUMÁRIO

<b>1. INTRODUÇÃO</b> .....	<b>10</b>
<b>2. APRESENTAÇÃO</b> .....	<b>12</b>
<b>3. PROBLEMÁTICA E JUSTIFICATIVA</b> .....	<b>13</b>
<b>3.1 Problemática</b> .....	<b>13</b>
<b>3.2 Justificativa</b> .....	<b>13</b>
<b>4. OBJETO DE ESTUDO E OBJETIVOS</b> .....	<b>14</b>
<b>4.1 Objeto de Estudo</b> .....	<b>14</b>
<b>4.2 Objetivo Geral</b> .....	<b>14</b>
<b>4.3 Objetivo Específico</b> .....	<b>14</b>
<b>5. REVISÃO BIBLIOGRÁFICA</b> .....	<b>15</b>
<b>5.1 Legislação e Políticas Públicas</b> .....	<b>15</b>
5.1.1 Código Florestal .....	15
5.1.2 Cadastro Ambiental Rural (CAR) .....	20
5.1.3 Sistema de Cadastro Ambiental Rural (Sicar) .....	21
5.1.4 Sistema Integrado de Monitoramento e Licenciamento Ambiental (Simlam) – Mato Grosso .....	38
5.1.5 Sistema Mato-grossense de Cadastro Ambiental Rural (Simcar - MT) .....	40
5.1.6 Mapeamento Anual da Cobertura e Uso do Solo do Brasil (MapBiomias) .....	48
<b>5.2. Caracterização da área de estudo</b> .....	<b>51</b>
5.2.1 Bioma Amazônico .....	51
5.2.2 Histórico da ocupação agrícola no norte do estado do Mato Grosso .....	51
5.2.3 Situação fundiária no norte do estado do Mato Grosso .....	52
5.2.4 Histórico dos assentamentos .....	53
5.2.5 Tipos de assentamentos rurais .....	56
<b>5.3 Satélites</b> .....	<b>57</b>
5.3.1 Teoria do imageamento por satélite .....	57
5.3.2 <i>RapidEye</i> .....	61
5.3.3 <i>Landsat</i> .....	62
5.3.4 <i>Sentinel-2</i> .....	64
<b>5.4 Discussão sobre o mapeamento do uso da terra</b> .....	<b>68</b>
<b>5.5 Métodos de Classificação</b> .....	<b>69</b>
5.5.1 Teoria da Classificação Supervisionada .....	69
5.5.2 <i>Spectral Angle Mapper</i> (SAM) .....	71
5.5.3 <i>Spectral Correlation Mapper</i> (SCM) .....	73
5.5.4 <i>Minimum Distance</i> .....	74
5.5.5 Máxima Verossimilhança (Maxver) .....	75
5.5.6 <i>Mahalanobis Distance</i> .....	77
5.5.7 <i>Feature Space</i> .....	79
<b>5.6 Métodos de validação</b> .....	<b>80</b>
5.6.1 Matriz de Confusão .....	80
5.6.2 Índice <i>Kappa</i> .....	82
5.6.3 <i>Accuracy Assessment</i> .....	83
5.6.4 <i>Image Difference</i> .....	83
<b>6. MATERIAIS E MÉTODOS</b> .....	<b>85</b>
<b>6.1 Satélites</b> .....	<b>85</b>
6.1.1 <i>Sentinel-2</i> .....	85
<b>6.2 Mosaico</b> .....	<b>85</b>

<b>6.3 Classificações.....</b>	<b>86</b>
6.3.1 Classes .....	86
<b>6.4 Métodos de validação .....</b>	<b>88</b>
6.4.1 Matriz de confusão.....	88
6.4.2 <i>Image Difference</i> .....	89
<b>6.5 Área de estudo.....</b>	<b>90</b>
<b>7. RESULTADOS .....</b>	<b>92</b>
<b>8. DISCUSSÃO .....</b>	<b>131</b>
<b>9. CONSIDERAÇÕES FINAIS.....</b>	<b>142</b>
<b>10. REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>144</b>

## 1. INTRODUÇÃO

De acordo com o Ministério do Meio Ambiente (MMA), o Cadastro Ambiental Rural foi

Criado pela Lei nº 12.651/2012, no âmbito do Sistema Nacional de Informação sobre Meio Ambiente – Sinima, e regulamentado pela Instrução Normativa MMA nº 2, de 5 de maio de 2014, o Cadastro Ambiental Rural – CAR é um registro público eletrônico de âmbito nacional, obrigatório para todos os imóveis rurais, com a finalidade de integrar as informações ambientais das propriedades e posses rurais referentes às Áreas de Preservação Permanente - APP, de uso restrito, de Reserva Legal, de remanescentes de florestas e demais formas de vegetação nativa, e das áreas consolidadas, compondo base de dados para controle, monitoramento, planejamento ambiental e econômico e combate ao desmatamento. (MMA, 2016, p. sn)

Caracteriza-se como um cadastro autodeclaratório, realizado por meio da Internet, junto ao órgão ambiental competente de cada estado. Os benefícios que o CAR promove para o imóvel rural são, entre outros: o planejamento econômico, visão do uso e ocupação, possibilidade de o proprietário regularizar as suas APP e ou a RL, a suspensão de sanções impostas às propriedades que não estão dentro dos parâmetros da Lei, seguro agrícola, linhas de financiamentos (MMA, 2016). O proprietário que não realizar o cadastro ou não cumprir as exigências do órgão competente de cada estado, no âmbito da recuperação das áreas degradadas, dentro dos limites estabelecidos por lei, passa a não poder mais acessar os programas de benefício ao agricultor e não pode realizar a venda do imóvel até que a situação esteja regularizada (MMA, 2015).

Reiterado pela revisão do Código Florestal, Lei nº 12.651, de 25 de maio de 2012 (BRASIL, 2012a), o Decreto nº 7.830, de 17 de outubro de 2012, (BRASIL, 2012b) dispõe sobre o Sistema de Cadastro Ambiental Rural (Sicar), o Cadastro Ambiental Rural (CAR), estabelece normas de caráter geral aos Programas de Regularização Ambiental.

De acordo com o atual Código Florestal (art.12), toda propriedade rural tem manter, a título de Reserva Legal, sem prejuízo para as Áreas de Preservação Permanente, na Amazônia Legal:

- a) 80% (oitenta por cento), no imóvel situado em área de florestas;
- b) 35% (trinta e cinco por cento), no imóvel situado em área de cerrado;
- c) 20% (vinte por cento), no imóvel situado em área de campos gerais;

Nas demais regiões do país, deve-se manter 20% de vegetação nativa preservada da área do imóvel.

Dois aspectos relevantes sobre o atual Código Florestal são que a RL deverá ser realizada em menos de vinte anos e que as propriedades com até quatro módulos fiscais, que não possuem as áreas de RL preservadas até o ano de 2008, estão anistiadas. Porém, determina que qualquer degradação da RL, a partir do ano de 2008, terá de ser recuperada (LAUDARES, et al., 2014)

Segundo a Instrução Normativa n° 2/06, de maio de 2014 (MMA, 2014), na Seção 3, que se refere à degradação dos imóveis rurais, a análise da mesma deverá ser realizada pelo órgão competente do estado e o Sicar poderá dispor de mecanismos de análise automática, em que se destacam: vértices do perímetro do imóvel; diferença entre a área declarada no cadastro e a que consta no documento; reserva legal em percentual, de acordo com os parâmetros do atual Código Florestal (ACF), e as APP do imóvel. O órgão competente do estado pode realizar visitas ao imóvel rural e ou solicitar que o proprietário revise as informações declaradas.

Como o CAR e o Sicar utilizam imagens do satélite *RapidEye*, adquiridas pelo governo federal, as análises temporais, de 2008 até o presente, devem utilizar as imagens desse satélite. O Ministério do Meio Ambiente não divulga o método a ser utilizado para realizar essa análise temporal, só é possível afirmar em termos gerais como ela será realizada e que deverá operar da seguinte maneira: o técnico do órgão competente do estado irá averiguar se a área de RL fornecida pelo proprietário está dentro da porcentagem exigida pelo ACF e, a partir da análise das imagens do *RapidEye*, se a mesma se encontra preservada. Caso alguma dessas condições não atenda ao exigido por Lei, o proprietário será notificado. Na questão das APP, será utilizada a cota regular do corpo hídrico para aferir sua largura e averiguar se, nas imagens, o corpo hídrico possui as dimensões declaradas. Da mesma forma, topo de morro não se enquadra na anistia de 2008, assim, caso não cumpra as normas, o proprietário também será notificado (MMA, 2014).

Para compreender melhor o processo de análise do CAR, é preciso estudar não apenas a legislação ou o CAR, mas, também, é necessário analisar o material utilizado. No caso, os materiais com maior importância e valor investido são as imagens de satélite do *RapidEye*, adquiridas pelo governo federal.

## 2. APRESENTAÇÃO

Com a sanção da Lei nº 12.651, de 25 de maio de 2012, (BRASIL, 2012a), conhecida como o atual Código Florestal (ACF), foram criadas novas diretrizes para as áreas de proteção de cada bioma e para as Áreas de Preservação Permanente (APP). O ACF referendou o Cadastro Ambiental Rural (CAR), que tem por objetivo o diagnóstico e o controle da Reserva Legal e das (APP), por meio de comparação de imagens de satélite do ano de 2008 com as imagens disponíveis mais recentes.

Este trabalho se propõe a verificar a aplicação de seis métodos de classificação supervisionada, o *Spectral Angle Mapper* (SAM), o Máxima Verossimilhança (Maxver), *Spectral Correlation Mapper* (SCM), *Minimum Distance*, *Mahalanobis Distance*, *Feature Space* em duas cenas do satélite *Sentinel-2*.

A verificação se baseia na possibilidade de identificar um método de classificação supervisionado que otimize a análise a ser feita pelo CAR. Para tanto, as imagens abrangeram vinte assentamentos em sete municípios do norte do estado do Mato Grosso, todos eles sendo pertencentes ao projeto de “Regularização Ambiental e Diagnóstico dos Sistemas Agrários dos Assentamentos da Região Norte do Estado do Mato Grosso (RADIS-MT/FUP-UnB)”, um projeto do Instituto Nacional de Colonização e Reforma Agrária (Incra), em parceria com a Universidade de Brasília (UnB).

### **3. PROBLEMÁTICA E JUSTIFICATIVA**

#### **3.1 Problemática**

O Cadastro Ambiental Rural (CAR) é um programa federal, de abrangência nacional, que, entre outros objetivos, realiza uma análise temporal de propriedades e assentamentos rurais por meio de imagens de satélites, para mensurar se a área total desmatada está dentro dos limites estabelecidos pelo atual Código Florestal (BRASIL, 2012a). Considerando que o governo federal é responsável por realizar o CAR em assentamentos e propriedades rurais de até quatro módulos fiscais, qual método de classificação supervisionada apresenta melhor resultado para ser utilizado em análises sobre o uso e cobertura do solo?

#### **3.2 Justificativa**

A relevância deste estudo está no fato de contribuir para a identificação de um método de classificação supervisionada, que auxilie no processo do CAR e que possa diminuir o volume de trabalho dos governos estaduais e federal, tornando, conseqüentemente, as análises do CAR mais rápidas e eficientes.

A temática ambiental vem ganhando grande atenção dos estudiosos e da sociedade civil nas últimas décadas. Com o crescimento do desmatamento no Brasil, as exigências ambientais, nacionais e internacionais, provocaram a revisão do Código Florestal. A partir desta revisão, o Código Florestal foi atualizado, no qual foi referendado o CAR, um mecanismo fundamental de monitoramento de desmatamento. O CAR utiliza imagens de satélite e auxilia tanto no controle do desmatamento quanto na questão da regulação ambiental dos assentamentos e das propriedades rurais.

Como a demanda para o diagnóstico do uso e ocupação dos assentamentos e das propriedades rurais sobrecarrega os governos federal e estaduais, corresponsáveis pela análise do CAR, vê-se a necessidade de se agilizar tal processo. Considerando a existência de métodos de classificação supervisionada, amplamente difundidos, é possível testá-los para identificar qual método atende a essa necessidade. Para tanto, este estudo utilizará um recorte espacial do norte do estado do Mato Grosso.

## **4. OBJETO DE ESTUDO E OBJETIVOS**

### **4.1 Objeto de Estudo**

A utilização imagens do satélite *Sentinel-2* para suporte ao Cadastro Ambiental Rural (CAR), em assentamentos rurais no norte do estado do Mato Grosso, a partir de classificação supervisionada.

### **4.2 Objetivo Geral**

Identificar o método de classificação supervisionada mais adequado para suporte ao CAR, em assentamentos rurais no norte do estado do Mato Grosso.

### **4.3 Objetivo Específico**

- i. Verificar a aplicabilidade das imagens do satélite *Sentinel-2* para análise de uso da solo, em assentamentos rurais no norte do estado do Mato Grosso.
- ii. Avaliar a viabilidade de métodos de classificação supervisionada para identificação do uso do solo, em assentamentos rurais no norte do estado do Mato Grosso, a fim de subsidiar a análise do CAR pelos órgãos estaduais competentes.

## **5. REVISÃO BIBLIOGRÁFICA**

### **5.1 Legislação e Políticas Públicas**

#### **5.1.1 Código Florestal**

O Antigo Código Florestal (ACF) era regulado pela Lei nº 4.771, de 15 de setembro de 1965 (BRASIL, 1965), após 47 anos de implementação o código tornou-se obsoleto, uma vez que não acompanhava mais as dinâmicas de ocupação agrícola nem os padrões de preservação nacionais e internacionais.

O debate do Código Florestal no Congresso Nacional levou 13 anos para aprovar todas as mudanças, dando origem ao Atual Código Florestal (ACF) que regula a exploração, a conservação e a recuperação da vegetação nativa em todo o território nacional. O ACF determina a área que pode ser utilizada na propriedade rural, com exceção da exploração agrossilvipastoril que pode ser realizada dentro da Reserva Legal (RL), conforme os critérios estabelecidos na Lei.

O ACF é de suma importância para a restauração, preservação e conservação dos nossos biomas, correspondente a 62%, cerca de 530 milhões de hectares (Mha), do Brasil. Desse total, 40% estão em áreas de conservação de domínio público ou em terras indígenas, aproximadamente, 212 Mha. As demais áreas de vegetação nativa estão ou em propriedades privadas ou em terras públicas, ainda sem designação. O que reforça a importância de conservar a vegetação nativa que está fragmentada dentro das propriedades privadas (SOARES-FILHO, 2013).

Apesar de o ACF estar em vigor desde 2012, a regulamentação e aprovação de algumas de suas diretrizes em nível estadual está em processo de análise pelo Supremo Tribunal Federal (STF). As alterações propostas podem gerar mudanças significativas que poderão tornar os métodos de controle e coerção mais severos para com quem suprimiu vegetação nativa além do permitido no passado. As diretrizes apontam, ainda, para um avanço com referência aos métodos de conservação da vegetação nativa.

As mudanças no Antigo Código Florestal conduzidas pelo ACF motivaram intensos debates, devido às grandes perdas relativas à conservação ambiental (SILVA et al., 2012, BRANCALION et al., 2016). Como o Brasil é um país rico em recursos naturais, e com importante papel na regulação dos serviços ecossistêmicos da biosfera, os efeitos colaterais da nova legislação podem afetar a população desde escala regional até mundial.

A Áreas de Reserva Legal (RL) e Preservação Permanente (APP) são de suma importância para a manutenção dos serviços ecossistêmicos, como por exemplo, a proteção à cobertura florestal colabora para a regulação dos ciclos biogeoquímicos, filtragem de poluentes, controle da erosão, função-tampão, manutenção do fluxo gênico de fauna e flora, preservação dos recursos hídricos e da paisagem, estabilização geológica e da biodiversidade, proteção do solo (NUNES et al., 2017) (GUIDOTTI et al., 2016).

Conforme o art. 4º do ACF, as áreas mais relevantes, consideradas como APP em zonas rurais ou urbanas, são: as faixas marginais de qualquer curso d'água natural perene e intermitente, excluídos os efêmeros, desde a borda da calha do leito regular; as áreas no entorno dos lagos e lagoas naturais; as áreas no entorno dos reservatórios d'água artificiais decorrentes de barramento ou represamento de cursos d'água naturais; as encostas ou partes destas com declividade superior a 45°, equivalente a 100% na linha de maior declive; as restingas, como fixadoras de dunas ou estabilizadoras de mangues; os manguezais, em toda a sua extensão; as bordas dos tabuleiros ou chapadas, até a linha de ruptura do relevo, em faixa nunca inferior a 100 metros em projeções horizontais; no topo de morros, montes, montanhas e serras, com altura mínima de 100 metros e inclinação média maior que 25°, as áreas delimitadas a partir da curva de nível correspondente a 2/3 da altura mínima da elevação sempre em relação à base, devendo esta ser definida pelo plano horizontal determinado por planície ou espelho d'água adjacente ou nos relevos ondulados, pela cota do ponto de sela mais próximo da elevação; as áreas em altitude superior a 1.800 metros, qualquer que seja a vegetação; e em veredas, com projeção horizontal da faixa marginal de no mínimo 50 metros de largura a partir do espaço permanentemente brejoso e encharcado (BRASIL, 2012a).

Conforme o parágrafo 4º do art. 4º, fica dispensada a reserva da faixa de proteção nas acumulações naturais ou artificiais de água com superfície inferior a 1 hectare prevista nos incisos II e III do caput, vedada nova supressão de áreas de vegetação nativa, salvo autorização do órgão ambiental competente do Sistema Nacional do Meio Ambiente (Sisnama) (BRASIL, 2012a).

A delimitação da área designada para as RL são regidas pelos art. 12 e 13 do ACF. O tamanho da RL pode variar de tamanho, a depender do território. Na Amazônia Legal, o percentual varia de 80% a 20% (80% para formações florestais, 35% para formações de Cerrado e 20% em formações de campos gerais). No restante do país, a área destinada para a RL deve corresponder a 20% da propriedade. A Amazônia Legal engloba os Estados do Acre, Amapá, Amazonas, Mato Grosso, Pará, Roraima, Rondônia, e parte dos estados de Tocantins e Maranhão (ZAKIA, M.J., 2013).

Quanto às APP e RL, ocorreram alguns retrocessos com a implementação do ACF que diminuíram algumas exigências do Código Florestal de 1965 como: a exclusão das nascentes intermitentes em áreas de APP; o fim do enquadramento de lagos, com menos de um hectare, naturais ou feitos pelo homem, como áreas de APP; a diminuição do potencial da área de APP pela mudança da medição da largura do rio que passa a ser feita por meio da cota média em vez da cota máxima; o fim da exigência para a recuperação de APP em topo de morros, de RL em pequenas propriedades de até quatro módulos fiscais (SOARES-FILHO et al., 2014).

Um dos pontos de divergência na revisão do ACF, entre os ambientalistas e os grandes agricultores, foi o Art.4º(BRASIL, 2012a), que trata sobre a largura da APP em relação à largura do curso d'água. A revisão do Código passou a utilizar a calha regular do corpo hídrico, enquanto o antigo código utilizava o nível mais alto em faixa marginal. Segundo Laudares, Silva e Borges (2014b), essa alteração na Lei facilita a obtenção da calha já que é mais fácil estipular a calha regular do que o nível mais alto em faixa marginal, pois a cada período de cheia essa calha varia. Entretanto, cerca de 90% dos rios do Brasil possuem calhas inferiores a 5 metros e pelo ACF esses corpos hídricos são os que possuem a menor área de preservação (LAUDARES; SILVA; BORGES, 2014).

Outro ponto de conflito foram as APP em áreas de nascentes de rios, que também sofreram diminuição. Nas áreas de nascentes de rios a vegetação atua como um redutor de velocidade das águas pluviais, diminuindo, assim, os processos de compactação, erosão e lixiviação do solo, evitando também o assoreamento da nascente e aumentando a capacidade de infiltração da água no solo, abastecendo o lençol freático.

O Código Florestal também alterou o conceito de topos de morros, serras, montanhas e montes. Como resultado, 87% da proteção sobre essas áreas foram reduzidas (SOARES-FILHO et al., 2014). Para as APP em encostas declivosas, a necessidade de proteção foi mantida. Entretanto, a nova lei diminuiu as exigências para a recomposição da vegetação nativa em casos de uso rural consolidado (GUIDOTTI et al., 2016).

Se as APP tiverem sido definidas antes de 22 de julho de 2008, e se a vegetação nativa for menor que quatro Módulos Fiscais, o proprietário ou produtor rural podem recompor as APP dentro das condições estabelecidas na Lei, ou manter o uso consolidado e recompor somente as faixas obrigatórias para as APP (ZAKIA, M.J., 2013). O módulo fiscal, instituído pela Lei nº 6.746, de 10 de dezembro de 1979, como uma unidade de medida agrária, corresponde à área mínima para uma propriedade rural ser economicamente viável. O Módulo Fiscal pode variar entre 5 e 110 hectares, conforme o estabelecido pela Prefeitura Municipal. Nas regiões metropolitanas, o módulo rural costuma ser menor que no interior. Com isso, uma

propriedade de 550 hectares pode ser considerada pequena, a depender do município (ZAKIA, M.J., 2013). O Programa Nacional de Fortalecimento da Agricultura Familiar (Pronaf) utiliza o Módulo Fiscal como parâmetro (no caso até quatro módulos fiscais) para selecionar os beneficiários do programa entre pequenos agricultores de economia familiar, proprietários, meeiros, posseiros, parceiros ou arrendatários (ZAKIA, M.J., 2013).

No Projeto de Recuperação de Áreas Degradadas e Alteradas (Prada), definido pelo ACF, os imóveis que possuam mais de quatro Módulos Fiscais são obrigados a recompor a Reserva Legal sempre que a cobertura florestal for menor que a porcentagem exigida para os imóveis da região ou do bioma (ZAKIA, M.J., 2013).

Três técnicas combináveis entre si podem ser efetuadas para a recomposição da RL. A primeira é o plantio intercalado entre espécies nativas de ocorrência regional com exóticas ou frutíferas, sendo que a área recomposta por espécies exóticas não pode exceder 50% da área total a ser recuperada. A segunda é a regeneração natural da vegetação, mas caso seja de interesse do proprietário, a recomposição pode ser feita pelo método da compensação da Reserva Legal, na qual a restauração é efetuada em um terreno fora da propriedade em questão. A área compensada deve ser obrigatoriamente no mesmo bioma e, preferencialmente, no mesmo estado em Unidades de Conservação (UC) com pendência de regularização. A compensação em outro estado só pode ser realizada em áreas prioritárias para a conservação (ZAKIA, M.J., 2013).

Para fazer a compensação, a propriedade deve ter o registro no Cadastro Ambiental Rural (CAR), com a averbação da RL em cartório de registro de imóveis, estar vegetada ou com PRA aprovado no CAR. A área excedente a ser compensada deverá estar acima do percentual exigido pela lei para a região, estar averbada como RL em cartório. O terreno pode ser requerido na forma de comodato, arrendamento, servidão florestal ou como Cota de Reserva Ambiental (CRA) (ZAKIA, M.J., 2013).

A obrigatoriedade da RL é incompatível com a realidade e sua função de regulador ecossistêmico é duvidosa, pois a localização dessas áreas é tecnicamente indefinida e os dados e critérios utilizados para sua fundamentação são insondáveis. Contudo, não há dúvidas de que a vegetação nativa remanescente no país repercute no clima, na manutenção da biodiversidade e do solo. Quanto ao carbono florestal, estima-se que a vegetação nativa consiga armazenar um total de  $67 \pm 13$  bilhões de toneladas de carbono (SOARES-FILHO, 2013).

A maior parte do ativo florestal se encontra nos estados da Bahia, Piauí e Maranhão, a partir do norte de Minas Gerais e da divisa de Tocantins e Goiás, cobrindo, sobretudo, extensões remanescentes de Caatinga e Cerrado. A Caatinga abrange cerca de  $26 \pm 1,5$  Mha, e o Cerrado

cerca de  $40 \pm 2$  Mha, com a maior extensão absoluta de propriedades com ativo florestal. Outras concentrações surgem ao longo da Serra do Mar, dos Pampas e do Pantanal, apesar de esses dois biomas terem pastagens nativas manejadas. O ativo florestal da Amazônia é preciso ser analisado com cuidado, pois boa parte dos  $20 \pm 1$  Mha está localizada em áreas ainda não designadas (SOARES-FILHO, 2013).

O bioma Amazônico é também responsável pela maior parte do passivo ambiental, no qual abrange 8Mha com maiores concentrações nas bordas da Amazônia. Seguido pelos biomas Mata Atlântica (6Mha, praticamente toda a sua extensão), e Cerrado (5Mha), principalmente ao sul onde a atividade agrícola é mais intensa (SOARES-FILHO, 2013). Após a revisão do Código Florestal o passivo ambiental obteve redução de  $50 \pm 6$  para  $21 \pm 0,6$  Mha, correspondente a 58% da extensão original. Em grande parte devido ao artigo 67, o qual define que para propriedades de até quatro módulos fiscais a reserva legal será constituída pela área ocupada com vegetação nativa existente em 22 de julho de 2008. Os estados mais afetados pela mudança do código foram Mato Grosso, Pará, Minas Gerais e Bahia (SOARES-FILHO, 2013).

Apesar de a revisão do ACF representar grande perda em áreas de passivo ambiental, um aspecto positivo foi o aprimoramento de mecanismos que facilitam a sua viabilização. Como a Cota de Reserva Ambiental (CRA), o Projeto de Recuperação de Áreas Degradadas e Alteradas (Prada), o Programa de Regularização Ambiental (PRA), e o método de fiscalização, que deixou de ser feita por meio de denúncias e passou a ser feita pelo CAR (SOARES-FILHO et al., 2014).

O art.1º do Decreto nº 8.235, de 5 de maio de 2014, estabelece normas gerais complementares aos Programas de Regularização Ambiental dos Estados e do Distrito Federal (PRA). Esses programas proporcionam vantagens ao proprietário do imóvel, como a suspensão de multas e a possibilidade de consolidar atividades agrossilvipastoris e infraestrutura normatizando sua utilização dentro das APP. Conforme o Código Florestal, os estados possuem autonomia para regulamentar os PRA, que funcionarão como instrumentos para definir as práticas de manejo a serem utilizadas em áreas rurais consolidadas. Por meio dos PRA, os estados brasileiros têm a oportunidade de ajustar a legislação federal às suas peculiaridades culturais, históricas, territoriais, climáticas, econômicas e sociais (BRANCALION et al., 2016).

Quanto ao método de fiscalização, o CAR é uma ferramenta de controle da questão ambiental e caracteriza-se como um cadastro autodeclaratório. Ele compõe o Sistema de Cadastro Ambiental Rural (Sicar) criado no mesmo ano para gerir as informações declaradas pelos proprietários e as análises realizadas pelas Secretarias Estaduais de Meio Ambiente. Após a adesão ao CAR, o proprietário rural fica isento do registro da RL em cartório (BRASIL, 2012b).

### 5.1.2 Cadastro Ambiental Rural (CAR)

O Cadastro Ambiental Rural (CAR) é um cadastro eletrônico e obrigatório para todas as propriedades rurais, e segundo Laudares, Silva e Borges (2014b) tem por objetivo reunir e integrar as informações ambientais relacionadas às Áreas de Preservação Permanente, de Reserva Legal (RL), às florestas e à vegetação nativa, às Áreas de Uso Restrito e às áreas consolidadas das propriedades e posses rurais. É a principal ferramenta prevista no ACF para a conservação do meio ambiente, a adequação ambiental das propriedades, o combate ao desmatamento ilegal e o monitoramento de áreas em restauração, auxiliando no cumprimento das metas nacionais e internacionais.

É importante destacar que a proposta do CAR foi referendada pelo Código Florestal, pois ele já havia sido instituído pelo Decreto nº 7.029, de 10 de dezembro de 2009 (BRASIL, 2009), no âmbito do Programa Federal de Apoio à Regularização Ambiental de Imóveis Rurais, denominado “Programa Mais Ambiente. Entretanto, segundo SOUZA (2013), a primeira iniciativa de sistema de monitoramento e controle de imóveis rurais foi o Sistema de Licenciamento Ambiental em Propriedades Rurais (SLAPR) no estado do Mato Grosso, em 1997, que, por sua vez, incentivou a criação de mecanismos semelhantes em estados como Pará, Rondônia, Acre, Bahia e Tocantins.

O Decreto acabou provocando a existência de bancos de dados dos CAR estaduais e do governo federal, no período entre 2009 e 2012, sem a unificação das informações. Apesar disso, a iniciativa demonstrou a importância do Cadastro, levando à sua nacionalização e institucionalização. O acúmulo das experiências vivenciadas pelo SLAPR, pelos sistemas do Pará, Rondônia, Acre, Bahia e Tocantins, assim como pelo CAR, existente no período de 2009 a 2012, contribuiu para a construção do CAR proposto pelo Código Florestal (SOUZA, 2013).

O CAR tem como motivação a unificação de todos os registros ambientais rurais do país em uma única plataforma, a fim de diminuir o tempo para averiguá-los, pois antes de sua implementação o registro de cada RL ficava, geralmente, no cartório da cidade mais próxima à propriedade. Entretanto, segundo Delalibera et al. (2008), diagnósticos ambientais apontam que poucas propriedades rurais têm RL ou RL averbadas em cartório. Além disso, há aquelas RL que, mesmo sendo averbadas em cartório, são transformadas em pastos, plantações agrícolas.

Para Araújo e Juras (2012), os governos podem não conseguir fiscalizar as ocupações ilegais, pois o controle de irregularidades não pode se firmar em uma nova lei que detém apenas um único sistema de monitoramento, neste caso o CAR. Além disso, acreditam que os órgãos ambientais ainda não estão prontos à adaptação que o CAR exige e avaliam que o cadastro

eletrônico não dá a segurança jurídica necessária à RL. No entanto, o governo federal afirma que o CAR tem validade jurídica, sendo um substituto para averbação de RL sem apresentar problemas. (BRASIL, 2012b).

Estima-se que sejam 5,2 milhões os proprietários de imóveis rurais no Brasil. Calcula-se, ainda, que quase 35 milhões de hectares, uma área um pouco maior que o Estado de São Paulo, precisem ser reflorestados ou recuperados com vegetação nativa para atender o Código Florestal, mas este número também é uma suposição, baseada em dados dos Ministérios do Meio Ambiente, da Agricultura e da Embrapa. “Agora é que nós vamos saber com exatidão quais são os números do Brasil”, diz Paulo Guilherme Cabral, secretário de Extrativismo e Desenvolvimento Rural do Ministério do Meio Ambiente, sobre o CAR “É mais um instrumento econômico e ambiental do que uma obrigatoriedade apenas, mas todos terão que fazer” (TAGUCHI, 2014).

### **5.1.3 Sistema de Cadastro Ambiental Rural (Sicar)**

O Sistema de Cadastro Ambiental Rural (Sicar) foi criado pelo Decreto nº 7.830, de 17 de outubro de 2012 (BRASIL, 2012c). O Sicar é um sistema eletrônico e tem por função: cadastrar e controlar as informações dos imóveis rurais como seu perímetro e localização, as áreas de vegetação nativa, as áreas de APP, as Áreas de Uso Restrito, as áreas consolidadas e as Reservas Legais; monitorar a manutenção, a recomposição, a regeneração, a compensação e a supressão da vegetação nativa e da cobertura vegetal nas áreas citadas anteriormente, no interior dos imóveis rurais; promover o planejamento ambiental e econômico do uso do solo e conservação ambiental no território nacional; e disponibilizar informações de natureza pública sobre a regularização ambiental dos imóveis rurais em território nacional, na Internet.

O Sicar tem a responsabilidade de emitir o Recibo de Inscrição do Imóvel Rural no CAR, que confirma o cadastro da propriedade e o envio de toda a documentação necessária para a análise da localização da área de Reserva Legal, inclusive perante as instituições financeiras para concessão de crédito agrícola, em qualquer de suas modalidades a partir de 31 de dezembro de 2017 (BRASIL, 2012b).

Dentro da plataforma do Sicar, vale a pena destacar a parte de cadastro do imóvel que é a etapa em que o proprietário realiza a vetorização da propriedade, da Reserva Legal e da APP.(BRASIL, 2014)

Figura 1 - Tela de imóveis cadastrados



Fonte: Manual Cadastro Ambiental Rural - CAR, Módulo de Cadastro, Manual do Usuário v2.0, 2016

Nesta tela, o usuário pode pesquisar por imóveis cadastrados ou cadastrar um novo imóvel. Estão listados todos os imóveis cadastrados no nome do proprietário que, não necessariamente, é o cadastrante. Logo abaixo dos campos para pesquisa, há uma tabela com todos os imóveis cadastrados. (BRASIL, 2016c)

No campo “Situação”, há as opções “Em andamento”, “Cadastrado” e “Gravado”. “Em Andamento” refere-se a um cadastro ainda não finalizado. “Cadastrado” refere-se a um cadastro finalizado, mas que ainda não foi gravado. Ou seja, ainda não foi gerado o arquivo para envio. “Gravado” refere-se a um cadastro finalizado e que já foi gerado o arquivo para envio.

A Figura 2 mostra um exemplo de pesquisa feito com o nome “Jardim” e a localização do imóvel “Fazenda Jardim das Acácias”. (BRASIL, 2016c)

Figura 2 - Exemplo de visualização de cadastro

### CADASTRO DE IMÓVEIS

---

**Resumo do preenchimento do CAR Módulo de Cadastro**

**Resumo**

Número do Protocolo: AM-1301100-FC65.D1BC.8C4C.3D6F.33B0.94DD.342F.AC68 Finalizado em: 27/01/2016 14:40:38

**DADOS DO IMÓVEL RURAL**

Nome do Imóvel Rural: **Fazenda Jardim das Acácias** Município: **Careiro** UF: **Amazonas**

Coordenadas geográficas do centroide do imóvel rural: (Latitude: 3°47'37" S/ Longitude: 60°21'34" O)

Área (ha): **33,1231** Módulos fiscais: **0,41**

Telefone de contato:

E-mail de contato:

**INFORMAÇÕES ADICIONAIS**

Foi detectada uma diferença entre a área do imóvel rural declarada conforme documentação comprobatória de propriedade/posse/concessão [33,1231 hectares] e a área do imóvel rural identificada na representação gráfica [32,7227 hectares]

**REPRESENTAÇÃO GRÁFICA**



**DOMÍNIO DO IMÓVEL RURAL**

CPF / CNPJ	Nome / Razão Social
078.728.788-10	Matheus

**ÁREAS DECLARADAS (em hectares)**

<b>Imóvel</b> Área Total do Imóvel: <b>32,7227</b> Área de Servidão Administrativa: <b>3,8945</b> Área Líquida do Imóvel: <b>28,8283</b>	<b>Cobertura do Solo</b> Área Consolidada: <b>0,0000</b> Área de Remanescentes de Vegetação Nativa: <b>6,7617</b>
<b>APP/Usos Restritos</b> Área de Preservação Permanente: <b>9,8082</b> Área de Uso Restrito Total: <b>0,0000</b>	<b>Reserva Legal</b> Área de Reserva Legal: <b>0,0000</b>

[← Voltar](#)
Imóveis Cadastrados →


MINISTÉRIO DO MEIO AMBIENTE
GOVERNO FEDERAL

CAR MÓDULO DE CADASTRO

Fonte: Manual Cadastro Ambiental Rural - CAR, Módulo de Cadastro, Manual do Usuário v2.0, 2016

Após encontrado o arquivo, o usuário possui as ações “Editar”, “Remover”, “Gerar protocolo” e “Visualizar cadastro”. (BRASIL, 2016c)

No ícone “Editar” (símbolo “lápis”), é possível continuar um cadastro ainda não gravado na situação “Em Andamento” ou “Cadastrado”. Após acessar esta ação, o sistema é automaticamente direcionado para a tela de cadastro, para poder continuar o cadastro ou alterar algum dado já informado. Após a gravação do cadastro, essa ação deixa de ser disponibilizada para seleção. (BRASIL, 2016c)

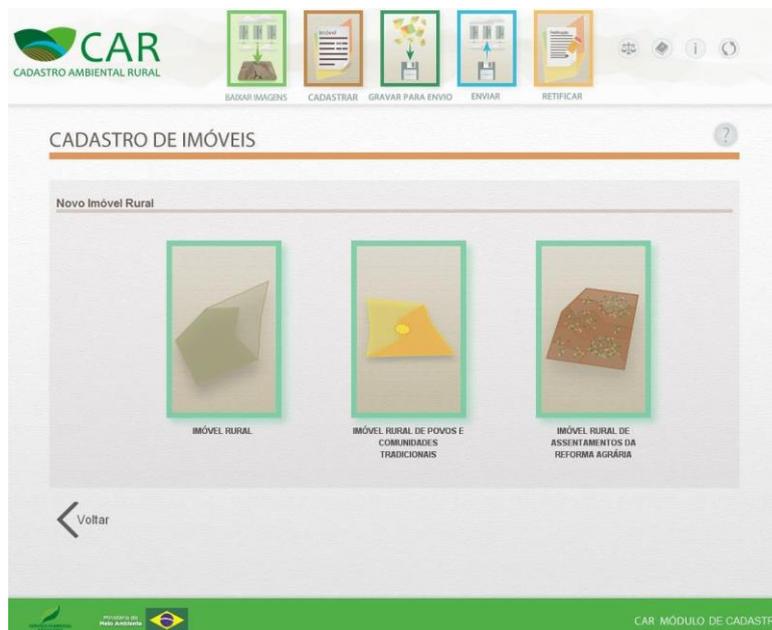
No ícone “Remover”, é possível excluir um cadastro de imóvel efetuado anteriormente. Uma vez excluído, o cadastro não poderá mais ser recuperado. Antes de concluir a ação, o sistema mostrará uma janela para confirmação da remoção. (BRASIL, 2016c)

No ícone “Gerar Protocolo” (símbolo “arquivo pdf”), é possível baixar o protocolo de preenchimento do CAR em formato PDF. (BRASIL, 2016c)

No ícone “Visualizar Cadastro”, o cadastro do imóvel, cadastrado ou gravado, pode ser visualizado. Ao selecionar esta ação, o sistema exibirá uma tela com as informações do cadastro em questão. (BRASIL, 2016c)

Caso seja necessário fazer um novo cadastro, ele deverá selecionar a opção “Cadastrar Novo Imóvel”. O sistema direcionará o usuário para a seção “Novo Imóvel Rural” (Figura 3), em que deverá escolher o tipo de imóvel a ser cadastrado. Se “Imóvel Rural”, “Imóvel Rural de Povos e Comunidades Tradicionais” ou “Imóvel Rural de Assentamentos da Reforma Agrária”. (BRASIL, 2016c)

Figura 3 – Tela de cadastro "Novo Imóvel Rural"



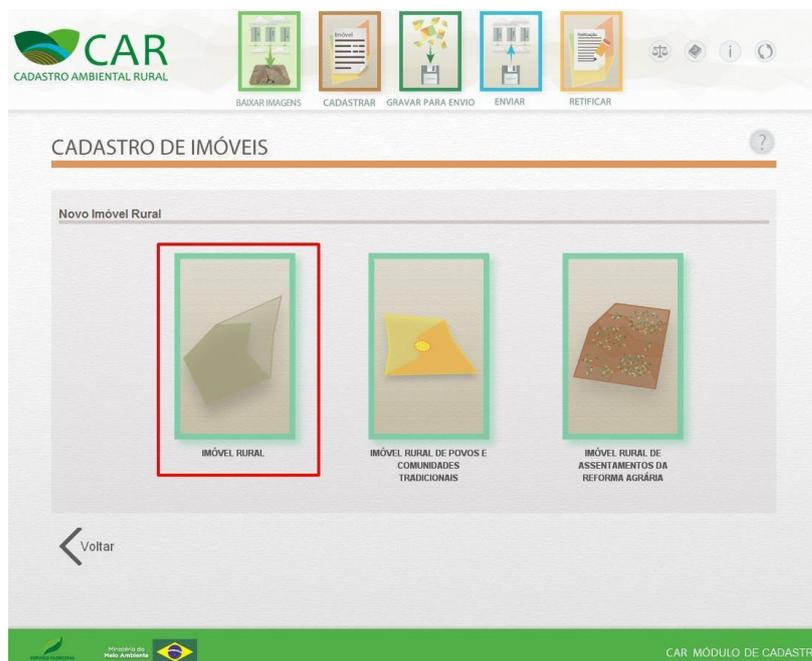
Fonte: Manual Cadastro Ambiental Rural - CAR, Módulo de Cadastro, Manual do Usuário v2.0, 2016

O módulo “Imóvel Rural” refere-se às pessoas que possuam propriedades em zonas rurais. O “Imóvel Rural de Povos e Comunidades Tradicionais” abrange os grupos que usam e ocupam de forma permanente ou temporária, territórios tradicionais e recursos naturais como condição para sua reprodução cultural, social, religiosa, ancestral e econômica. São eles: indígenas, quilombolas, comunidades de terreiro, extrativistas, ribeirinhos, caboclos, pescadores artesanais, pomeranos, dentre outros. O módulo “Imóvel Rural de Assentamentos

da Reforma Agrária” é direcionado aos usuários que irão cadastrar um imóvel pertencente aos assentamentos instituídos por órgãos federais, estaduais e municipais. (BRASIL, 2016c)

As opções “Imóvel Rural” e “Imóvel Rural de Povos e Comunidades Tradicionais” são semelhantes, distinguindo-se apenas no cálculo dos módulos fiscais. Para apresentar o funcionamento do sistema, nesta seção será utilizada a opção “Imóvel Rural”. Para acessar esta opção, deve ser selecionado o ícone referente à opção “Imóvel Rural” (Figura 4). (BRASIL, 2016c)

Figura 4 – Em destaque, a opção de cadastro "Imóvel Rural"



Fonte: Manual Cadastro Ambiental Rural - CAR, Módulo de Cadastro, Manual do Usuário v2.0, 2016

Em seguida, o sistema apresentará a primeira etapa de cadastro, conforme mostra a Figura 5. Na etapa “Cadastrante”, devem ser preenchidos os campos obrigatórios “CPF”, “Data de Nascimento”, “Nome”, “Nome da Mãe” e os dados do representante. Para informar a data de nascimento, o usuário deve clicar no calendário localizado ao lado do campo e então selecionar a data. Devem ser preenchidos em todas as etapas, obrigatoriamente, os campos indicados com asterisco para a realização completa do cadastro. (BRASIL, 2016c)

Figura 5 – Etapa “Cadastrante”

**CADASTRAR IMÓVEL RURAL**

Novo Imóvel Rural

Cadastrante | Imóvel | Domínio | Documentação | Geo | Informações

**Dados do Cadastrante**

CPF \* :  Data de Nascimento \* :

Nome \* :  Nome da Mãe \* :

Informe o nome conforme consta no CPF declarado

**Dados do Representante:**

Representante: A figura do representante no âmbito do Cadastro Ambiental Rural é a pessoa física que estará habilitada pelo proprietário / possuidor a representá-lo em todas etapas do CAR deste imóvel.

Não possui representante

Possui representante, e ele é o cadastrante

Possui representante, mas ele não é o cadastrante

\* Campos Obrigatórios

Obs.: Você deverá iniciar e finalizar o cadastro de um imóvel utilizando sempre o mesmo computador.

[Voltar](#) [Próximo](#)

CAR - MÓDULO DE CADASTRO

Fonte: Manual Cadastro Ambiental Rural - CAR, Módulo de Cadastro, Manual do Usuário v2.0, 2016

Na etapa “Imóvel” (Figura 6), deve ser feita a identificação do imóvel em questão. Após o preenchimento, deve ser acessada a opção “Próximo” e o sistema é direcionado para a etapa “Domínio”. (BRASIL, 2016c)

Figura 6 – Etapa “Imóvel”

The image shows the 'Novo Imóvel Rural' form in the CAR system. The form is organized into several sections:

- Nome do Imóvel:** A text input field.
- UF:** A dropdown menu with 'Selecione' as the current selection.
- Município:** A dropdown menu with 'Selecione' as the current selection.
- CEP:** A text input field.
- Descrição de Acesso ao Imóvel:** A large text area for describing the access to the property.
- Zona de Localização:** Radio buttons for 'Rural' (selected) and 'Úrbana'.
- Endereço de Correspondência:**
  - Endereço/Logradouro:** A text input field.
  - Número:** A text input field.
  - Complemento:** A text input field.
  - Bairro:** A text input field.
  - CEP:** A text input field.
  - UF:** A dropdown menu with 'Selecione' as the current selection.
  - Município:** A dropdown menu with 'Selecione' as the current selection.
  - E-mail:** A text input field.
  - Telefone:** A text input field.

The interface includes a top navigation bar with icons for 'BAIXAR IMAGENS', 'CADASTRAR', 'GRAVAR PARA ENVIO', 'ENVIAR', and 'RETIFICAR'. The footer contains the logo of the 'Ministério do Meio Ambiente' and the text 'CAR - MÓDULO DE CADASTRO'.

Fonte: Manual Cadastro Ambiental Rural - CAR, Módulo de Cadastro, Manual do Usuário v2.0, 2016

Na etapa “Domínio” (Figura 7), devem ser identificados o(s) proprietário(s) do imóvel em questão, que podem ser classificados como “Pessoa Física” ou “Pessoa Jurídica”.

Caso o proprietário seja uma pessoa física, devem ser informados o seu CPF, Data de Nascimento, Nome e Nome da Mãe. Para Pessoas Jurídicas devem ser informados o CNPJ da Empresa/Instituição, Nome da Empresa/Instituição e, opcionalmente, o seu Nome Fantasia. Bem como os “Dados Pessoais do Representante Legal”, o CPF, Data de Nascimento, Nome, Nome da Mãe, E-mail, Telefone Residencial, Logradouro, Número, Complemento, Bairro, CEP, UF e Município. (BRASIL, 2016c)

Para incluir os proprietários, há a opção de “Preencher os dados” ou “Importar arquivo de dados”. Dependendo da escolha realizada, o sistema exibe conteúdos diferentes para essa etapa de preenchimento. Assim que o usuário preencher todos os dados do proprietário, ele deve selecionar a opção “Adicionar proprietário/possuidor”. (BRASIL, 2016c)

Todos os proprietários adicionados são listados na tabela “Proprietários/ Possuidores Adicionados”, localizada logo abaixo dos campos de preenchimento. Para editar ou remover um proprietário/possuidor adicionado, há as ações “Editar Cadastro” e “Remover”. (BRASIL, 2016c)

Após o término da adição dos proprietários/possuidores, deve ser selecionada a opção “Próximo” para avançar à etapa seguinte de preenchimento. (BRASIL, 2016c)

Figura 7 – Etapa "Domínio"

Fonte: Manual Cadastro Ambiental Rural - CAR, Módulo de Cadastro, Manual do Usuário v2.0, 2016

Na etapa “Documentação”, devem ser incluídos os documentos que comprovem a propriedade do imóvel, selecionando entre as opções “Propriedade” (Figura 8) ou “Posse” (Figura 9). Conforme a opção desejada, o sistema fornece modos de preenchimento diferentes. Em seguida, os campos de identificação do documento devem ser preenchidos como mostrado nas respectivas figuras. (BRASIL, 2016c)

Para o campo “Possui Reserva Legal Averbada e/ ou Reserva Legal Aprovada e não Averbada”, o usuário deve informar se o documento é registrado em cartório e/ ou se possui Reserva Legal. Caso a resposta seja “Sim”, o sistema exibe novos conteúdos para essa etapa de preenchimento. O usuário deve informar o “Número da averbação/ documento”, a “Data de Averbação/ Aprovação”, a “Área da Averbação/Aprovação”, informar se a Reserva Legal está dentro do imóvel e se a área de Reserva Legal, ou parte dela, destina-se à compensação de Reserva Legal de outro imóvel. (BRASIL, 2016c)

No quadro “Adicionar Posseiros”, é exibido o quadro para adicionar as pessoas. Após adicionar, o usuário deve selecionar aquela(s) que deseja associar à documentação do imóvel a ser cadastrada. (BRASIL, 2016c)

Ao término do preenchimento dos dados do documento, tanto na modalidade “Propriedade” quanto “Posse”, o usuário deve selecionar o botão “Adicionar” (Figura 9) para salvar o registro do documento em questão. (BRASIL, 2016c)

Figura 8 – Etapa "Documentação", modalidade "Propriedade"

The screenshot shows the 'Novo Imóvel Rural' form in the 'Documentação' tab. The 'Propriedade ou Posse' section has 'Propriedade' selected. The form includes fields for 'Nome da Propriedade', 'Área (ha)', 'Tipo de Documento', 'Número da Matrícula ou Documento', 'Data do Documento', 'Livro', 'Folha', 'UF do Cartório', 'Município do Cartório', 'Código no Sistema Nacional de Cadastro Rural - SNCR', 'Certificação do Imóvel no INCRA', and 'NIRF'. There are also radio buttons for 'Possui Reserva Legal Averbada e/ou Reserva Legal Aprovada e não Averbada?' with 'Não' selected. A list of owners is shown with 'Ana Paula Oliveira' selected. The footer includes the logo of the Ministério do Meio Ambiente and the text 'CAR MÓDULO DE CADASTRO'.

Fonte: Manual Cadastro Ambiental Rural - CAR, Módulo de Cadastro, Manual do Usuário v2.0, 2016

Figura 9 – Etapa "Documentação", modalidade "Posse".

The screenshot shows the 'Novo Imóvel Rural' form in the 'Documentação' tab. The 'Propriedade ou Posse' section has 'Posse' selected. The form includes fields for 'Nome da Posse', 'Área (ha)', 'Tipo de Documento', 'Emissor do documento', and 'Data do documento'. There are also radio buttons for 'Possui Reserva Legal Averbada e/ou Reserva Legal Aprovada e não Averbada?' with 'Não' selected. A list of owners is shown with 'Ana Paula Oliveira' and 'Donizetti Oliveira' selected. The 'Adicionar' button is highlighted with a red box. The footer includes the logo of the Ministério do Meio Ambiente and the text 'CAR MÓDULO DE CADASTRO'.

Fonte: Manual Cadastro Ambiental Rural - CAR, Módulo de Cadastro, Manual do Usuário v2.0, 2016

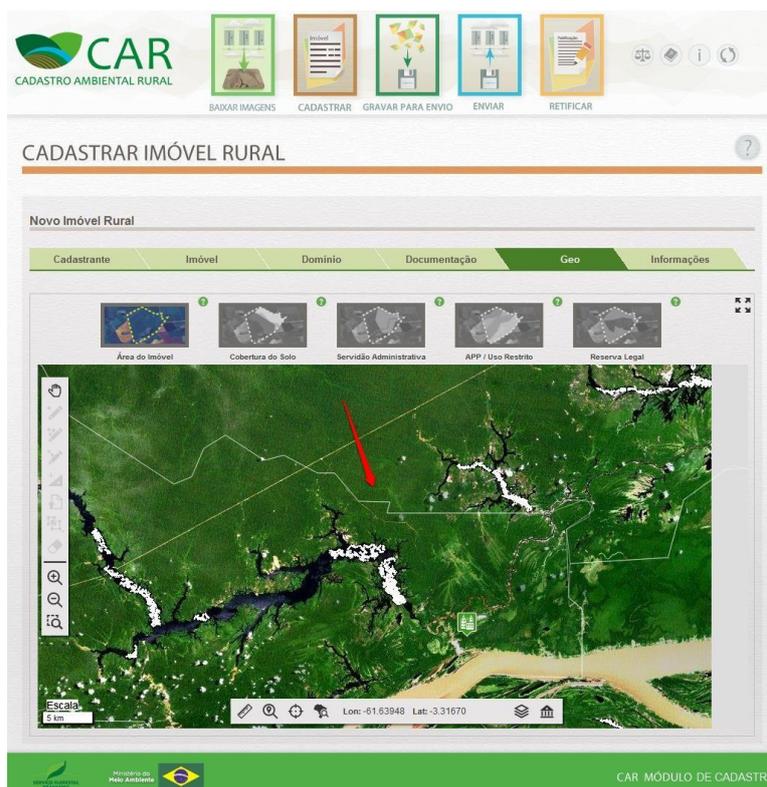
Após a etapa "Documentação" ser concluída, o sistema é direcionado para a tela inicial

da próxima etapa “Geo” (Figura 10). (BRASIL, 2016c)

Nessa etapa, é realizada a demarcação da área do imóvel e são informadas as características físicas do terreno. Essa demarcação é realizada por meio de um georreferenciamento composto por 5 passos executados pelo usuário. Para cada passo, o sistema fornece um conjunto de ferramentas. Para iniciar o georreferenciamento, é necessário ter em sua posse as imagens do município onde se localiza o imóvel a ser cadastrado. (BRASIL, 2016c)

O município selecionado na etapa de identificação do imóvel automaticamente é centralizado e focalizado no mapa ao acessar a etapa “Geo”. No mapa exibido cada município é delimitado por um polígono irregular, no qual os limites e divisas municipais são definidos por uma linha branca, conforme demonstrado na Figura 10. (BRASIL, 2016c)

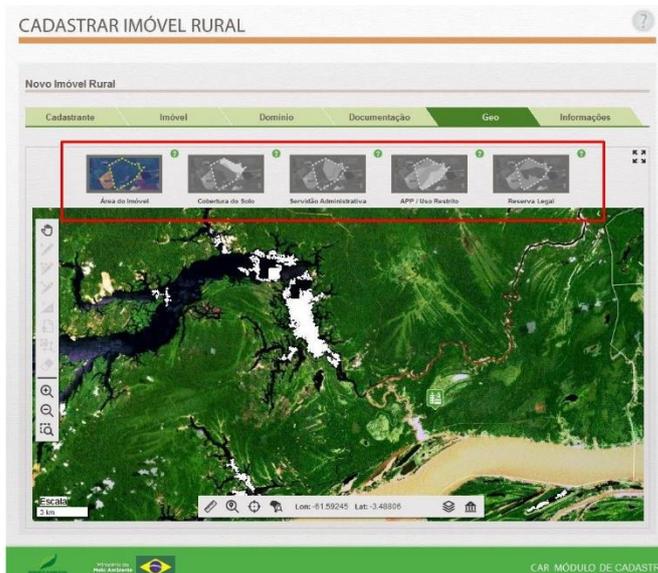
Figura 10 – Etapa “Geo”. Em destaque, a linha que define os limites municipais



Fonte: Manual Cadastro Ambiental Rural - CAR, Módulo de Cadastro, Manual do Usuário v2.0, 2016

Na margem esquerda e na margem inferior da tela há duas barras de ferramentas que visam facilitar a localização exata do imóvel, como *zoom* e “tela cheia”. Na margem superior, miniaturas de mapas indicam o passo a passo a ser seguido para execução do georreferenciamento do imóvel (Figura 11).

Figura 11 – Miniaturas de mapas que indicam os passos para demarcação do imóvel



Fonte: Manual Cadastro Ambiental Rural - CAR, Módulo de Cadastro, Manual do Usuário v2.0, 2016

O nome de cada passo é mostrado logo abaixo de sua miniatura conforme mostrado na Figura 12. Inicialmente, apenas o primeiro passo é habilitado para o usuário. Os passos seguintes são habilitados, conforme a conclusão dos passos anteriores. (BRASIL, 2016c)

Figura 12 – Passos para georreferenciamento



Fonte: Manual Cadastro Ambiental Rural - CAR, Módulo de Cadastro, Manual do Usuário v2.0, 2016

No primeiro passo, a área total do imóvel que está sendo cadastrado deve ser demarcada. Está incluído o conjunto de propriedades ou posses distribuídas de forma contínua, pertencentes a um ou mais proprietários ou possuidores rurais. Devido à medida de algumas áreas serem obtidas com instrumentos sem precisão, a área declarada nos documentos pode não corresponder com o desenho elaborado. Entretanto, esse fator não impede a conclusão do registro no CAR, contanto que sejam evitadas sobreposições sobre áreas de outros imóveis rurais. É obrigatória a indicação da “Sede ou Ponto de Referência do Imóvel”. (BRASIL, 2016c)

No segundo passo, devem ser demarcadas as áreas no interior do imóvel rural que são constituídas por “Área de Pousio”, “Área Consolidada” e “Remanescente de Vegetação Nativa”.

Em seguida, no terceiro passo devem ser declaradas as áreas de servidão administrativa,

correspondentes às áreas ocupadas por estradas e outras obras públicas que recortam o interior do imóvel rural. Podem ser classificadas no georreferenciamento como “Infraestrutura Pública”, “Utilidade Pública” ou “Reservatório para Abastecimento ou Geração de Energia”. Essas áreas devem ser obrigatoriamente demarcadas, de modo que o cálculo da área líquida do imóvel rural seja dimensionada corretamente para a projeção da área necessária para a Reserva Legal. (BRASIL, 2016c)

No quarto passo, as áreas destinadas à APP e áreas de Uso Restrito devem ser demarcadas. As APP são definidas por parâmetros instituídos pelo ACF e devem ter suas margens respeitadas ao traçar o desenho individual de cada APP existente no interior do imóvel. O georreferenciamento pode ser classificado como Uso restrito ou Área de Preservação Permanente. (BRASIL, 2016c)

As áreas de Reserva Legal devem ser demarcadas no quinto passo. Devem ser áreas instituídas voluntariamente, temporária ou perpetuamente, para conservação dos recursos naturais. As condições para delimitação dessas áreas estão previstas no art. 4º do Código Florestal. O georreferenciamento neste passo pode ser classificado como “Reserva Legal Proposta”, “Reserva Legal Averbada”, “Reserva Legal Aprovada e não Averbada” e “Reserva Legal vinculada à compensação de outro imóvel”. (BRASIL, 2016c)

Para demarcar as áreas, o usuário deve selecionar o passo desejado, selecionar uma das opções disponíveis ao acessar o passo escolhido, selecionar alguma ferramenta de desenho e desenhar o polígono sobre o mapa. (BRASIL, 2016c)

Após todos os passos concluídos, deve ser acessada a opção “Próximo” e avançar à etapa seguinte de preenchimento. (BRASIL, 2016c)

A etapa “Informações” corresponde a um questionário que visa ao fornecimento de algumas informações específicas sobre o imóvel. O usuário deve responder a cada uma das perguntas selecionando as opções “Sim” ou “Não”. Em algumas perguntas, caso a resposta selecionada seja “Sim”, são apresentados novos campos complementares que também devem ser preenchidos. (BRASIL, 2016c)

Para finalizar a etapa “Cadastro”, deve ser selecionada a opção “Finalizar” disponível na margem inferior direita (Figura 13) e em seguida confirmar selecionando “Sim”. O imóvel em questão passa a ser listado na tabela “Imóveis Cadastrados”. Caso o usuário deseje finalizar o cadastro em outro momento, basta selecionar a opção “Não”. (BRASIL, 2016c)

Ao término do cadastro, o sistema exibe uma tela com os dados resumidos do imóvel cadastrado

Figura 13 – Etapa "Informações"

**CADASTRO AMBIENTAL RURAL**

BAIXAR IMAGENS CADASTRAR GRAVAR PARA ENVIO ENVIAR RETIFICAR

## CADASTRAR IMÓVEL RURAL

### Novo Imóvel Rural

Cadastrante	Imóvel	Domínio	Documentação	Geo	Informações
-------------	--------	---------	--------------	-----	-------------

**Informações do Imóvel**

Deseja aderir ao Programa de Regularização Ambiental - PRA, caso o imóvel rural possua (uma das situações a seguir, ocorrida até 22 de julho de 2008): necessidade de recomposição de áreas de APP e de uso restrito; déficit referente a Reserva Legal; autuação? \*

Sim  Não

O imóvel rural possui área com déficit de vegetação nativa para fins de cumprimento da Reserva Legal? \*

Sim  Não

Existe Termo de Ajuste de Conduta (TAC) aprovado referente à regularização de APP, Reserva Legal ou área de uso restrito? \*

Sim  Não

Existe Projeto de Recuperação de Áreas Degradadas (PRAD) ou outro documento aprovado referente à regularização de APP, Reserva Legal ou área de uso restrito? \*

Sim  Não

Existem infrações cometidas até 22 julho de 2008, relativas à supressão irregular de vegetação em APP, Reserva Legal ou área de uso restrito do imóvel, objeto de autuação? \*

Sim  Não

O imóvel rural possui área remanescente de vegetação nativa excedente ao mínimo exigido para Reserva Legal? \*

Sim  Não

Existe Reserva Particular do Patrimônio Natural - RPPN - no interior do imóvel rural? \*

Sim  Não

Possui cota de reserva florestal - CRF? \*

Sim  Não

A Reserva Legal do imóvel rural está submetida à legislação de que período? \*

A partir de 22/07/2008 - Lei nº 12.651 de 25 de maio de 2012

21/01/2001 a 21/07/2008 - MP nº 2.166-67, de 21 de janeiro de 2001

27/12/2000 a 20/01/2001 - MP nº 2.080, de 21 de janeiro de 2001

14/12/1998 a 26/12/2000 - MP nº 1.736-19/31 de 14 de dezembro de 1998, MP nº 1885-38/44 de 29 de junho de 1999 a MP nº 1.956 de 09 de dezembro de 1999

11/12/1997 a 13/12/1998 - MP nº 1.605-18, de 11 de dezembro de 1997

25/07/1996 a 10/12/1997 - MP nº 1.511-1, 25 de julho de 1996

19/10/1994 a 24/07/1996 - Decreto nº 1.282, de 19 de outubro de 1994

18/07/1989 a 18/10/1994 - Lei nº 7.803, de 18 de julho de 1989

15/09/1965 a 17/07/1989 - Lei nº 4.771, de 15 de setembro de 1965

23/01/1934 a 14/09/1965 - Decreto Lei nº 23.793, de 23 de janeiro 1934

Anterior a 23/01/1934

Ocorreu alteração no tamanho da área do imóvel após 22/07/2008? \*

Sim  Não

\* Campos Obrigatórios

[Voltar](#) [Finalizar](#)

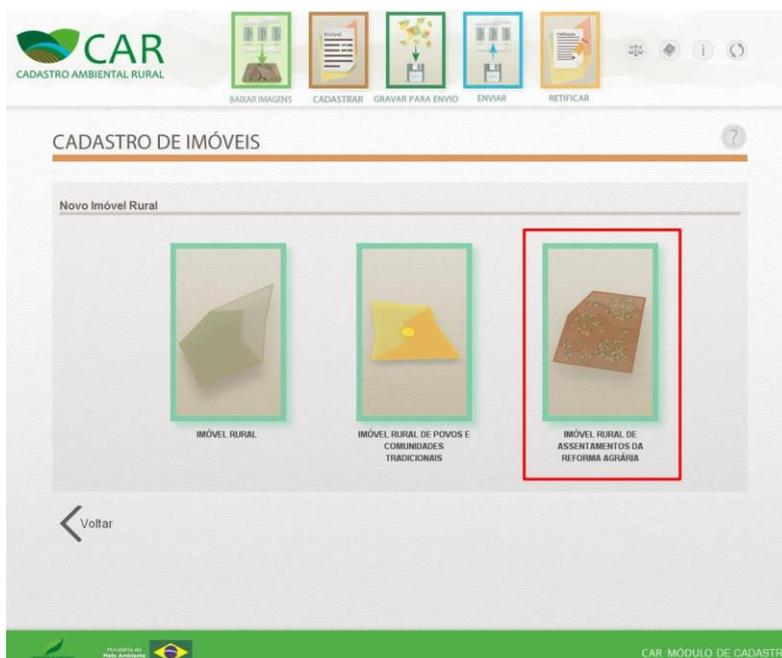
Ministério do Meio Ambiente CAR MÓDULO DE CADASTRO

Fonte: Manual Cadastro Ambiental Rural - CAR, Módulo de Cadastro, Manual do Usuário v2.0, 2016

A maioria das opções exibidas em “Imóvel Rural”, “Imóvel Rural de Povos e Comunidades Tradicionais” e “Imóvel Rural de Assentamentos da Reforma Agrária” são semelhantes, sendo que a opção “Imóvel Rural de Assentamentos da Reforma Agrária” possui algumas especificidades. (BRASIL, 2016c)

Para acessar a opção de cadastro de “Imóvel Rural de Assentamentos da Reforma Agrária”, o usuário deve clicar na imagem destacada na Figura 14. O acesso a essa opção fica disponível apenas às entidades responsáveis pelo cadastramento de assentamentos da Reforma Agrária. (BRASIL, 2016c)

Figura 14 – Em destaque, a opção de cadastro "Imóvel Rural de Assentamentos da Reforma Agrária"



Fonte: Manual Cadastro Ambiental Rural - CAR, Módulo de Cadastro, Manual do Usuário v2.0, 2016

Após acessar a opção “Imóvel Rural de Assentamentos da Reforma Agrária”, o sistema apresenta a primeira etapa de cadastro, semelhante aos módulos “Imóvel Rural” e “Imóvel Rural de Povos e Comunidades Tradicionais”. (BRASIL, 2016c)

Já na etapa “Imóvel” (Figura 15), o usuário deve obrigatoriamente preencher os campos específicos sobre o assentamento “Fração ideal do assentamento 1/x”, “Código do Projeto de Assentamento” e “Data de Criação do Assentamento”, sendo que a fração ideal do assentamento reflete o número de assentados dentro do imóvel. (BRASIL, 2016c)

Figura 15 – Etapa "Imóvel"

**CADASTRAR IMÓVEL RURAL DE ASSENTAMENTOS DA REFORMA AGRÁRIA**

Novo Imóvel Rural

Cadastrante | **Imóvel** | Domínio | Documentação | Geo | Informações

**Dados do Imóvel**

Nome do Imóvel <sup>o</sup>:

UF <sup>o</sup>:  Município <sup>o</sup>:  CEP:

Fração Ideal do assentamento 1/x <sup>o</sup>:  Código do Projeto de Assentamento <sup>o</sup>:  Data de Criação do Assentamento <sup>o</sup>:

Descrição de Acesso ao Imóvel <sup>o</sup>:

Zona de Localização <sup>o</sup>:  Rural  Urbana

**Endereço de Correspondência**

Endereço/Logradouro <sup>o</sup>:  Número <sup>o</sup>:  Complemento:

Bairro <sup>o</sup>:  CEP <sup>o</sup>:  UF <sup>o</sup>:  Município <sup>o</sup>:

E-mail:  Telefone:

Ministério do Meio Ambiente CAR MÓDULO DE CADASTRO

Fonte: Manual Cadastro Ambiental Rural - CAR, Módulo de Cadastro, Manual do Usuário v2.0, 2016

Na etapa “Domínio” (Figura 16), ao contrário dos módulos “Imóvel Rural” e “Imóvel Rural de Povos e Comunidades Tradicionais”, há uma opção extra relativa aos concessionários. Para isso, primeiramente é necessário escolher o campo “Proprietário, Possuidor ou Concessionários” entre as opções “Pessoa Física” ou “Pessoa Jurídica”. (BRASIL, 2016c)

O preenchimento segue, então, sem muitas diferenças quanto ao enunciado anteriormente. Após completar os campos, o usuário deve acessar a opção “Próximo” e avançar à etapa seguinte de preenchimento. (BRASIL, 2016c)

Figura 16 – Etapa "Domínio"

Fonte: Manual Cadastro Ambiental Rural - CAR, Módulo de Cadastro, Manual do Usuário v2.0, 2016

Na etapa de “Documentação”, primeiramente o usuário deve escolher entre as opções “Propriedade”, “Posse” ou “Concessão”. As opções “Propriedade” e “Posse” seguem conforme o preenchimento nos módulos “Imóvel Rural” e “Imóvel Rural de Povos e Comunidades Tradicionais”. (Figura 17) (BRASIL, 2016c)

Na opção “Concessão”, deve ser informado, obrigatoriamente, o “Nome da Concessão”, a “Área” e o “Tipo de Documento”. Após incluir pessoas no quadro “Adicionar Concessionários”, o usuário deve selecionar, na lista disponível, aquela(s) que deseja associar à documentação do imóvel a ser cadastrada. (BRASIL, 2016c)

Para salvar o registro do documento em questão, deve ser selecionado o botão “Adicionar” ao término do preenchimento dos dados do documento e da seleção das pessoas associadas a ele. (BRASIL, 2016c)

Caso o usuário queira adicionar mais de um documento comprobatório de concessão para o imóvel, deve realizar o preenchimento dos dados e a seleção das pessoas, para cada um dos documentos a ser incluído. (BRASIL, 2016c)

Figura 17 – Etapa "Documentação"

**CADASTRO AMBIENTAL RURAL**

BAIXAR IMAGENS CADASTRAR GRAVAR PARA ENVIO ENVIAR RETIFICAR

**CADASTRAR IMÓVEL RURAL DE ASSENTAMENTOS DA REFORMA AGRÁRIA**

**Novo Imóvel Rural**

Cadastrante Imóvel Domínio **Documentação** Geo Informações

**Dados do Documento**

Propriedade, Posse ou Concessão \*:  
 Propriedade  Posse  Concessão

Nome da Propriedade \*:  Área (ha) \*:  Tipo de Documento \*:

1 Número da Matrícula ou Documento:  Data do Documento:  Livro:

Folha:  UF do Cartório:  Município do Cartório:

2 Código no Sistema Nacional de Cadastro Rural - SNCR:  3 Certificação do Imóvel no INCRA:

4 NIRF (Número de Inscrição do Imóvel Rural na Secretaria da Receita Federal do Brasil):

Possui Reserva Legal Averbada e/ou Reserva Legal Aprovada e não Averbada?  
 Sim  Não

Não possui Reserva Legal Averbada e/ou Reserva Legal Aprovada e não Averbada.

Adicionar Proprietários \*:

Filtrar:

Selecionar Todos  
 Elivania Oliveira

**Documentos Adicionados**

Tipo	Nome	Área (ha)	Ações
Não há documentos adicionados Para adicionar um documento use o formulário acima			

Área Total do Imóvel (ha): 0.0000

**CAR MÓDULO DE CADASTRO**

Fonte: Manual Cadastro Ambiental Rural - CAR, Módulo de Cadastro, Manual do Usuário v2.0, 2016

A etapa “Geo” e “Informações” são exatamente iguais aos módulos “Imóvel Rural” e “Imóvel Rural de Povos e Comunidades Tradicionais”. Após esse dois passos, o usuário é redirecionado para o menu principal, em que ele obtém informações e exporta o seu cadastro para um dispositivo de armazenamento externo como pen drive, HD externo, nuvem entre outros meios. No menu principal, também é possível realizar o envio dos cadastros e retificá-los, caso haja necessidade de reformulação, segundo as Secretarias de Estado do Meio Ambiente (Sema), responsáveis pela análise dos dados preenchidos no Sicar. (BRASIL, 2016c)

O trabalho das Sema pode ser prejudicado por possíveis inconsistências nos dados do Sistema, pois, no preenchimento da etapa Geo, os usuários talvez utilizem diferentes sistemas de coordenadas, o que provavelmente acarretará sobreposição nos limites das propriedades. Devido a esse problema, alguns estados optaram por criar uma nova plataforma estadual integrada ao CAR federal, mas sob a responsabilidade e gestão de cada estado, como, por exemplo, Mato Grosso e Mato Grosso do Sul. No caso do estado do Mato Grosso, o governo voltou a utilizar a plataforma do Sistema Integrado de Monitoramento e Licenciamento Ambiental (Simlam), enquanto desenvolvia a nova plataforma de integração ao CAR, lançada neste ano (Sistema Mato-grossense de Cadastro Ambiental Rural (Simcar - MT) (BRASIL, 2017a).

Segundo Carlos Fávaro, Vice-Governador e Secretário Estado de Meio Ambiente de Mato Grosso, diante das inúmeras reclamações da Sema/ MT, envolvendo os procedimentos de regularização ambiental das propriedades rurais, foi solicitada a realização de um estudo para o desenvolvimento de um substituto ao CAR. Tal ação justificou-se pelo fato de os órgãos federais responsáveis pelo Cadastro não terem respondido as dúvidas da Sema/ MT e terem se recusado a abrir o código de programação do Sicar, para que a Secretaria pudesse tentar resolver os problemas encontrados.

Por meio de uma dispensa de licitação, com orientação e acompanhamento da Procuradoria Geral do Estado (PGE) e da Empresa Mato-grossense de Tecnologia de Informação (MTI), uma empresa de geotecnologia foi contratada, para realizar um estudo buscando sanar os problemas encontrados com a plataforma do Sicar. Enquanto a nova plataforma era desenvolvida, a Sema/ MT voltou a utilizar o Sistema Integrado de Monitoramento e Licenciamento Ambiental (Simlam/ MT) (BRASIL, 2017a).

#### **5.1.4 Sistema Integrado de Monitoramento e Licenciamento Ambiental (Simlam) – Mato Grosso**

O Sistema Integrado de Monitoramento e Licenciamento Ambiental (Simlam) teve por objetivo auxiliar a gestão ambiental e o controle fiscal no estado do Mato Grosso. Esse sistema tecnológico já foi referendado por várias Secretarias de Estado de Meio Ambiente (Sema) em todo Brasil, como a do Pará, São Paulo, Rondônia e Espírito Santo (BRASIL, 2017b).

O Simlam, por muito tempo, foi a ferramenta mais utilizada pelas Secretarias Estaduais de Meio Ambiente, por conseguir se adaptar à diversidade ambiental brasileira. Por esse motivo, funcionalidades e *layouts* de sistema são diferentes de estado para estado e as funcionalidades

do Simlam também são distintas, para suprir as necessidades de cada Secretaria (BRASIL, 2017b).

O sistema Simlam permite a organização do fluxo de trabalho da equipe da Secretaria, para que todos possam contribuir, desde o interessado, passando pela equipe de protocolo, análise técnica e monitoramento até a fiscalização. Dessa forma, a implantação do Simlam traz junto de si, aumento de produtividade, qualidade e transparência das atividades da instituição (BRASIL, 2017b).

Uma das características do Simlam é o relatório com a listagem completa dos responsáveis técnicos em atividade na Secretaria de Estado de Meio Ambiente de Mato Grosso. Nesta listagem é possível visualizar o Nome do Responsável Técnico, o seu número de cadastro no órgão, e a data de validade do seu cadastro. Além disso, é possível visualizar a formação profissional, a sua atividade e os seus contatos. Também é possível visualizar na listagem os processos que este responsável técnico possui no órgão, verificando o seu tipo, número e situação que ele se encontra na Sema (BRASIL, 2007).

Na plataforma *online* do Simlam, o usuário pode acessar a “Lista de Responsáveis Técnicos”, realizar buscas e utilizar filtros (por nome, profissão, atividade ou município), e pode ver cada processo do responsável técnico e suas pendências. O usuário pode ver qual é a situação de cada processo e qual é o empreendimento do processo (BRASIL, 2007).

No campo “Empreendimentos Cadastrados”, é possível inserir os dados das propriedades cadastradas, como informações sobre o nome fantasia da propriedade, a razão social, a situação da propriedade, coordenadas, a atividade principal da propriedade, a área da propriedade, o endereço da mesma, os meios de contato e seus proprietários. Sendo possível ver os processos ligados a essa propriedade, como o tipo do processo, a situação do processo, o número, a data de criação, o interessado, o empreendimento, a atividade licenciada, os arquivos do processo, o responsável técnico, além de outras informações, e pesquisa de processos (BRASIL, 2007).

No quarto tópico do menu principal, há a função de “Licenças e Autorizações” com a lista das licenças e autorizações, emitidas pela Superintendência de Gestão Florestal da Sema/ MT (BRASIL, 2007). No tópico “Mapas”, o usuário pode visualizar os mapas de “Manejo”, “Empreendimentos” e “Limites Rurais” com as informações e características destes mapas. O usuário também pode realizar o *download* de imagens de satélites, como as imagens do *Cebers* e do *Landsat* por meio de uma ferramenta que o sistema do Simlam disponibiliza (BRASIL, 2007).

### **5.1.5 Sistema Mato-grossense de Cadastro Ambiental Rural (Simcar - MT)**

O Sistema Mato-grossense de Cadastro Ambiental Rural (Simcar) foi criado por meio da Lei Complementar do Estado do Mato Grosso de nº 592 de 26 de maio de 2017 (BRASIL, 2007), publicada no Diário Oficial do Estado do Mato Grosso no dia 26 de maio de 2017. O Simcar é regulamentado pelo Decreto 1.031, publicado no Diário Oficial do Estado do Mato Grosso no dia 2 de junho de 2017 (BRASIL, 2007). A Lei Complementar nº 592, dispõe sobre o Programa de Regularização Ambiental (PRA), institui o Simcar e disciplina o Cadastro Ambiental Rural (CAR) (BRASIL, 2007).

O estado do Mato Grosso já possuía um Programa de Regularização Ambiental chamado MT Legal, que contemplava o CAR e o Licenciamento Ambiental Único (LAU) e utilizava o Simlam como plataforma. Devido à publicação do ACF, o estado do Mato Grosso, em 2014, precisou se adequar à legislação federal, aderindo ao sistema federal: o Sicar.

Em 2016, a Sema/ MT identificou que o Sicar não atendia à demanda das análises dos cadastros realizados no Estado do Mato Grosso. Sendo assim, a secretaria decidiu retomar ao Simlam e começou o planejamento do sistema de regularização ambiental criando o Sistema Mato-grossense de Cadastro Ambiental Rural (Simcar) (BARROS, 2017).

O novo sistema permite que os produtores realizem a inscrição de novos imóveis rurais e a retificação dos cadastros serão transferidos do Sicar para o Simcar. Todos os cadastros antigos do Sicar, serão migrados de forma automática pela Sema/ MT para o novo sistema e, obrigatoriamente, deverão ser retificados no prazo de 90 dias após a data da publicação do Decreto que regula o Simcar que foi no dia 2 de Junho de 2017. (BRASIL, 2016c)

O Simcar tem como objetivos: receber, gerenciar e integrar os dados de todos os CAR do Mato Grosso; Cadastrar e controlar as informações dos imóveis rurais, referentes ao seu perímetro e localização da propriedade, aos remanescentes de vegetação nativa, às APP, às Áreas de Uso Restrito, às Áreas Consolidadas e monitorar a manutenção, a recomposição, a regeneração, a compensação e da cobertura vegetal nas APP; e promover o planejamento ambiental, conservação e econômico das propriedades do estado do Mato Grosso (BRASIL, 2017c).

Com a criação do Simcar todos os CAR feitos no estado do Mato Grosso deverão ser migrados para a nova plataforma. Com isso, todos os cadastros migrados do Sicar para o Simcar deverão ser retificados, devido à alteração do sistema e às novas exigências da legislação estadual, definidas na Lei Complementar nº 592. Um dos motivos para os cadastros terem a

obrigação de serem retificados é que, ao contrário do Sicar que não cobra anexar ou enviar documentos pessoais ou do imóvel no ato da inscrição, o Simcar possui essa nova exigência, para evitar possíveis grilagens de terra. Os cadastros que forem migrados da base de dados do Sicar para o Simcar só serão analisados e validados somente após a sua retificação, de acordo com o atendimento das novas metodologias empreendidas pela Sema MT (BRASIL, 2017d).

Após formalizada a inscrição no CAR, por meio do Simcar, o processo seguirá automaticamente para a fase de regularização ambiental da propriedade ou posse rural, que é composta por uma etapa de análise e validação das informações declaradas no CAR, identificação da cobertura vegetal, fixação do percentual a alocação e delimitação do registro das APP, e áreas de uso restrito e eventual resolução de sobreposições de áreas. Após as etapas de análise e validação e realizada a avaliação da proposta de regularização dos passivos ambientais (PRA) se houverem das APP, RL ou Uso Restrito, realizada pelo proprietário e/ou possuidor rural, com a consequente assinatura do correspondente Termo de Compromisso.

O Simcar cobra taxas referentes à análise dos CAR do estado do Mato Grosso e dentro dessas análises estão a análise das informações e documentos inerentes ao CAR e da Regularização Ambiental de posse e propriedades rurais. A cobrança das taxas só é realizada de propriedades acima de quatro módulos fiscais. A taxa é de 8 unidades de padrão fiscal (UPF) o UPF é um indexador que corrige as taxas cobradas pelos estados brasileiros, como IPVA e ICMS, sendo que o valor da UPF, no estado do Mato Grosso, em julho de 2017, corresponde a R\$ 124,88 (BRASIL, 2017a).

Para explicar e fomentar a maneira de utilização do Simcar, a Sema/ MT preparou um material explicativo, *on line*, com vídeo aulas aos usuários e vídeos às entidades representativas do setor produtivo de Mato Grosso, como Federação da Agricultura e Pecuária do Estado de Mato Grosso (Famato) e Centro das Indústrias Produtoras e Exportadoras de Madeira do Estado de Mato Grosso (Cipem), para que essas entidades possam contribuir com a distribuição desse material nos municípios e sindicatos rurais (BRASIL, 2017e).

Para realizar o armazenamento dos dados do Simcar, a Sema/ MT desenvolveu o Sistema Integrado de Gestão Ambiental (Siga) como uma ferramenta que centralizará todos os serviços, tanto internos quanto externos, disponibilizando e armazenando os dados pessoais dos usuários e histórico. O Siga será utilizado no primeiro momento para realizar os cadastros de pessoas que utilizarão o Simcar, mas, posteriormente, todos os sistemas da Sema/ MT utilizarão a ferramenta. Com o Siga, o usuário terá apenas um *login* e uma senha, para acessar tudo o que a Sema oferece (BRASIL, 2017f).

Na plataforma do Simcar, na área “Propriedade” (Figura 18), são solicitadas informações referentes como Nome, atividade, endereço, e, inclusive, a inserção dos documentos digitais, para poder prosseguir com o processo de cadastro (BRASIL, 2017g).

Figura 18 – Informações referentes à propriedade

The screenshot shows the 'Editar CAR' interface in the SIMCAR system. The 'Propriedade' tab is active. The form contains the following sections:

- Identificação da Propriedade:** A text field for 'Nome da Propriedade' with the value 'Propriedade Teste'.
- Atividade:** A dropdown for 'Atividade' with 'Pecuária' selected. There are radio buttons for 'Desenvolvida' (selected) and 'Pretendida'. An 'Adicionar' button is present.
- Endereço:** Fields for 'UF' (MT), 'Município' (Pacoté), and 'Zona de Localização' (Zona Rural). A text area for 'Roteiro para Localização' contains the instruction 'Insira aqui o roteiro para localização.'
- Documentos Digitais:** A section for uploading files. A table below shows a document with 'CPF' as the description, 'Documento.JPG' as the name, and 'Pendente' as the status.

At the bottom, there are 'Cancelar' and 'Salvar/Avançar' buttons.

Fonte: Manual de Operação do Simcar - Versão 1.0 - maio 2017

Na tela “Interessado” (Figura 19), devem ser informados dados referentes ao proprietário como o CPF ou CNPJ, que, ao serem preenchidos, são verificados na base única da Sema. Para tanto, basta inserir a informação no respectivo campo pertinente e clicar no botão “Buscar”. E, da mesma forma que nas telas anteriores, para salvar e prosseguir no cadastro, basta selecionar o item “Salvar/Avançar” (BRASIL, 2017g).

Figura 19 – Seção “Interessado” do Simcar

Fonte: Manual de Operação do Simcar - Versão 1.0 - maio 2017

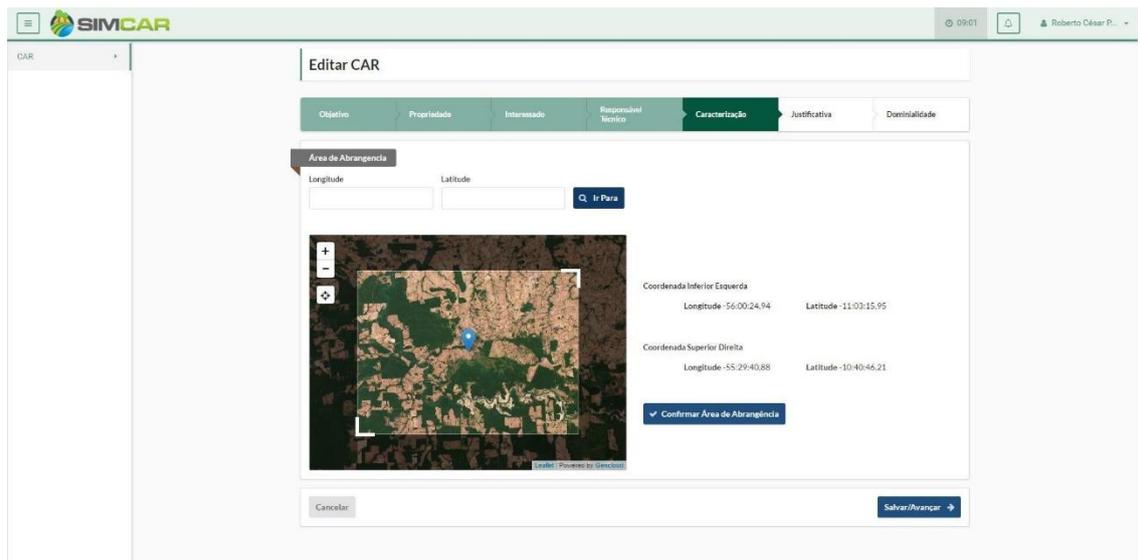
A tela apresentada, a seguir, é a de “Responsável Técnico” (Figura 20), em que o usuário pode ou não designar um Responsável Técnico para a propriedade. E, da mesma forma da tela anterior, basta aplicar o CPF ou CNPJ que o sistema preenche os restantes dos dados (BRASIL, 2017g).

Figura 20 – Seção “Responsável Técnico” do Simcar

Fonte: Manual de Operação do Simcar - Versão 1.0 - maio 2017

No tópico “Caracterização” (Figura 21), deve ser selecionada uma área de enfoque. Para tanto, é possível utilizar um mapa disponibilizado pelo sistema, que está localizado ao final da tela, ou buscar uma localização pelo ponto de coordenadas. Para buscar, basta inserir a longitude e latitude do local desejado e selecionar “Ir Para”. Após a localização da área de enfoque, deve ser selecionada a opção “Confirmar Área de Abrangência” (BRASIL, 2017g).

Figura 21 – Caracterização da área de abrangência – 1ª parte



Fonte: Manual de Operação do Simcar - Versão 1.0 - maio 2017

Após a confirmação da área de abrangência, o sistema apresenta as informações, processa a base de referência e disponibiliza o “Arquivo modelo” e a “Base de Referência” para auxiliar o usuário na confecção da parte GEO. O credenciado poderá importar um ou mais arquivos *shape*, caso utilize alguma ferramenta externa como o *QGIS* ou *ARCGIS*, ou poderá utilizar o próprio desenhador do sistema para confeccionar o projeto GEO (Figura 22) (BRASIL, 2017g).

Figura 22 -- Caracterização da área de abrangência – 2ª parte

The screenshot displays the 'Editar CAR' interface in the SIMCAR system. At the top, there is a navigation bar with the SIMCAR logo and user information (Roberto César P.). The main content area is divided into several sections:

- Objetivo:** A horizontal menu with tabs for 'Objetivo', 'Propriedade', 'Interessado', 'Responsável Técnico', 'Caracterização' (selected), 'Justificativa', and 'Determinação'.
- Área de Abrangência:** Contains fields for 'Coordenada Inferior Esquerda' (Longitude: -55:52:42.69, Latitude: -10:57:36.24) and 'Coordenada Superior Direita' (Longitude: -55:37:20.66, Latitude: -10:46:21.37), with a 'Descartar' button.
- Base de Referência:** Shows 'Situação: Processamento concluído' and 'Data de Conclusão: 05/04/2017 09:05', with a 'Reprocessar' button.
- Importador de Shape:** Includes a warning: 'Caso seja feita uma importação de shape o projeto GEO que está em elaboração será substituído.' and an 'Aguarde o fim do processamento' indicator.
- Desenhador GEO:** Features an 'Abre Desenhador Geo' button.
- Processar e Validar:** Shows 'Situação: Em processamento' and 'Data de Início: 05/04/2017 09:05', with a 'Reprocessar' button.
- Documentos:** A table listing files:
 

Nome	Descrição	
Arquivo Modelo	Arquivo ZIP com os arquivos Shapefile de modelo para elaboração do projeto	[Download]
Base de Referência	Arquivo ZIP com os arquivos Shapefile contendo a base de referência necessária para elaboração do projeto	[Download]
Arquivo Enviado	Arquivo ZIP com os arquivos Shapefile enviados	[Download]
Relatório de Importação	Arquivo PDF do relatório que identifica o resultado do processo de importação do arquivo enviado	[Download]

At the bottom, there are 'Cancelar' and 'Salvar/Avançar' buttons.

Fonte: Manual de Operação do Simcar - Versão 1.0 - maio 2017

O sistema envia uma mensagem avisando que o processamento do projeto geográfico está correto ou não. É emitido, também, um relatório informando sobre falhas na importação do PDF (PDF Relatório de importação) e PDF de processamento (PDF Relatório de processamento). Caso o credenciado opte por importar um arquivo *shape* com o seu projeto GEO, deve fazer o *upload* do arquivo, o sistema processa a importação e como resultado dessa importação disponibiliza o Relatório de Importação no “grupo Documentos”. É importante que o usuário abra este documento para confirmar se não ocorreu nenhum problema na importação (Figura 23) (BRASIL, 2017g).

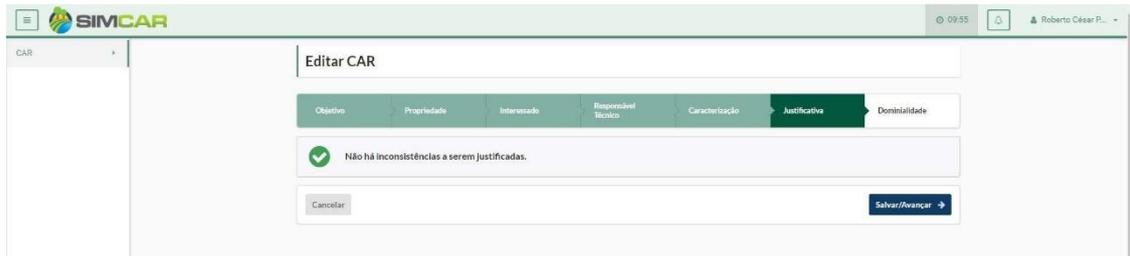
Figura 23 -- Caracterização da área de abrangência – 3ª parte

Fonte: Manual de Operação do Simcar - Versão 1.0 - maio 2017

Caso o processamento seja aprovado com sucesso, o sistema exibe as informações relacionadas a Área de Reserva Legal (ARL), e o usuário deve responder se concorda ou não com a ARL exigida e o déficit indicado. Existindo também alguma inconsistência no projeto GEO que seja passível de justificativa, o credenciado deve indicar que vai justificar as mesmas para seguir com o cadastro, ou fazer suas devidas correções (BRASIL, 2017g).

Na tela de “Justificativa” Figura 24, caso o usuário concorde com a decisão da tela anterior a respeito da ARL, não será necessário apresentar justificativa. Caso contrário, se o usuário optou por informar uma área divergente das áreas exigidas pelo sistema ou justificar alguma inconsistência, ele terá de apresentar uma justificativa (BRASIL, 2017g).

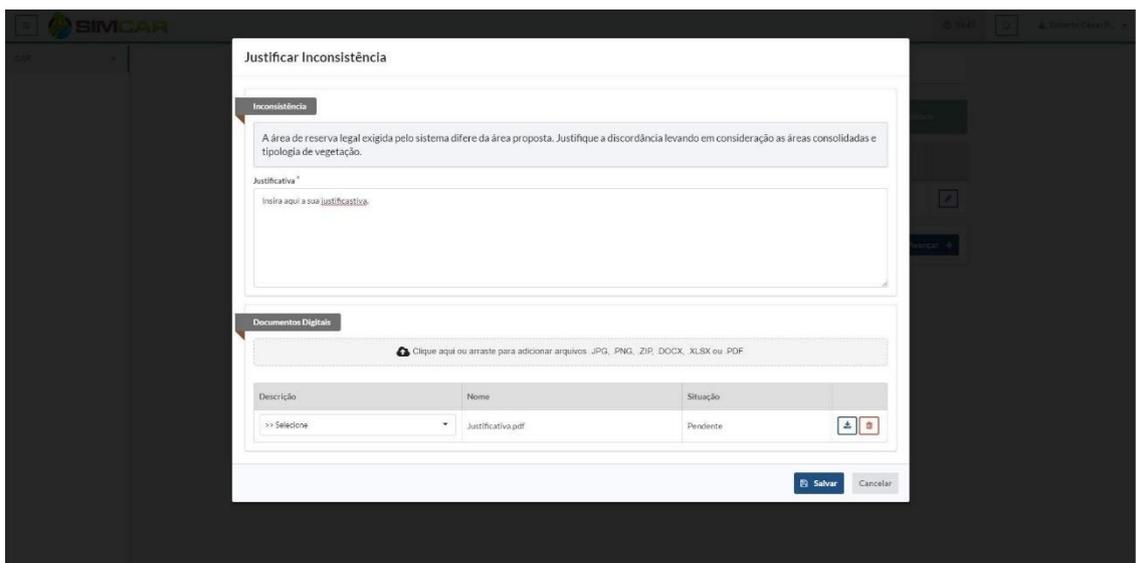
Figura 24 – Seção “Justificativa” do Simcar



Fonte: Manual de Operação do Simcar - Versão 1.0 - maio 2017

Se na tela “Justificativa” houver uma ou mais inconsistências, para justificar, basta clicar no ícone “Editar” (Figura 25). O usuário deve justificar a discordância das áreas e pode fazer *upload* dos documentos digitais para embasamento de sua justificativa (BRASIL, 2017g).

Figura 25 – Campo para justificar possíveis inconsistências



Fonte: Manual de Operação do Simcar - Versão 1.0 - maio 2017

Na tela “Dominialidade” (Figura 26), a última do cadastro, o sistema exhibe as matrículas ou posses informadas no projeto GEO da caracterização. Na edição do “Dominialidade” (Figura 27), devem ser informados os dados e a documentação da Área do Imóvel Rural (AIR), adicionar os documentos digitais necessários e preencher as informações da(s) Reserva(s) Legal(ais). O cadastro finalizado aparece na lista da tela inicial (BRASIL, 2017g).

Figura 26 – Seção “Dominialidade” do Simcar – 1ª parte

Georreferenciada	Tipo	Identificação	Área (ha)	Possui ARL?
Sim	Matrícula	Matrícula 1	227,3549	Sim

Fonte: Manual de Operação do Simcar - Versão 1.0 - maio 2017

Figura 27 - Seção “Dominialidade” do Simcar – 2ª parte

Fonte: Manual de Operação do Simcar - Versão 1.0 - maio 2017

É importante destacar que, até a presente data, não há no Simcar tratamento diferenciado para o CAR de Imóvel Rural de Assentamentos da Reforma Agrária e de Imóvel Rural de Povos e Comunidades Tradicionais. Também não há registro se ele pode ser adaptado à realidade de outros estados (BRASIL, 2017g).

### 5.1.6 Mapeamento Anual da Cobertura e Uso do Solo do Brasil (MapBiomás)

Segundo Azevedo e Saito (2013), o Sistema de Licenciamento Ambiental em Propriedades Rurais (SLAPR), implementado em Mato Grosso, no ano de 2000, foi a primeira iniciativa de sistema de monitoramento e controle de imóveis rurais, os projetos Radam (Radar da Amazônia), iniciado em 1970, e Radambrasil, fruto da expansão do projeto original para todo o território nacional, em 1975, foram as primeiras iniciativas nacional para mapear recursos minerais, tipos de solo, vegetação, e uso da terra. Para tanto, os projetos do Ministério

das Minas e Energia utilizavam imagens de radar aereotransportado, interpretação visual e trabalho de campo extenso e detalhado, e envolviam várias equipes de diferentes organizações. O RadamBrasil produzia mapas a escala 1:250.000 e é, ainda, uma referência sólida para estudos científicos e técnicos sobre vegetação (IBGE, 2017).

Em 2004, o Ministério do Meio Ambiente (MMA) lançou, no âmbito do Projeto de Conservação e Utilização Sustentável da Diversidade Biológica Brasileira (Probio), dois editais a fim de selecionar seis subprojetos para mapear a cobertura vegetal, adotando-se o recorte dos seis biomas estabelecidos no Mapa de Biomas do Brasil (BRASIL, 2004). O objetivo era suprir a demanda de um mapeamento mais preciso desde o RadamBrasil, pois apenas os biomas Amazônico e Mata Atlântico estavam sendo monitorados após o término daquele projeto. Foram utilizadas imagens *Landsat* adquiridas em 2002, com unidade de mapeamento mínimo variando de 40 a 100 hectares e escala de mapeamento de 1:250.000. A avaliação de precisão foi baseada em produtos de imagens digitais em 1:100.000, com um mínimo de precisão geral de 85%. As classes de cobertura do solo seguiram as diretrizes do manual do Instituto Brasileiro de Geografia e Estatística (IBGE) para a vegetação (BRASIL, 2004). O projeto Probio teve atualizações para as mudanças florestais em 2008 com referência a todos os biomas, e em 2009, 2010 e 2011, somente para alguns biomas.

Com o objetivo de verificar a possibilidade e a viabilidade de se criar mapas anuais com a cobertura e o uso do solo, em todo o Brasil, de forma significativamente mais barata, rápida e atualizável, comparativamente aos métodos e práticas vigentes, e que possibilitassem recuperar o histórico das últimas décadas, o Sistema de Estimativa de Emissões de Gases de Efeito Estufa (SEEG/ OC) reuniu, em 2015, um grupo de especialistas em sensoriamento remoto e mapeamento de vegetação. A conclusão dos debates foi a de que era possível alcançar essa meta, desde que estivessem disponíveis uma alta capacidade de processamento e um alto grau de automatização do processo, e que o processo deveria envolver a participação de uma comunidade de especialistas em cada bioma e temas transversais (JUNIOR, 2017).

Surge, então, o Projeto de Mapeamento Anual da Cobertura e Uso do Solo do Brasil (MapBiomas), uma iniciativa que envolve uma rede colaborativa com diversos especialistas em diversas áreas incluindo: especialistas em cada um dos biomas nacionais, nos usos da terra, em sensoriamento remoto, no Sistema de Informações Geográficas (SIG) e em Ciência da Computação (JUNIOR, 2017).

O MapBiomas utiliza processamento em nuvem com classificadores automatizados desenvolvidos e operados a partir da plataforma *Google Earth Engine* para gerar uma série histórica de mapas anuais da cobertura e do uso da terra no Brasil. Para tanto, foi assinado um

termo de cooperação técnica com o *Google* para desenvolver a iniciativa tendo como base a plataforma *Google Earth Engine*. (JUNIOR, 2017).

O projeto tem por objetivo contribuir para o entendimento da dinâmica do uso e ocupação do solo no Brasil e em outros países tropicais, considerando: i) o desenvolvimento e a implementação de uma metodologia rápida que seja confiável e de baixo custo para gerar mapas anuais de cobertura e uso do solo do Brasil a partir de 1985 até os dias atuais; ii) a criação de uma plataforma para facilitar a disseminação da metodologia para outros países e regiões interessadas; iii) o estabelecimento de uma rede colaborativa de especialistas nos biomas brasileiros para o mapeamento da cobertura do solo; iv) a possibilidade de trabalho colaborativo em Rede com instituições responsáveis por cada biomas e temas transversais (JUNIOR, 2017).

Para realizar as análises de acurácia dos mapas produzidos pelo MapBiomias uma das estratégias é coletar amostras por meio de análises visuais em imagens de alta resolução. Para que fosse possível gerenciar a coleta das amostras e realizar amostras de inventário florestal, o MapBiomias aderiu ao programa *Collect Earth* desenvolvido pela Organização das Nações Unidas para Agricultura e Alimentação (FAO). Como esse programa foi originalmente desenvolvido para o ambiente *desktop*, para possibilitar a sua utilização pelo MapBiomias, que utiliza uma plataforma de trabalho em nuvem, foi necessário o desenvolvimento do aplicativo *WebCollect*. Com esse aplicativo, que é a versão do *Collect Earth* para ambientes em nuvem, será possível que múltiplos analistas trabalhem simultaneamente em projetos de amostragem de cada bioma (JUNIOR, 2017).

O MapBiomias é baseado no processamento de mosaicos criados a partir das melhores cenas do ponto órbita durante o período do ano em que é analisado, utilizando a série de satélites *Landsat* abrangendo o período de 1985, começo da série de satélites *Landsat*, até os dias atuais (MAPBIOMAS, 2017).

No dia 28 de abril de 2017, em Brasília, foi lançada a segunda coleção de mapas do MapBiomias, com dados inéditos sobre as transformações do território brasileiro ao longo do século XXI e com imagens de satélite que vão dos anos 2000 até o ano de 2016. Esses dados revelaram um cenário de dificuldade para a preservação dos biomas brasileiros, como a perda de 20% da área de manguezais entre 2001-2015, em boa parte destruídos pela expansão urbana. No mesmo período, 13% do Pantanal foi perdido sendo que estas áreas perdidas foram convertidas em áreas de pastagem. Mesmo assim, o Pantanal é o bioma brasileiro mais preservado. Já o Cerrado teve perdas proporcionalmente três vezes mais elevadas do que as sofridas pelo bioma Amazônico. Mas, por outro lado, houve o ganho de 2,5 milhões de hectares de Mata Atlântica (o equivalente a quase uma Bélgica), graças a programas de reflorestamento

e conscientização sobre a importância do bioma para a biodiversidade do país (MAPBIOMAS, 2017).

## **5.2. Caracterização da área de estudo**

### **5.2.1 Bioma Amazônico**

O bioma amazônico é o mais extenso dos biomas predominantemente florestais do território brasileiro. Estende-se do Oceano Atlântico até as encostas orientais da Cordilheira dos Andes, atingindo até aproximadamente 600 m de altitude. É constituído por nove países da América do Sul, sendo que 69% da área total pertencem ao Brasil (AB'SABER, 1977). Esse bioma recobre os estados do Acre, Amapá, Amazonas, Goiás, Maranhão, Mato Grosso, Pará, Rondônia e Roraima, totalizando 4.871.000 km<sup>2</sup>.

O bioma amazônico é formado por diversos ecossistemas distintos entre si, como florestas densas de terra firme, florestas estacionais, florestas de igapó, campos alagados, várzeas, savanas, refúgios montanhosos e formações pioneiras (BRASIL, 2010). E engloba a maior floresta tropical existente, compreendendo 1/3 das florestas tropicais úmidas do planeta. A fauna e a flora são extremamente diversificadas, sendo que muitas delas são endêmicas, ou seja, ocorrem exclusivamente no bioma amazônico.

Estima-se que a maior biodiversidade, o maior banco genético do mundo e 1/5 da disponibilidade mundial de água potável estejam no bioma amazônico. (IBGE – Índice de Desenvolvimento Sustentável, 2012). Embora as florestas tropicais cubram apenas 7% da superfície do nosso planeta, elas abrigam cerca de 60% dos organismos da biosfera. Reafirma-se, então, o quão crucial é o valor desse ecossistema. (NEPSTAD et al., 2008). Mesmo assim, a Amazônia é tida como a última fronteira brasileira de colonização e estima-se que já foram perdidos cerca de 967.003km<sup>2</sup> de cobertura florestal, devido ao processo de ocupação (NOGUEIRA et al. 2015).

### **5.2.2 Histórico da ocupação agrícola no norte do estado do Mato Grosso**

O desenvolvimento e a expansão demográfica na Amazônia podem ser descritos historicamente por três fases de ocupação. A primeira fase é representada pelos pioneiros: povos indígenas, garimpeiros e populações ribeirinhas. A segunda fase foi fomentada pela exploração

extrativista de bens naturais, como o período da extração da borracha por migrantes nordestinos e o período das “drogas do sertão”. A terceira fase ocorreu durante o regime militar, com o objetivo de ocupar os vazios demográficos por meio da expansão de projetos agropecuários. (BECKER 2004, SAYAGO et al. 2004, CARDOSO e MULLER 1978).

A Superintendência do Desenvolvimento da Amazônia (Sudam) e a Superintendência do Desenvolvimento do Centro-Oeste (Sudeco) estimularam a migração de investidores por meio de políticas públicas de incentivos fiscais e isenção de tributos. Essas superintendências visavam a tecnificação e a modernização da produção, promovendo a privatização de terras e a consequente substituição do modelo agropecuário familiar (COSTA, 2000).

Por volta dos anos 1970, com a abertura das rodovias Cuiabá-Santarém (BR-163) e Transamazônica (BR-230), os programas de desenvolvimento da região amazônica, como o Programa de Integração Nacional (PIN), consideraram o estado do Mato Grosso um importante polo estratégico. Essas rodovias possibilitaram a implementação de programas de ocupação e exploração de madeira no extremo norte do estado, resultando na criação de cidades pelo Instituto Nacional de Colonização e Reforma Agrária (Incrá) (MORENO e HIGA, 2005; VILARINHO NETO, 2009; MENDES, 2012).

Portanto, o Incra priorizou a criação de projetos de assentamentos em Rondônia e Mato Grosso com três objetivos básicos: a contenção do êxodo rural em direção às grandes metrópoles do Sudeste e a reorientação do mesmo para a Amazônia, o desenvolvimento da agricultura visando o abastecimento interno e externo, e a diminuição das tensões sociais provocadas pelo minifúndio no Sul e latifúndio no Nordeste do país (KAUANO; PASSOS, 2008; PASSOS, 2000).

### **5.2.3 Situação fundiária no norte do estado do Mato Grosso**

Em meados da década de 1970, a colonização governamental, antes efetuada pelo Incra, passou a ser comercial, marcada pela venda de grandes extensões de terra a empresas colonizadoras, frente à necessidade de ocupação rápida de uma área extensa como a Amazônia, como também, à considerável escala nos investimentos e de organização empresarial. Tais iniciativas visavam à produção de cereais, carne, à extração de minérios e madeira para atender ao mercado internacional, com incentivos fiscais e creditícios a grandes empresas nacionais e multinacionais. Este processo de colonização resultou no surgimento de cidades como Sinop, Vera, Matupá, Sorriso e Alta Floresta (TEIXEIRA, 2004; HESPANHOL, 2000).

A expansão da fronteira agropecuária na Amazônia é parte do processo de avanço da pecuária extensiva nas áreas de florestas, por meio do desmatamento e do fogo, seguido do cultivo de lavouras temporárias para a formação de pastagens, que, iniciado no Sudeste do país, comandou as mudanças em larga escala no uso da terra no Brasil nos últimos cinquenta anos (BECKER, 2004). A economia e a população na fronteira agrícola dessa região apresentam taxas de crescimento superiores ao restante do país, e estão fundamentadas na criação de núcleos urbanos, com atração de fluxos migratórios (BECKER, 2004, 1997).

Becker (2004) destaca que no “arco do desmatamento” a escala e a lógica estão associadas a atividades que tendem a se intensificar, e que essa vasta área não é mais uma fronteira de ocupação, mas sim uma área de povoamento consolidado, com significativo potencial de desenvolvimento, seja pela intensificação do povoamento e das atividades produtivas, ou pela recuperação das áreas alteradas e/ ou abandonadas. Essa mesma autora analisa que a entrada e expansão da agricultura capitalizada na Amazônia constitui-se em uma novidade histórica, particularmente por se tratar de uma região fortemente dominada por atividades extrativistas, mineral e vegetal. Além disso, a sua consolidação não deve ser vista como contraditória com a manutenção da riqueza ambiental, desde que sejam respeitados os limites impostos pela fragilidade do seu bioma.

Para os agricultores familiares, o desmatamento da área e a substituição da vegetação por pastagem foi apresentada como alternativa mais rápida para a valorização de suas terras. Para o grande agricultor que pratica agricultura baseada em latifúndios, o desmatamento e a implantação da pecuária extensiva foi a forma encontrada para garantir a legitimação jurídica da propriedade (TEIXEIRA, 2004).

#### **5.2.4 Histórico dos assentamentos**

A história dos assentamentos de Reforma Agrária no país se inicia nos anos 1960, com os debates sobre as reformas de base e o Estatuto da Terra (SAUER, 2005; SPAROVEK, 2003). Com o governo militar foi implementada uma política voltada à expansão agrícola e à ocupação do território nacional que usou a Reforma Agrária como estratégia para tal expansão (SZMRECSANYI; DELGADO; RAMOS, 2005).

Os assentamentos surgem, então, como resultado da pressão popular e dessa política, e representando uma expectativa de vida nova aos nordestinos atingidos pela seca e aos moradores dos grandes centros urbanos, principalmente do estado São Paulo, que buscavam novas oportunidades (BECKER, 2001; OLIVEIRA, 1991).

A motivação para a grande maioria dos que migraram para a Amazônia Legal durante a expansão agrícola foi a oferta de terras e de crédito subsidiado (BECKER, 2001). Tais famílias, em sua maioria, estavam vinculadas a projetos de colonização do recém-criado Incra, e moravam ao longo da Transamazônica e da BR-163 no Estado do Pará, as principais rodovias da Amazônia Legal (OLIVEIRA, 1991).

Embora tenha-se passado meio século, desde o início da política de ocupação, a Amazônia Legal ainda representa a principal fronteira de expansão da Reforma Agrária. Mais de um terço (3.589) dos assentamentos brasileiros estão localizados na região. Conforme o Sistema de Informações de Projetos de Reforma Agrária (Sipra), cerca de 62% (2.217) dos assentamentos da Amazônia Legal estão localizados no bioma Amazônico (ALENCAR et al., 2016).

A Amazônia Legal contém 39% do total de assentamentos do país, significando 41,8 milhões de hectares (8% da área da Amazônia Legal). No entanto, esta área representa 81% da área destinada à Reforma Agrária no Brasil. (ALENCAR et al., 2016).

Apesar de esses assentamentos também terem um importante papel na conservação das florestas (LE TOURNEAU; BURSZTYN, 2010), como esperar que os assentados consigam conservar as áreas de vegetação nativa, durante a implementação dos assentamentos não foram dados os recursos necessários tais como infraestrutura de transporte, energia, serviços sociais básicos e assistência técnica (PASQUIS et al., 2005).

Os assentamentos tem corroborado de forma contínua para o aumento do desmatamento total da Amazônia nas últimas décadas. A área desmatada da Amazonia Legal correspondente aos assentamentos era de 18 % entre 2003 e 2005. Entre os anos de 2010 e 2014 a média aumentou para 30%. E atualmente corresponde a cerca de 40%. Esse aumento causou uma preocupação no governo federal, que percebem que a redução do desmatamento nos assentamentos apresenta um grande desafio para a sustentabilidade desses assentamentos e para o cumprimento das metas de redução de emissões de gases do efeito estufa, principalmente de CO<sub>2</sub> causados pelo desmatamento na região. (ALENCAR et al., 2016).

Uma característica importante a ser ressaltada é o fato de que uma grande parte dos assentamentos recentes, principalmente os Projetos de Assentamentos (PA), foi criada incluindo grandes passivos florestais. Portanto, não é correto afirmar que a área desmatada é totalmente consequência das práticas produtivas pelos assentados (ALENCAR et al., 2016).

Para se chegar a essa conclusão foi realizada uma análise que considerou os 1.759 assentamentos criados a partir de 1997. Os resultados mostram que 46% da área dos 815 assentamentos criados entre 1997 e 2003 já estava desmatada antes mesmo de serem criados.

Os 736 assentamentos criados no período de 2004 a 2008, foram estabelecidos com, em média, 43% de sua área desmatada. Os outros 208 assentamentos criados a partir de 2009 apresentaram, em média, apenas 33%. (ALENCAR et al., 2016).

De acordo com o levantamento realizado pela Superintendências Regionais do Incra, a pecuária extensiva é a principal atividade responsável pelo desmatamento nos assentamentos, e é citada como fator principal em todas as onze Superintendência Regionais da Amazônia. Esse fato reafirma a pecuária como principal atividade da Amazônia rural, que ocupa aproximadamente 80% das áreas desmatadas na região (BOWMAN et al., 2012). A pecuária é uma das atividades predominantes na grande maioria dos assentamento devido ao baixo custo, fácil implantação, manutenção e por possuir um mercado seguro (WALKER, MORAN e ANSELIN, 2000). Contudo, como a produtividade da pecuária extensiva na Amazônia é mais baixa que na média nacional, uma densidade de 0,8 cabeças por hectare, e como a pecuária extensiva tradicional implementada no Brasil não realiza o manejo das pastagens, esse fato gera uma demanda para incorporar novas áreas de pastagem, causando um desmatamento quase que permanente (BROWDER et al., 2008). Ademais, a pecuária extensiva é apoiada por programas de fomento à produção e crédito rural, como o Programa Nacional de Fortalecimento da Agricultura Familiar (Pronaf) e o Fundo Constitucional do Norte (FNO) (COSTA, 2000; SCHONS; AZEVEDO; ALENCAR, 2013).

A exploração ilegal de recursos madeireiros é outro vetor importante do desmatamento nos assentamentos da Amazônia Legal, na maioria das vezes, coloca os assentados em condição desfavorável no que diz respeito ao valor pago na madeira retirada. Além do baixo custo pago na madeira, o estado da floresta remanescente (pós-extração) prejudica muito o desenvolvimento sustentável da propriedade (LIMA et al., 2006).

Reforçando esse pensamento, segundo Merry et al. (2006) essa atividade, apesar de gerar uma renda inicial e infraestrutura de acesso às famílias, a dinâmica de extração de recursos madeireiros em assentamentos da Amazônia Legal é efetuada sem plano de manejo e planejamento adequado de infraestrutura, degradando a vegetação nativa remanescente. O que reduz o seu valor comercial e abre caminho para a implantação de outras atividades, como a pecuária extensiva e a agricultura de corte e queima, práticas muito prejudiciais para a biodiversidade.

Segundo Alencar et al. (2016), a Assistência Técnica e Extensão Rural (Ater) é uma das principais assistências de qualquer sistema produtivo que envolva o uso da terra. Sendo assim, uma Ater de qualidade deve considerar cada um dos aspectos ambientais, sociais e tecnológicos, e focar não somente a propriedade, mas também as potencialidades do assentamento como

um todo. Com isso, a Ater se torna em um poderoso instrumento de disseminação de práticas produtivas sustentáveis e uma das principais peças para o desenvolvimento sustentável dos assentamentos. Mesmo com a orientação do Incra e do Ministério do Desenvolvimento Agrário (MDA), a luta dos movimentos sociais por uma Ater voltada para a implementação e transição para a produção agroecológica, a maioria das Ater praticadas nos assentamentos, além de ser insuficiente, ainda é focada no acesso ao crédito voltado principalmente para a pecuária. Sendo que o crédito rural mais difundido é para o fomento do crescimento da produção agropecuária implantada de forma extensiva e para produtos agrícolas normalmente não adaptados ao mercado e demandas locais.

Mesmo que a grilagem ocorra principalmente fora dos assentamentos, esse processo também é identificado em assentamentos da Amazônia Legal, envolvendo principalmente a apropriação e compra ilegal de lotes (SIMMONS, 2004). Muitas vezes esse processo acarreta o efeito chamado de “reconcentração”, que corresponde à aglomeração de lotes pertencentes a um único dono. A reconcentração afeta diretamente as taxas de desmatamento e regeneração no assentamento (GODAR; TIZADO; POKORNY, 2012), pois geralmente é realizada por proprietários de médio porte, que identificam nos assentamentos uma alternativa para expandirem a atividade pecuária com menores chances de serem pegos pela fiscalização. O excesso de burocracia que é necessária para reaver as terras adquiridas de maneira ilegal de um assentamento é outro fator que agrava e dificulta essa situação (ALENCAR et al., 2016).

### **5.2.5 Tipos de assentamentos rurais**

O Incra aplicou vários tipos de projetos de ocupação na Amazônia, embora a maioria destes projetos tenha sido abandonada. Dentre eles, a área de estudo compreende três modelos de assentamento, o Projeto de Assentamento (PA), o Processo de Assentamento Conjunto (PAC), e o Projeto de Desenvolvimento Sustentável (PDS).

O Projeto de Assentamento consiste em um conjunto de ações de natureza interdisciplinar e multisetorial planejadas em áreas destinadas à Reforma Agrária. O projeto visa o desenvolvimento territorial e regional e é definido com base em diagnósticos precisos acerca do público beneficiário e das áreas a serem trabalhadas. As ações são orientadas para a utilização racional dos espaços físicos e dos recursos naturais existentes. Além disso, objetiva a implementação dos sistemas de vivência e produção sustentáveis, na perspectiva do cumprimento da função social da terra e da promoção econômica, social e cultural do trabalhador rural e de seus familiares.

Segundo a Instrução Normativa nº15, de 30 de março de 2004 (BRASIL, 2004), art. 3º, é de responsabilidade do Incra a obtenção da terra, a criação do Projeto, a seleção dos beneficiários, o aporte de recursos de crédito, o apoio ao Pronaf, a infraestrutura básica (água, estradas de acesso e energia elétrica), o parcelamento do projeto e a titulação do terreno (Concessão de Uso e Título de Propriedade).

Conforme a Lei nº 4.504, de 30 de novembro de 1964 (BRASIL, 1964), o PAC é um projeto de ocupação oficial implantado pelo Incra em parceria previamente definida com grandes empresas rurais ou cooperativas.

O Projeto de Desenvolvimento Sustentável é uma modalidade de projeto voltada às populações que baseiam sua subsistência no extrativismo, na agricultura familiar e em outras atividades de baixo impacto ambiental. O PDS propõe o desenvolvimento de atividades sustentáveis e ambientalmente diferenciadas.

A Instrução Normativa nº15, de 30 de março de 2004 (BRASIL, 2004), art. 3º também é válida para o PDS. E de acordo com a Portaria nº 477, de 4 de novembro de 1999 (BRASIL, 1999) do Incra, não cabe ao PDS a individualização de parcelas referente à titulação coletiva.

## **5.3 Satélites**

### **5.3.1 Teoria do imageamento por satélite**

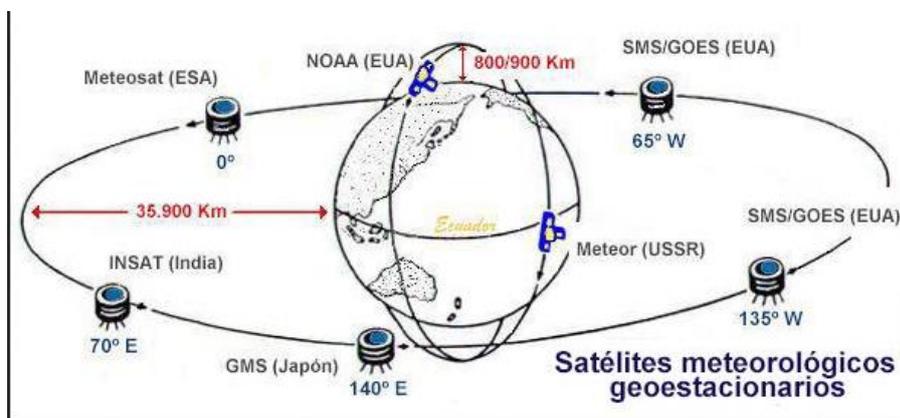
Segundo Lillesand e Kiefer (1994) e Rees (1990), sensoriamento remoto é a ciência por meio da qual são obtidos dados sobre um alvo, área ou fenômeno sem a necessidade de se ter contato direto com o mesmo. A fotografia é um exemplo, pois, durante muito tempo foi a única forma de sensoriamento remoto.

Segundo o enfoque científico abordado por Lillesand e Kiefer (1994), sensoriamento remoto significa observar a superfície e a atmosfera da Terra por meio de sensores localizados muito acima do solo. Tais sensores podem captar tanto o espectro visível, mas também a radiação em outros comprimentos de onda, como o infravermelho, ultravioleta, e as microondas.

O sensoriamento remoto passivo é aquele em que o sensor não emite nenhum tipo de sinal para realizar a captura de informação, mas, sim, utiliza a interação entre a radiação eletromagnética (REM) emitida pelo o Sol e o alvo. Essa interação acontece pela absorção e a reflexão da radiação eletromagnética pelo alvo, quando o sensor capta a energia refletida pelo objeto.

Os dados do sensoriamento remoto podem ser usados para estimar variáveis geofísicas e biofísicas como, por exemplo, posição, altura ou profundidade, temperatura, biomassa, resposta da clorofila, concentração de sedimentos, umidade do solo etc. Algumas das aplicações mais utilizadas para os dados de sensoriamento remoto são a modelagem de processos naturais (mudanças climáticas, eutrofização, desertificação, desastres naturais etc) ou causados pelo homem (desflorestamento, poluição, expansão urbana, deslizamentos etc). (Figura 28) (MORAES, 1999).

Figura 28 – Satélites meteorológicos geostacionários

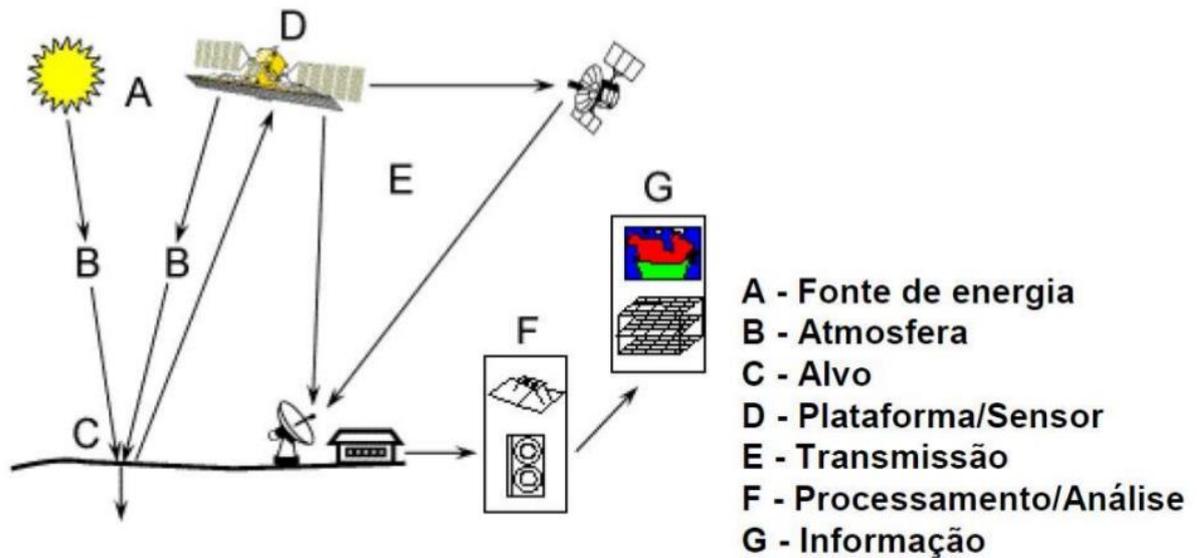


Fonte: <https://ea3atl.ure.es/satsmet/satsmete.htm>

Alguns satélites, denominados Radar de Abertura Sintética (SAR), utilizam sistemas ativos que emitem algum tipo de energia no alvo e capta a energia refletida pelo mesmo. Alguns exemplos de satélites desse tipo são o *Seasat* (EUA), *European Remote Sensing Satellite - ERS-1* (Europa), *Japanese Earth Resources Satellite - JERS* (Japão) e *Radarsat* (Canadá) (Figura 29) (MORAES, 1999).

Já os satélites que não têm enfoque em serviços meteorológicos, em geral, não são geostacionários, imageiam todo o globo terrestre e, por isso, demoram alguns dias para retornar a um mesmo ponto terrestre. O *Sentinel-2*, por exemplo, demora cinco dias. O *Landsat V* (EUA) leva dezesseis dias, possuindo seis sensores espectrais e um sensor termal. O satélite *Satellite Pour l'Observation de la Terre - Spot* (França) tem um ciclo de 26 dias e três sensores espectrais. Esses satélites, denominados multiespectrais, normalmente, utilizam vários sensores embarcados (MORAES, 1999).

Figura 29 – Obtenção de imagens por sensoriamento remoto

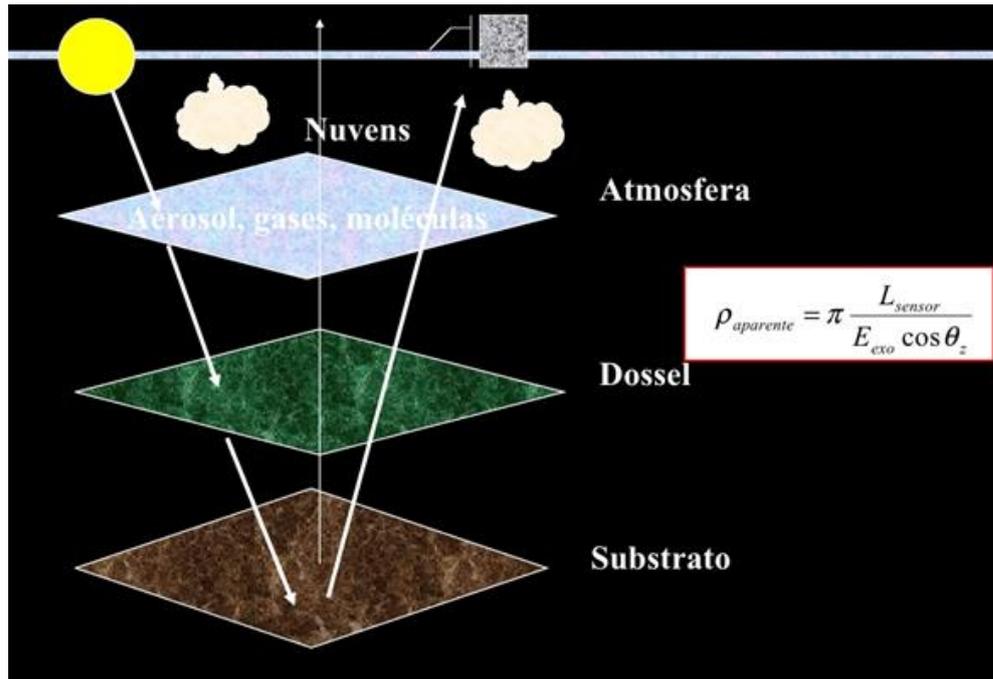


Fonte: ALBUQUERQUE e PONTUSCHKA (2012)

As cenas são realizadas pelos sensores para captar a resposta do alvo em faixas definidas do espectro. Entretanto, como os sensores multiespectrais não captam todo o espectro, eles registram faixas do mesmo. Para detectar ou imagear um objeto, os sensores, no geral, terão alguns limites. Caso o objeto a ser focado for menor que um *pixel*, ele não será imageado, a menos que seu índice de luminosidade se sobreponha aos objetos ao seu redor. Se o tamanho do objeto for igual a um *pixel*, ele também não será detectado, a menos que o *pixel* esteja localizado exatamente sobre ele e o seu índice de luminosidade seja maior que os objetos ao seu redor (MORAES, 1999).

Além disso, um objeto pode ter sua curva espectral alterada no momento em que for imageado na presença de outros objetos muito próximos a ele, podendo a distorção aumentar quando os outros objetos forem menores que os *pixels*, como demonstra a Figura 30. Quando isso ocorre denomina-se “confusão espectral” (MORAES, 1999),

Figura 30 – Confusão Espectral

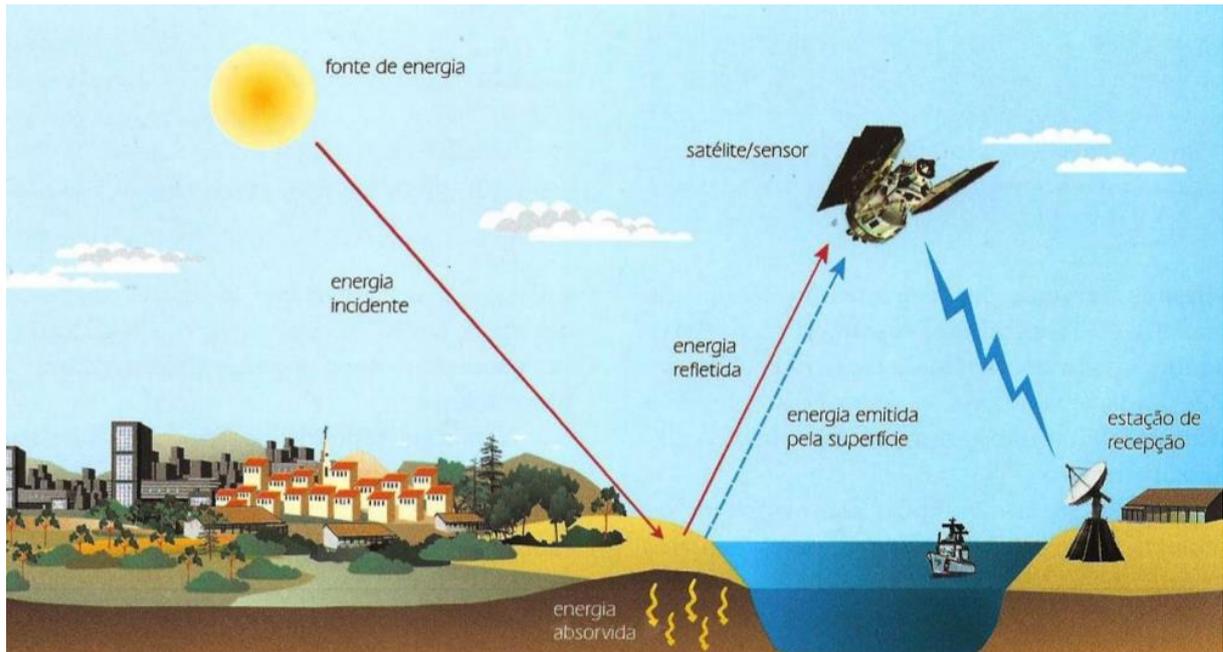


Fonte: SOUSA (2011)

Os sensores do tipo passivo sofrem muita interferência do efeito atmosférico que pode ocorrer de duas formas, dispersão e absorção. A dispersão potencializa a “luminosidade” refletida, enquanto a absorção a retira. A atmosfera, por exemplo, potencializa o comprimento da onda do verde quatro vezes mais que o comprimento da onda do infravermelho. Assim, essa absorção afeta principalmente a faixa do infravermelho, principalmente porque é mais fácil corrigir os efeitos da dispersão do que os da absorção. Outro desafio a ser enfrentado é a qualidade da luz refletida que depende da radiação incidente, visto que a assinatura espectral varia pela quantidade de nuvens do dia (Figura 31) (MORAES, 1999).

Além disso, como dois objetos distintos podem apresentar diferenças espectrais entre si, em faixas específicas do espectro, e como um sensor multiespectral possui poucos intervalos, e esses intervalos são grandes em relação a sistemas hiperspectrais, essas diferenças podem se tornar imperceptíveis para o sensor multiespectral. Para evitar esse tipo de problema, é necessário escolher corretamente as bandas a serem observadas (MORAES, 1999).

Figura 31 – Obtenção de imagens por sensoriamento remoto



Fonte: ALBUQUERQUE e PONTUSCHKA (2012)

### 5.3.2 *RapidEye*

O *RapidEye* é uma constelação de cinco microsatélites multispectrais, cada um desses satélites possui um nome sendo eles: *Tachys*, *Mati*, *Trochia*, *Choros* e *Choma*. Esse conjunto de satélites foi lançado em 29 de agosto de 2008, no cosmódromo de *Baikonur*, no Cazaquistão. Todos os microsatélites foram lançados pelo foguete russo DNEPR-1. O controle dos microsatélites é feito pela *BlackBridge*, empresa alemã do segmento de sensoriamento remoto. Um dos grandes pontos fortes dessa constelação de satélites é o curto período de tempo de revisita que é de apenas 24 horas, pelo imageamento *off-nadir* e imageamento por *nadir* de 5,5 dias (BRASIL, 2013a).

A constelação do *RapidEye* tem todos os seus microsatélites ativos até o momento. Eles possuem vida útil estimada em sete anos. A órbita de todos os microsatélites é do tipo heliosíncrona, com uma inclinação de 97,8 graus e um tempo de órbita de 96,7 minutos. Seu horário de passagem pelo Brasil é às 11 horas da manhã, com uma altitude de 630 quilômetros e um imageamento de 77,25 quilômetros.

A taxa de transferência dos dados satélite solo e vice-versa é de 80Mbps, algo consideravelmente rápido considerando o tamanho deles, a distância da terra, largura da faixa de imageamento é de 77km, o giro em relação a terra de 25°, a precisão de apontamento é menos

a 1º nos três eixos, a capacidade de armazenamento a bordo de cada satélite é de 6gb o que em área é igual a 115.500km<sup>2</sup>, a capacidade da área mapeada é de 4.000.000km<sup>2</sup>. (KEPLER, s.d.)

As características da órbita são: altitude orbital média 643km, inclinação da órbita 97,8 graus, período da órbita de 1h36, com isso temos 14.9 órbitas por dia. O tipo da órbita é uma órbita LEO, uma órbita de baixa altitude hélio síncrona (KEPLER, s.d.).

O sistema sensor utilizado pelo *RapidEye* é o sistema *REIS*, instalado em cada um dos microsatélites. É um sistema *pushbroom* (varredura eletrônica) com números de detectores de 12.288 com seu tamanho de 6,5 µm, distância focal de 636mm com campo de visada de 6,75 graus, com *IFOV* (*Instantaneous Field of View*) de 10.3 µm, resolução radiométrica de 12 bits ou 4.096 tons de cinza resolução temporal de toda a constelação de 5,5 dias (KEPLER, s.d.). Suas bandas e resoluções são divididas conforme discriminado na Tabela 1.

Tabela 1 - Bandas e Resoluções *RapidEye*

Bandas espectrais	Resolução espectral	Resolução espacial
Azul	0.440 – 0.510 micrômetros	6.5 metros (nadir) e 5 metros para ortoimagens
Verde	0.520 – 0.590 micrômetros	
Vermelho	0.630 – 0.690 micrômetros	
<i>Red-Edge</i>	0.690 – 0.730 micrômetros	
Infravermelho próximo	0.760 – 0.880 micrômetros	

Fonte: (KEPLER, s.d.)

Esse estudo não utiliza as imagens do *RapidEye*, pois o governo brasileiro optou pela compra de cenas mosaicos que eliminam todas as nuvens. Esse processo remove os *pixels* com nuvens, substituindo por *pixels* da mesma cena, mas em um período de tempo diferente. Essa característica (eliminação de todas as nuvens) foi solicitada, pois a função dessas cenas e a vetorização dos lotes no processo autodeclaratório do CAR, torna muito mais fácil a vetorização manual pelo proprietário ou técnico e não inviabiliza a classificação. Entretanto, o resultado das classificações não é condizente com a verdade, devido ao fato de não se ter a data exata da cena.

### 5.3.3 Landsat

O satélite *Landsat* começou na segunda metade da década de 1960 com a denominação de *Earth Resources Technology Satellite (ERS)* (tecnologia de satélites para recursos terrestres - tradução livre). Em 1975, o nome foi alterado para *Land Remote Sensing Satellite* (sensoriamento remoto terrestre via satélite - tradução livre) ou como é conhecido *Landsat*. A maioria das missões *Landsat* foram realizadas pela *National Aeronautics and Space*

*Administration* (Administração Nacional da Aeronáutica e Espacial) conhecida pela sigla NASA e pelo *U.S. Geological Survey* (Serviço Geológico Norte Americano) conhecido como USGS que é o órgão que disponibiliza as imagens do *Landsat* para o público (BRASIL, 2013b).

O quinto satélite da família *Landsat*, o *Landsat 5*, foi lançado no dia 1 de março de 1984 e encerrou suas atividades em 22 de novembro de 2011 (BRASIL, 2013b).

Esse satélite possui o sensor *Thematic Mapper* (TM), com 7 bandas (Tabela 2) e possui uma resolução espacial de 30 metros em todas as bandas exceto a banda 6 de infravermelho termal que possui uma resolução espacial de 120 metros. Sua resolução temporal, ou seja o tempo que o satélite demora para voltar ao mesmo ponto é de 16 dias. A área imageada é de 185 quilômetros e sua resolução radiométrica é de 8 bits ou 256 níveis de cinza.

Tabela 2 - Bandas e Resoluções *Landsat 5*

Bandas espectrais	Resolução espectral	Resolução espacial
(B1) Azul	0.45 - 0.52 micrômetros	30 metros
(B2) Verde	0.52 - 0.60 micrômetros	
(B3) Vermelho	0.63 - 0.69 micrômetros	
(B4) Infravermelho próximo	0.76 - 0.90 micrômetros	
(B5) Infravermelho médio	1.55 - 1.75 micrômetros	
(B6) Infravermelho termal	10.4 - 12.5 micrômetros	120 metros
(B7) Infravermelho médio	2.08 - 2.35 micrômetros	30 metros

Fonte: (KEPLER, s.d.)

O último satélite da série *Landsat*, lançado em 11 de fevereiro de 2013, foi o *Landsat 8*, com o sensor *OLI* (*Operational Land Imager*) que é o sensor das bandas de 1 a 9. Além do sensor *OLI*, o *Landsat 8* possui o sensor *TIRS* (*Thermal Infrared Sensor*) que é um sensor destinado ao infravermelho termal, com resolução espacial de 100 metros e duas bandas: banda 10 LWIR-1 e a banda 11 LWIR-2 (BRASIL, 2013b). As bandas e resoluções do *Landsat 8* são divididas, conforme discriminado na Tabela 3.

Tabela 3 - Banda e Resoluções *LANDSAT 8*

Banda	Resolução espectral	Resolução espacial
(B1) Costal	0.433 até 0.453 micrômetros	30 metros
(B2) Azul	0.45 até 0.515 micrômetros	30 metros
(B3) Verde	0.525 até 0.6 micrômetros	30 metros
(B4) Vermelho	0.63 até 0.68 micrômetros	30 metros
(B5) Infravermelho próximo	0.845 até 0.885 micrômetros	30 metros
(B6) Infravermelho médio	1.56 até 1.166 micrômetros	30 metros
(B7) Infravermelho médio	2.1 até 2.3 micrômetros	30 metros
(B8) Pancromático	0.5 até 0.68 micrômetros	15 metros
(B9) Cirrus	1.36 até 1.39 micrômetros	30 metros
(B10) LWIR-1	10.30 até 11.30 micrômetros	100 metros
(B11) LWIR-2	11.5 até 12.5 micrômetros	100 metros

Fonte: (KEPLER, s.d.)

Neste trabalho, o *Landsat* não é utilizado pelo fato de já existirem muitos outros analisando essa plataforma e, também, porque as cenas do *Sentinel-2* se tornaram gratuitas a partir de 2016. Essa última plataforma é bastante promissora, devido a seus aspectos técnicos e, por ser recente, ainda não se têm muitas pesquisas sobre sua utilização no Brasil como objeto de estudo.

### 5.3.4 *Sentinel-2*

O programa “*Global Monitoring for Environment and Security*” (*GMES*), em português monitoramento global da segurança ambiental, é uma iniciativa conjunta da Comissão Europeia (CE) e da Agência Espacial Europeia “*European Space Agency*” (ESA), destinada a fornecer informações de monitoramento operacional para aplicações ambientais e de segurança.

O papel da *ESA* no *GMES* é desenvolver o sistema relacionado com o espaço e o solo. Os principais objetivos da missão *Sentinel-2* (Figura 32) são fornecer: aquisições de cenas multiespectrais de alta resolução com alta frequência de revisão; a próxima geração de produtos operacionais, tais como mapas de cobertura terrestre, mapas de detecção de mudança de solo e variáveis geofísicas. Conseqüentemente, o *Sentinel-2* contribuirá, diretamente, para os serviços de monitoramento do planeta (ESA, 2016a).

Figura 32 – Imagem ilustrativa do *Sentinel*

Fonte: (ESA, 2016a)

Os objetivos direcionaram o programa para um sistema multiespectral confiável, como o *Multispectral Instrument (MSI)*, sensor do *Sentinel-2* que possui treze bandas espectrais que vão desde o visível ao infravermelho de ondas curtas. A resolução espacial varia de 10 m a 60 m dependendo da faixa espectral e com uma variação do comprimento das ondas entre 490 a 1375 nanômetros como mostra a Figura 33.

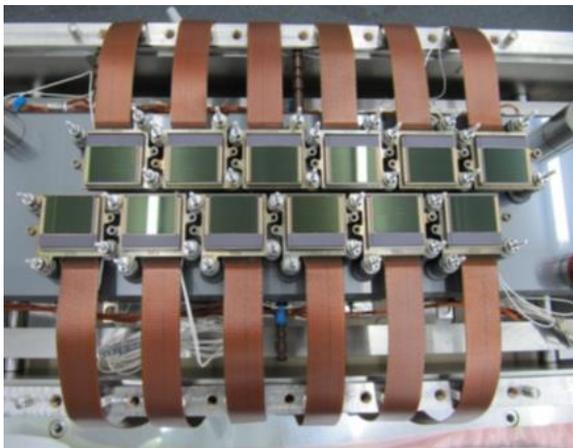
Figura 33 – Resoluções e bandas do *Sentinel-2*

Resolução	Nr da Banda	Nome da Banda	Comprimento de Onda Central (nanômetro)	Combinações de Bandas
10 m	B02	Blue (Azul)	490	Cor Verdadeira RGB 04/03/02 Falsa Cor 1 e 2 RGB 08/04/03 e 04/08/03
	B03	Green (Verde)	560	
	B04	Red (Vermelho)	665	
	B08	NIR (Infravermelho Próximo)	842	
20 m	B05	Red Edge 1	705	SWIR 1 RGB 12/11/8A
	B06	Red Edge 2	740	
	B07	Red Edge 3	783	
	B08A	Red Edge 4	865	
	B11	SWIR 1	1610	
	B12	SWIR 2	2190	
60 m	B01	Aerossol	443	-
	B09	Water Vapor	940	
	B10	Cirrus	1375	

Fonte: (ESA, 2016b)

O sensor do *Sentinel-2* possui um campo de visão de 290 km<sup>2</sup>. Para conseguir esse campo de visão, o *MSI*, que é um sensor *pushbroom*, é composto por doze detectores organizados em duas faixas horizontais, como mostra a Figura 34. Se os sensores fossem organizados em uma única linha (com os sensores lado a lado), a imagem apresentaria *gaps* (espaços) entre as linhas de *pixels*, pois os detectores precisam de espaço entre si, e mesmo o menor espaço entre os sensores causaria esse *gap*. Por esse fator, o conjunto de detectores é organizado em duas linhas, com parte do detector sobreposta com o detector inferior (ESA, 2016a).

Figura 34 – Sensor Multispectral Instrument (MSI) do *Sentinel-2*



Fonte: (ESA, 2016a)

Esta combinação de alta resolução espacial, amplo campo de visão representa um grande passo com referência às atuais missões multiespectrais. A missão prevê uma série de satélites, cada um com uma vida útil de 7,25 anos (prorrogáveis até 12 anos), durante um período de 20 anos, a partir do lançamento do *Sentinel-2A*, que foi em meados de 2014, e *Sentinel-2B*, lançado em março de 2017. Ambos possuem a mesma órbita de sincronismo solar com uma diferença de fase de 180°, proporcionando um tempo de revisão de cinco dias no Equador (ESA, 2016c).

A ESA disponibiliza “produtos” do *Sentinel-2* que são cenas desde sem correção nenhuma nas imagens até com “*Simulation of cloud corrections*” que significa a simulação da correção total das nuvens. Este trabalho utiliza o produto Nível 2A que fornece produtos com processamento *Bottom-Of-Atmosphere* (BOA) que é a refletância de superfície terrestre. Esse processamento é realizado a partir de produtos de Nível 1C que possui correção de topo de atmosfera - *Top Of Atmosphere* (TOA) *reflectance* -. O produto de Nível 1C não é operacionalmente produzido, mas pode ser gerado pelo usuário utilizando a caixa de

ferramentas do programa da *ESA* destinado ao processamento das imagens do *Sentinel-2* (ESA, 2016c).

O processamento do Nível 2A é dividido em duas partes. A primeira parte é a classificação da cena, tendo por objetivo proporcionar um mapa de classificação de *pixel* com onze classes como mostra a Figura 35. Após essa classificação, a cena passa por uma correção atmosférica que visa transformar de refletância de topo de atmosfera (TOA) em refletância de superfície terrestre (BOA), diminuindo as distorções da imagem (ESA, 2016c).

Figura 35 – Classificações de *pixels*

Label	Classification
0	NO_DATA
1	SATURATED_OR_DEFECTIVE
2	DARK_AREA_PIXELS
3	CLOUD_SHADOWS
4	VEGETATION
5	BARE_SOILS
6	WATER
7	CLOUD_LOW_PROBABILITY
8	CLOUD_MEDIUM_PROBABILITY
9	CLOUD_HIGH_PROBABILITY
10	THIN_CIRRUS
11	SNOW

Fonte: (ESA, 2016c)

O processo de transformação de refletância TOA para BOA consiste basicamente quando *pixels* defeituosos, não-existentes e saturados, são removidos das etapas de processamento Nível 2 A. Na Figura 36, é possível perceber a diferença de cena antes e após a correção atmosférica do Nível 2A (ESA, 2016c).

Figura 36 – Comparação de cenas com e sem correção atmosférica



Fonte: (MOTA, 2016)

#### 5.4 Discussão sobre o mapeamento do uso da terra

O mapeamento do uso e ocupação do solo vem se tornando cada vez mais essencial para o entendimento das dinâmicas de uso e ocupação do solo não só no Brasil como no resto do mundo, essas dinâmicas são causadas em sua grande maioria por ações antrópicas, sendo assim se torna necessário o acompanhamento regular que permita realizar análises de tendências com o intuito de fornecer informações para a tomada de decisão e gestão dos recursos naturais, pois a dinâmica de ocupação humana está em constante mudança principalmente no ambiente urbano (ALVES; CONCEIÇÃO, 2015).

As primeiras classificações do uso e ocupação do solo eram realizadas por meio de trabalhos de campo. Mas com a chegada das primeiras imagens multiespectrais orbitais na década de 1970, como por exemplo os primeiros satélites da série *Landsat*, o mapeamento do uso e ocupação do solo ganhou uma importante ferramenta como auxílio para a sua realização. A interpretação das imagens de satélite permite delimitar alvos que seguem um determinado padrão de distribuição permitindo assim, por exemplo, interpretar e classificar áreas de reflorestamento, de agricultura, solo exposto, vegetação natural, urbana, acompanhar geleiras e icebergs. Com isso, é possível elaborar análises estatísticas que permitem demonstrar os

percentuais de interferência antrópica. O Sensoriamento Remoto é a tecnologia que fornece grande parte dos dados para o estudo dos fenômenos espaciais (FITZ, 2008).

O mapeamento do uso da terra é uma técnica de sensoriamento remoto que consiste em classificar uma imagem para se ter uma resposta de como a dinâmica de uso e ocupação do solo funciona, muito utilizada no Brasil a várias décadas, segundo Andrade, Ribeiro, Lima (2015) as informações sobre as mudanças do uso e cobertura do solo são de grande importância para a análise e o entendimento em escala mundial e local, os processos que impactam o meio ambiente, de acordo com Nunes, Gioppo, (2015a) o uso das técnicas de geoprocessamento apoiadas com a utilização do sensoriamento remoto e nos sistemas de informação geográficas permitem aos pesquisadores realizarem pesquisas sobre mapeamento e uso e cobertura do solo.

Muitos métodos de classificação são utilizados para mapear o uso e cobertura do solo: como mapeamentos manuais em que a análise visual do usuário determina o mapeamento da área de estudo; métodos que utilizam classificadores automatizados, em que o processo de mapeamento é totalmente automatizado, muito rápido de ser realizado, mas apresenta erros de classificação; árvores de decisão em que são utilizados diversas regras estabelecidas pelo usuário para a utilização de métodos diferentes e a classificação da imagem ou regras simples de aplicar ou não algum filtro; métodos de classificação supervisionada em que o usuário define a quantidade de classes e suas amostras de treinamento a partir da imagem e o classificador realiza as classificações utilizando essas amostras como base; entre outros métodos.

## **5.5 Métodos de Classificação**

### **5.5.1 Teoria da Classificação Supervisionada**

Como o CAR utiliza a classificação de imagens de satélite para realizar o diagnóstico sobre o uso e a cobertura do solo e verificar o nível de desmatamento no imóvel rural, é importante discorrer sobre os métodos de classificação supervisionada utilizados neste trabalho, e abordar a literatura alusiva a cada um.

A classificação de imagens é um processo muito utilizado para o mapeamento do uso do solo. Por meio desse processo, é possível extrair informações de imagens e agrupar em classes ou temas. Essas classes podem ser associadas a diferentes formas de cobertura das terras, como florestas, pastagens, áreas urbanas, corpos d'água, culturas agrícolas, assentamentos, etc.

As classes utilizadas podem estar associadas a feições conhecidas ou áreas com características diferentes para o computador. Desta forma, o processo de classificação pode ocorrer de forma supervisionada ou não-supervisionada.

A classificação supervisionada é feita por um analista, na qual é fornecido ao programa um conjunto de amostras de treinamento para cada classe que deve ser diferenciada na imagem. As amostras de treinamentos são polígonos da imagem que melhor representam as classes escolhidas. Elas devem ser determinadas pelo analista que, por sua vez, deve possuir um conhecimento prévio das classes e da área de estudo (RICHARDS, 1986; NOVO, 1992). Segundo Noguchi (2004), para que a classificação seja bem sucedida é imprescindível uma boa seleção das amostras de treinamento. As amostras devem ser homogêneas e representativas de toda a variação possível dentro da classe. Além disso, o campo amostral deve ser grande o suficiente para que a estimativa das características espectrais da classe de interesse seja feita corretamente.

Caso a distância espectral entre duas amostras não seja significativa, o algoritmo de classificação pode não conseguir distinguir entre as classes que elas representam e ao final do processo ocorrerá muita confusão entre as classes. A medida estatística da distância espectral entre duas assinaturas é chamada de separabilidade (ERDAS, 1999). Quando ocorre má separabilidade deve-se considerar a possibilidade de rever as áreas de treinamento, eliminar bandas muito próximas ou fundir agrupamentos de assinaturas que representem uma única classe (QUARTAROLI; BATISTELLA, 2006). Para assegurar uma boa classificação pode-se, também, aplicar correções de efeitos atmosféricos e ruídos, quando os efeitos forem muito severos.

O processo de classificação não supervisionado não necessita de dados de treinamento e é feito automaticamente pelo algoritmo de classificação. Os *pixels* são analisados e separados em classes por meio de agrupamentos naturais existentes nos valores da imagem. A classificação é baseada no fato de que os valores correspondentes a certo tipo de imagem estão próximos, já os valores de classes diferentes estão comparativamente distantes (LILLESAND; KIEFER; CHIPMAN, 2004).

As características estatísticas das classes, estimadas nas amostras de treinamento, dependem dos métodos de classificação utilizados, que podem ser paramétricos ou não paramétricos.

Os *pixels* não são classificados, estatisticamente, pelos métodos não paramétricos. Se um *pixel* possui uma assinatura não paramétrica pertencente a uma determinada classe, o algoritmo simplesmente o agrupa para a classe adequada. As assinaturas não paramétricas são definidas

por polígonos restritos ao espaço de atributos da imagem fornecida na amostra de treinamento (QUARTAROLI; BATISTELLA, 2006). O único método não paramétrico utilizado nesse estudo é o *Feature Space*.

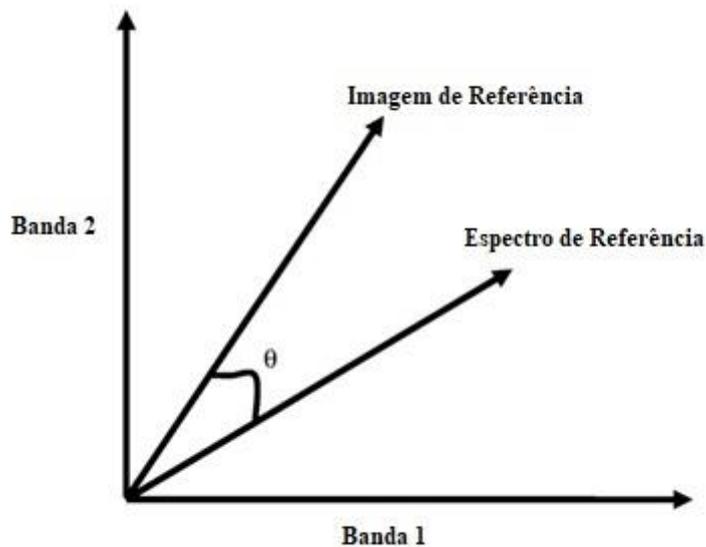
Os métodos paramétricos utilizam de parâmetros estatísticos como matriz de covariância e média para efetuar a classificação. Podem ser divididos em três categorias, conforme o parâmetro e a regra de decisão em que são fundamentados: na distância, na probabilidade ou no ângulo espectral. Os algoritmos classificadores que se baseiam na distância são os métodos *Minimum Distance* e *Mahalanobis Distance*. O método de Máxima Verossimilhança (Maxver) fundamenta-se na probabilidade, e utiliza tanto a média como a variância. Os métodos baseados nos ângulos espectrais são o *Spectral Angle Mapper* (SAM) e *Spectral Correlation Mapper* (SCM). (SOUTH; QI; LUSCH, 2004).

### 5.5.2 *Spectral Angle Mapper* (SAM)

O *Spectral Angle Mapper* (SAM) (KRUSE et al., 1993a) é um método de classificação supervisionada que considera semelhança entre dois espectros. O método calcula a diferença angular entre os espectros a partir da amostra de treinamento definida para cada classe de imagem, permitindo a atribuição de cada espectro da imagem para uma das classes, e utilizando todas as bandas da imagem para realizar a classificação.

A classificação dos *pixels* da imagem para uma das classes se baseia na medição do ângulo entre o espectro das amostras de treinamento e o espectro da imagem no espaço  $n$ -dimensional (Figura 37), onde  $n$  é o número de bandas. A utilização do método SAM gera uma imagem com um ângulo, para cada um dos espectros da amostra de treinamento. O resultado da comparação entre os ângulos da amostra de treinamento com os ângulos do restante da imagem é o valor da diferença angular. Quanto menor o valor da diferença angular de cada *pixel* maior é a semelhança entre a amostra de treinamento com o *pixel* da imagem. A classificação do *pixel* ocorre quando se chega ao menor valor da diferença angular entre todas as classes de treinamento (DE CARVALHO et al., 1999).

Figura 37 - Espaço  $n$ -dimensional



Fonte: (KRUSE et al., 1993)

O SAM, conforme observado em diversos artigos, mostra resultado com relevância para a área do sensoriamento remoto tais como: Yagoub et.al (YAGOUB; BELBACHIR; BENABADJI, 2014) em que é utilizado para identificar e mapear cobertura vegetal a partir de dados adquiridos pelo sensor *Advanced Very High Resolution Radiometer* (AVHRR), de 1 quilômetro de resolução espacial, com resultados satisfatórios segundo os autores. Em Castro *et al.* (2011), é empregado para mapear campos infestados por ervas daninhas, localizados em Córdoba e Sevilha, no sul da Espanha, com resultados baixos de acurácia. Em Renza *et al.* (2017), para mapear mudanças espectrais em uma comunidade em Madri, Espanha, com imagens do *Spot5* e *Quickbird*. No processamento são utilizados a análise do Índice de Vegetação pela Diferença Normalizada (NDVI) e o SAM em conjunto, sendo que, em suas conclusões, os autores salientam a necessidade de realizar estudos futuros para confirmar os resultados obtidos. Para mapear solos por meio de imagens hiperespectrais em Xiya e Peijun (2014), são utilizadas duas variações do SAM com o objetivo de analisar se os seus resultados são melhores dos que os do SAM convencional. Os resultados mostram que ambas as variações têm melhores resultados que os do SAM convencional.

A formulação matemática do SAM (KRUSE et al., 1993) é oriunda da equação:

$$SAM = \alpha = \cos^{-1} \frac{\sum_{i=1}^{i=nb} ER_i EI_i}{\sqrt{\sum_{i=1}^{i=nb} (EI_i)^2 \sum_{i=1}^{i=nb} (ER_i)^2}}$$

Onde,  $ER$  corresponde ao espectro de referência,  $EI$  ao espectro da imagem,  $nb$  ao número de bandas e  $\alpha$  ao ângulo formado entre o  $ER$  e  $EI$  (JUNIOR; SILVA, 2007).

O valor do SAM é expresso em radianos, sendo que quanto menor o valor de  $\alpha$ , maior é a similaridade entre as curvas. O ângulo  $\alpha$  é determinado pela função arco-cosseno e apresenta uma variação entre 0 e 90°. Portanto, os valores de cosseno (SAM) pode variar de 0 até 1 (JUNIOR; SILVA, 2007).

A desvantagem do método SAM é a incapacidade de detectar os falsos positivos gerado pelo coeficiente de correlação não normalizado pela média (JUNIOR; SILVA, 2007). Tendo isso em vista, foi desenvolvido uma variação do método SAM, o *Spectral Correlation Mapper* (SCM).

### 5.5.3 Spectral Correlation Mapper (SCM)

Carvalho & Menezes (2000) propôs o método *Spectral Correlation Mapper* (SCM) baseado no coeficiente de correlação de Pearson. Ao contrário do SAM, em que os valores de cosseno variam de 0 até 1, os valores da correlação de Pearson podem variar de -1 até 1 no método SCM. Portanto, uma das vantagens deste método é a capacidade de detecção da correlação negativa. Além disso, o método apresenta melhor ajuste na presença de assinaturas espectrais semelhantes (JUNIOR; SILVA, 2007).

Como o método SCM é uma variação do SAM e, portanto, é um método angular, ele também pode ser expresso na forma de ângulo. Para tanto, os valores negativos referentes à correlação de Pearson adquirem valores nulos. Em seguida, é aplicada a função arco-cosseno, gerando a seguinte formulação matemática:

$$SCM = \frac{\sum_{i=1}^{i=nb} (EI_i - \overline{EI})(ER_i - \overline{ER})}{\sqrt{\sum_{i=1}^{i=nb} (EI_i - \overline{EI})^2 \sum_{i=1}^{i=nb} (ER_i - \overline{ER})^2}}$$

Onde,  $ER$  corresponde ao espectro de referencia,  $EI$  ao espectro da imagem,  $nb$  ao número de bandas e  $\alpha$  ao ângulo formado entre o  $ER$  e  $EI$ .

A correlação com o espectro da imagem deve considerar não somente os membros finais como também os espectros provenientes da mistura entre assinaturas espectrais. De modo geral, os métodos de classificação espectral não conseguem discernir com exatidão as misturas entre classes, principalmente quando um elemento espectral ocorre em menor quantidade no *pixel*. Essa limitação pode gerar erros e, desta forma, o melhor modelo de mistura deve ser identificado nas amostras de treinamento (JUNIOR; SILVA, 2007).

No trabalho de (JUNIOR; SILVA, 2007), é desenvolvido um novo método chamado de SMCM, que permite um alto desempenho na diferenciação das misturas espectrais. O método proposto permite identificar o melhor conjunto de espectros, definindo mais precisamente os elementos e a sua proporção dentro de cada *pixel*.

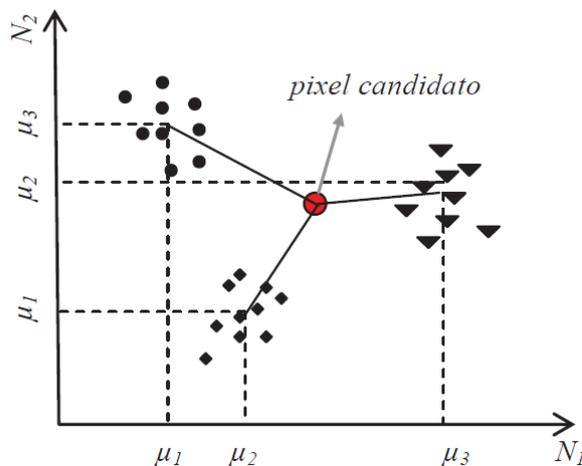
#### 5.5.4 *Minimum Distance*

O método *Minimum Distance* baseia-se nas distâncias espectrais entre o *pixel* analisado e o vetor médio para cada assinatura de classe fornecida no treinamento para realizar a classificação. O algoritmo utiliza da medida de similaridade de distância Euclidiana, que é obtida conforme a formulação matemática.

$$D(x, n) = \sqrt{(x_i - m_i)^2}$$

Onde  $x_i$  corresponde ao *pixel* analisado,  $m_i$  à média das classes e  $n$  o número de bandas (MENESES; ALMEIDA, 2012). O algoritmo, então, compara as distâncias obtidas de cada *pixel* à média das classes e agrupa o *pixel* analisado à classe mais próxima, como ilustrado na Figura 38.

Figura 38 - Medidas da distância mínima entre um *pixel* analisado e as classes, indicada pela linha cheia



Fonte: MENESES; ALMEIDA, 2012

A vantagem deste método é a velocidade com que os dados são processados e o fato de que durante a classificação supervisionada cada *pixel* é designado a uma classe em função da sua proximidade. Portanto, todos os *pixels* são classificados. Entretanto, esse fator também pode caracterizar uma desvantagem, uma vez que *pixels* que não devem ser classificados, por não estarem espectralmente próximos a nenhuma classe dentro do limite razoável, também são classificados. Além disso, o método não considera a variabilidade espacial de cada classe (MENESES; ALMEIDA, 2012), pois os *pixels* longe da média com uma grande variância podem pertencer a uma outra classe.

Segundo (RICHARDS, 1986), o método *Minimum Distance* considera as matrizes de covariância de todas as classes como diagonais e iguais, e pode, portanto, ser considerado um caso particular do método de Máxima Verossimilhança.

Segundo as pesquisas de Müller; Dalmolin; Araki (1999), o método *Minimum Distance* é o mais apropriado para reconhecimento de padrões de cores reais. Além disso, é o mais rápido na classificação entre os métodos estudados e oferece vantagens quando é necessário o reconhecimento de cores em tempo real.

### 5.5.5 Máxima Verossimilhança (Maxver)

O resultado do método Maxver é alcançado por meio da comparação do *pixel* em relação à média dos valores dentro dos limites da classe amostral. O método assume que a estatística das classes em cada banda espectral possui distribuição normal baseada nas amostras coletadas pelo analista (distribuição gaussiana) (RICHARDS; JIA, 1986).

O classificador calcula estatisticamente a probabilidade de cada *pixel* pertencer à determinada classe de treinamento e agrupa-o àquela que possui maior probabilidade.

Conforme Lillesand e Kiefer (1995), para efetuar o cálculo da probabilidade, inicialmente deve ser feita a média dos níveis de cinza de cada classe em cada banda, a variância e a correlação de cada classe de cobertura terrestre nos dados de treinamento. A partir destas informações, pode ser descrito o desvio dos *pixels* ao redor de cada vetor de média utilizando a função da probabilidade. A classificação é então realizada por meio da seguinte desigualdade (RICHARDS; JIA, 1986).

$$\mathbf{x} \in \omega_i, \quad \text{se} \quad p(\omega_i | \mathbf{x}) > p(\omega_j | \mathbf{x}) \quad \forall \quad j \neq i$$

Onde  $p(\omega_i | \mathbf{x})$  representa a probabilidade de o *pixel* analisado  $x$  pertencer à classe correta  $\omega_i$ . O *pixel* analisado  $x$  está classificado adequadamente se a desigualdade estiver correta. Ou seja, o valor de  $p(\omega_i | \mathbf{x})$  deve ser maior que o valor  $p(\omega_j | \mathbf{x})$  da amostra de treinamento. Caso os valores de probabilidade encontrados estejam abaixo do limite aceitável o *pixel* pode ser classificado como desconhecido (LILLESAND, 1995).

O método *Minimum Distance* pode ser considerado um caso particular do método de Máxima Verossimilhança, como descrito anteriormente, pois considera as matrizes de covariância de todas as classes como diagonais e iguais (RICHARDS, 1986). A diferença entre os dois métodos é que no método Maxver são utilizados os valores de média e covariância dos *pixels* amostrados, enquanto no método *Minimum Distance* é utilizado apenas o valor da média. Como resultado já é esperado desempenho superior do método Maxver (MENESES; ALMEIDA, 2012).

A alta acurácia do método deve-se ao fato de o cálculo incluir mais variáveis que os outros métodos paramétricos. Além disso, as classes de treinamento são utilizadas para localizar o centro de cada classe e estimar a geometria da distribuição dos *pixels* em cada classe no espaço de  $n$  bandas (MENESES; ALMEIDA, 2012). A desvantagem do método é a tendência de superclassificação, ou seja, relacionar um maior número de *pixels* às amostras com maiores valores relativos contidos na matriz de covariância.

O método Maxver é um dos mais utilizados para a classificação de dados multiespectrais, pois costuma obter bons resultados na discriminação em todo o espectro. Por esta razão, vários autores costumam comparar métodos antigos e novas técnicas com o método Maxver (BOLSTAD; LILLESAND, 1990).

Pereira et al., (2011) compara os métodos de classificação supervisionada Maxver e *Minimum Distance* na análise do uso e cobertura do solo na região do Alto Araguaia. Pereira et

al., (2011) utiliza duas cenas do satélite *Landsat TM 5* para o recobrimento da área de estudo. Foram selecionadas seis classes: florestas, cerrado, água, pastagens, agricultura e nuvem. Para a avaliação da acurácia dos classificadores foi utilizado o índice *Kappa*. Os resultados da classificação utilizando o método Maxver obtiveram valores do coeficiente *Kappa* 0,9549 e 0,9639. Para o método *Minimum Distance* o coeficiente *Kappa* foi de 0,9310 e 0,9681.

Os dois métodos obtiveram índices *Kappa* excelentes, onde os mapas temáticos gerados podem ser considerados confiáveis pelo usuário. Entretanto, os melhores resultados ainda estão relacionados com as imagens do satélite quando utilizado o método Maxver.

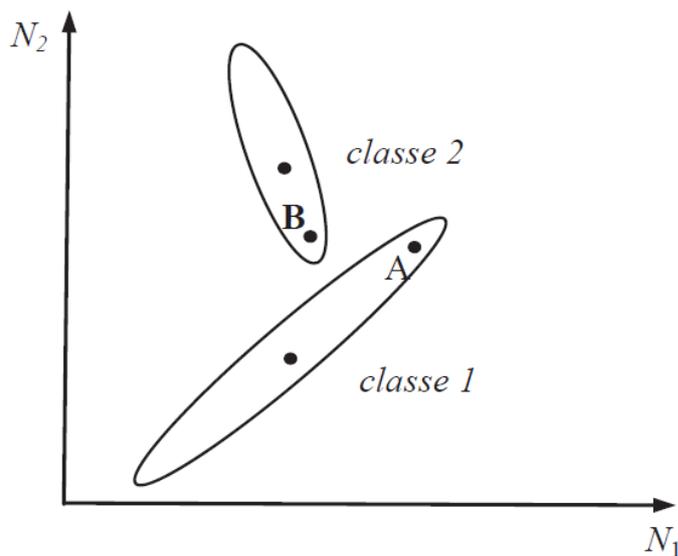
Segundo Cohenca & Carvalho (2015), as diferenças entre os métodos em respeito ao seu desempenho para classes específicas devem ser consideradas, mesmo que a análise de exatidão com base nos coeficientes globais seja um bom indicador da adequação de métodos específicos a determinados objetivos da classificação.

### 5.5.6 Mahalanobis Distance

O *Mahalanobis Distance* é um classificador de distância por meio da direção e utilizando estatística para cada classe. Assemelha-se ao método Maxver, no entanto assume que todas as classes possuam covariâncias iguais e caracteriza-se por ser um classificador mais rápido do que o de Máxima Verossimilhança (MENESES; ALMEIDA, 2012).

O *Mahalanobis Distance* mede a distância entre o *pixel* analisado na posição  $x$  do espaço e o centro da classe, dividida pelo comprimento do elipsóide na direção de  $x$ . A Figura 39 ilustra as distribuições de probabilidades representadas pelas elipses. Ao fazer o cálculo desta forma, a distância do *pixel* analisado ao centro de média é minimizada.

Figura 39 - Elipses de distribuição de probabilidade em um espaço bidimensional



Fonte: MENESES; ALMEIDA, 2012

O ponto estará mais próximo ao centro em que o elipsóide tem um eixo menor, e mais distante do centro em que o eixo for maior. O elipsóide utilizado como referência, e que melhor representa a distribuição de probabilidade da classe, é estimado pela matriz de covariância das amostras de treinamento (MENESES; ALMEIDA, 2012).

Para realizar a classificação, inicialmente deve-se calcular a matriz de covariância baseada nos dados das amostras de treinamento. O *Mahalanobis Distance* é então calculado para o *pixel* a ser analisado conforme a formulação matemática.

$$DM = (\vec{X} - \vec{M})^T (V)^{-1} (\vec{X} - \vec{M})$$

Onde  $X$  corresponde ao vetor de características,  $M$  ao vetor de médias e  $V$  à matriz de variância – covariância. O *pixel* será destinado à classe à qual a distância seja a menor de todas e esteja ao longo do eixo da classe com maior variabilidade.

Os *Mahalanobis Distance* obtidos das amostras de treinamento definem um espaço multidimensional cujos limites determinam o intervalo de variação aceitável para que o *pixel* seja agrupado àquela classe. Quando um *pixel* distancia-se significativamente da classe, pode haver contaminação da homogeneidade das classes de treinamento, ocasionando prováveis erros nos cálculos da matriz de covariância e da média. Nesses casos, é possível fazer regressões para determinar se um *pixel* é atípico ou não no espaço multivariado (MENESES; ALMEIDA, 2012).

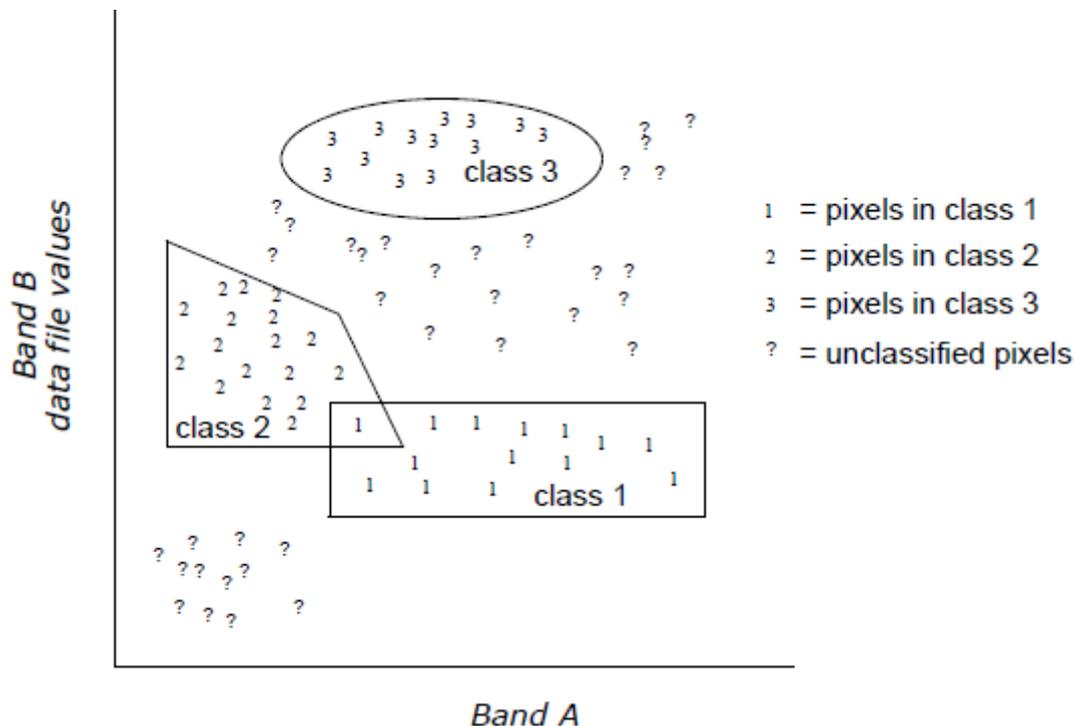
Cattani et al. (2013) testou os classificadores Mínima Distância, *Mahalanobis Distance*, Maxver e SAM, para a classificação supervisionada de imagens dos satélites *RapidEye*. Os métodos apresentaram variações significativas quanto aos desempenhos no mapeamento de uso e ocupação do solo. O classificador Maxver apresentou excelente resultado atestado pelos índices de Exatidão Global, Índice *Kappa* e Índice Tau. O classificador pelo *Mahalanobis Distance* obteve o segundo melhor resultado.

### 5.5.7 Feature Space

O *Feature Space*, ou espaço de atributos, corresponde a um gráfico com as frequências de distribuição de intensidades das bandas de uma imagem multiespectral (Crósta 1989).

A regra de decisão do método *Feature Space* baseia-se nas assinaturas não paramétricas das classes, que estão contidas em áreas definidas dentro de um *Feature Space Image*. Quando a assinatura espectral de um *pixel* estiver dentro da área delimitada, o *pixel* é classificado à classe correspondente àquele *Feature Space* (Figura 40).

Figura 40 - Polígonos utilizados para definir as classes



Fonte: ERDAS

Como ilustrado pela Figura 40, as desvantagens são que o método *Feature Space* permite a sobreposição de classes e a existência de *pixels* não classificados. Os *pixels* não classificados podem ser agrupados às classes por métodos paramétricos. Caso não possa ser classificado por nenhum método paramétrico, o *pixel* permanecerá não classificado. Nos casos em que as classes se sobrepuserem, o analista deve decidir se o *pixel* será classificado por ordem de assinatura no *Feature Space*, por métodos paramétricos, ou se permanecerá como não classificado (ERDAS, s.d).

Além da velocidade de processamento, a vantagem do método é a facilidade com que alguns atributos são identificados visualmente. O método pode ser utilizado como ferramenta auxiliar para os métodos paramétricos ao diferenciar classes espectralmente semelhantes (ERDAS, s.d).

## **5.6 Métodos de validação**

### **5.6.1 Matriz de Confusão**

A matriz de confusão, ou matriz de erro, é assim chamada por facilitar a visualização dos erros de classificação do sistema. É um método quantitativo para caracterizar a acurácia e é comumente utilizada para validar os resultados das classificações com base em um dado de referência.

A matriz de erro apresenta a relação entre dois conjuntos de dados, geralmente um mapa classificado e um mapa de referência (Figura 41).

Figura 41: Mapa 1) *Raster grid* de imagem classificada em 5 categorias. Mapa 2) *Raster grid* de imagem referência com 5 categorias.



Fonte: SPIEGEL, 1993

A partir dos dados obtidos pela comparação entre as duas imagens é gerada uma tabela binomial (Figura 42) que apresenta de forma resumida os resultados da classificação. Cada frequência observada corresponderá também a uma frequência esperada, que é calculada de acordo com as regras da probabilidade (SPIEGEL, 1993).

Figura 42 - Tabela de frequências comparadas entre a imagem de referência e a imagem classificada

		Reference image			Total
		A	B	C	
Classified image	a	37	3	7	$\Sigma a = 47$
	b	9	25	5	$\Sigma b = 39$
	c	11	2	43	$\Sigma c = 56$
Total		$\Sigma A = 57$	$\Sigma B = 30$	$\Sigma C = 55$	$N = 142$

Fonte: LABBASSI et al., 2012

A frequência observada na diagonal principal (destacada em azul) apresenta a concordância entre o esperado e o observado em cada classe (*accuracy*), e corresponde à quantidade de *pixels* corretamente classificados. Ao dividir o somatório de *pixels* corretos pela quantidade total de *pixels*, obtém-se o valor da acurácia (*overall accuracy – OvAc*). O cálculo é representado pela seguinte formulação matemática (LABBASSI et al., 2012).

$$OvAc = ( aA + bB + cC ) / N$$

Para realizar a validação do resultado, a ferramenta da matriz de confusão utiliza o coeficiente *Kappa* como índice de avaliação.

### 5.6.2 Índice *Kappa*

O índice *Kappa* mede o grau de concordância do resultado obtido pela matriz de confusão. Ao contrário do método de exatidão global, o coeficiente *Kappa* agrupa as informações de todos os *pixels*, e não só dos *pixels* com as melhores classificações (CONGALTON; GREEN, 1999).

Conforme Congalton; Green, (1999), o coeficiente *Kappa* mede o grau de concordância em escalas nominais, sendo que as classes da escala nominal são independentes e mutuamente exclusivas e o classificador e os pontos de referência operam de forma independente.

Os coeficientes de concordância podem ser expressos como concordância total ou para classes individuais. A concordância para a avaliação da acurácia total pode ser obtida pela formulação matemática:

$$\kappa = \frac{P_o - P_e}{1 - P_e}$$

O coeficiente para as classes individuais é calculado pelo mesmo princípio que a acurácia total, sendo descrito pela formulação matemática:

$$\kappa_i = \frac{N X_{ii} - X_{i+} X_{+i}}{N X_{i+} - X_{i+} X_{+i}}$$

Onde  $P_o$  corresponde ao total de *pixels* classificados corretamente e  $P_e$  à proporção de elementos atribuídos à determinada classe.  $P_o$  pode ser descrito como a razão do somatório da diagonal principal ( $\sum X_{ii}$ ) pelo número total de observações ( $N$ ). E  $P_e$  pode ser expresso pelo somatório do produto dos elementos das linhas e colunas marginais ( $\sum X_{i+} X_{+i}$ ) pelo número total de observações ao quadrado (CONGALTON; GREEN, 1999).

Os valores de *Kappa* variam entre 0 e 1. Onde 0 significa que não há concordância entre a imagem classificada e a imagem de referência, e 1 significa que as imagens são totalmente idênticas. Portanto, quanto maior o coeficiente *Kappa* melhor a acurácia da classificação. Segundo (LANDIS; KOCH, 1977), os níveis de relevância para o índice *Kappa* variam conforme disposto na Tabela 4.

Tabela 4 - Índice de Relevância *Kappa*

Estatística <i>Kappa</i>	Relevância do <i>Kappa</i>
<0.00	Nulo
0.00 – 0.2	Ruim
0.21 – 0.4	Fraco
0.41 – 0.6	Moderado
0.61 – 0.8	Substancial
0.81 – 1.00	Quase perfeito

Fonte: (LANDIS; KOCH, 1977)

### 5.6.3 Accuracy Assessment

O *Accuracy Assessment* ou índice de acurácia compara a imagem classificada com outra imagem considerada como referência ou verdade de campo. A verdade de campo também pode ser obtida por meio de interpretações de imagens de alta resolução, dados de Processamento Digital de Imagem (PDI) ou imagens previamente classificadas (ESRI, 2016).

A melhor forma para avaliar a acurácia de um mapa classificado é criar um conjunto de pontos da verdade de campo e comparar com os dados classificados em uma matriz de confusão (ESRI, 2016).

### 5.6.4 Image Difference

O método *Image Difference* é utilizado para analisar as alterações em uma área devido a um intervalo temporal entre as imagens. Devido às diferenças espectrais é possível destacar áreas específicas que foram modificadas ao longo do tempo. A partir da comparação são geradas duas imagens (ESRI, 2016).

A primeira é chamada de Imagem Diferença, e representa o resultado direto da subtração da imagem mais recente pela imagem mais antiga. O resultado é uma imagem contínua em escala de cinza, composta por dados de uma única banda. Esta ferramenta calcula a mudança nos valores de brilho ao longo do tempo e reflete a alteração utilizando a escala de cinza. As

áreas mais brilhantes aumentaram em reflectância com o passar do tempo, e pode significar, por exemplo, o desmatamento de áreas florestadas. As áreas escuras diminuíram na reflectância, que pode indicar aumento da área vegetada. Ou então, a mudança de uma área seca para uma área úmida (ESRI, 2016).

A segunda imagem é chamada de *Highlight Difference*. Representa uma imagem temática composta por cinco classes: *Decreased*, *Some Decrease*, *Unchanged*, *Some Increase*, e *Increased*. A classe *Decreased* é caracterizada pela coloração vermelha e representa áreas de mudança negativa (mais escura). A classe *Increased* possui coloração esverdeada e mostra áreas de mudança positiva (mais brilhante). Outras áreas de mudanças positivas e negativas menores do que os limiares de mudança apresentam coloração transparente, juntamente com as áreas *Unchanged*, que não apresentaram diferença entre as imagens (ESRI, 2016).

## 6. MATERIAIS E MÉTODOS

### 6.1 Satélites

#### 6.1.1 *Sentinel-2*

O *Sentinel-2* foi escolhido como um dos materiais a ser utilizado neste trabalho, pois, como, a partir de 2016, suas imagens se tornaram gratuitas, ele se tornou o satélite gratuito com maior resolução espacial, característica, essa, que se soma às suas 13 bandas e à sua capacidade de imagear uma área extensa em um único processo. O que o torna muito promissor para o tipo de análise feita neste trabalho - apesar de ter uma resolução espacial inferior ao *Rapideye*, cerca de 4 vezes menor - é o fato de suas cenas não serem composições de mosaicos como as cenas do *Rapideye*, adquiridas pelo governo federal, mas disponibilizadas de forma gratuita.

Além disso, o sistema *pushbroom* de imageamento do *Sentinel-2* e sua área imageada *nadiral* garantem a esse satélite um grande diferencial, pois suas imagens possuem menos erros de distorção óptica do que sistemas tradicionais, como o *Landsat 5 TM* ou, até mesmo, o *Rapideye* que, para diminuir o tempo de revisita, se utiliza de um imageamento *off nadir*, o que acaba acarretando distorções ópticas (ESA, 2016a).

Como as imagens utilizadas neste estudo são um dos produtos do *Sentinel-2*, elas já passaram por um processo de correção, o que elimina a maior parte do ruído atmosférico incluindo a remoção de nuvens pequenas, e principalmente o cirrus (nuvens formadas por partículas de gelo em altas altitudes, com a aparência semelhante a um véu) (ESA, 2016a).

### 6.2 Mosaico

O processo de criação do mosaico a partir do *Sentinel-2* utiliza o recorte no qual suas cenas são disponibilizadas, doze partes de 100km<sup>2</sup> (Figura 44). Como a área de estudo utiliza dois pontos orbitais, as cenas contêm 24 partes. O estudo utiliza as bandas de 10 m de resolução espacial que são as bandas do azul, verde, vermelho e infravermelho próximo, do produto de Nível 2A do *Sentinel-2*, que, conforme explicado anteriormente, é um produto com correção atmosférica.

Para realizar o mosaico e evitar um maior número de erros de número digital e distorção espacial, foram criados, primeiramente, mosaicos verticais no sentido norte a sul e com o

resultado foram feitos os mosaicos de sentido leste a oeste de maneira crescente - os dois mosaicos mais ao leste, o resultado desse com o vizinho a oeste e, assim, sucessivamente.

Figura 44 - Distribuição das imagens do *Sentinel-2*



Fonte: do Autor

## 6.3 Classificações

### 6.3.1 Classes

Para realizar a classificação do mosaico do *Sentinel-2*, foram utilizados os métodos de classificação supervisionada paramétricos, disponíveis no *software Erdas*, SAM, *Maxver*, *Minimum Distance*, SCM, *Mahalanobis Distance* e o método não paramétrico *Feature Space*. Há, também a opção do método não paramétrico *Parallelepiped*, mas que não foi utilizado neste trabalho.

Segundo Crósta (1992), para obter um bom resultado com um método de classificação supervisionada, é necessário ter várias classes para não haver mistura entre elas e não gerar erros de classificação. Além disso, é preciso ter um número razoavelmente elevado de *pixels* nas amostras de treinamento em cada classe. Assim, com o objetivo de melhorar a classificação, foram feitas 137 classes discriminando em áreas de vegetação, solo exposto, pastagens e áreas urbanas. O total de *pixels* utilizados nas áreas de treinamento para todas as classes foi de mais

de 6 milhões de *pixels*. Como o objetivo da criação das 137 classes foi evitar confusão espectral, cada classe possui apenas uma área de treinamento, ou seja, apenas uma área de interesse, pois se houvesse mais de uma área de treinamento esse fator poderia adicionar erros às classificações.

Devido à resolução espacial do *Sentinel-2* e ao tamanho da área classificada, que contém 1,682 bilhões de *pixels*, os 6 milhões de *pixels* utilizados como amostra de treinamento representam menos que 1% da área de estudo. Mesmo assim, a amostra é representativa para classificação.

Como o CAR tem por objetivo o diagnóstico e controle do desmatamento, ele utiliza em suas análises apenas as classes remanescentes de vegetação e áreas de uso alternativo do solo - tratadas como áreas antropizadas neste trabalho – assim, optou-se por aglutinar os resultados das 137 classificações, em apenas essas duas classes.

Cada uma das classes teve sua área de treinamento coletada pela ferramenta do *software Envi*, chamadas de Regiões de Interesse (ROI). Para possibilitar as classificações, esse arquivo é convertido para arquivo *.sig* no *software Erdas*, para ser utilizado como área de treinamento pelos métodos de classificação. Após a conversão das classes de treinamento, foram realizadas as classificações no *Erdas* utilizando a ferramenta *Supervised Classification*, em que são selecionadas a imagem raiz, a imagem classificada e a entrada das áreas de treinamento. Cada um dos seis métodos utilizou as mesmas áreas de treinamento, eliminando, assim, possíveis disparidades causadas por diferenças na quantidade de *pixels* amostrais.

Nos métodos não paramétricos, o usuário pode optar por duas regras: a de sobreposição e a de *pixels* não classificados. A regra de sobreposição possui três modos de análise: a utilização de alguns dos métodos paramétricos; a classificação por ordem; e a não classificação. Para este trabalho, foi escolhido a não classificação. Os dois outros de análise da regra de sobreposição não foram utilizados para não aumentar as variáveis da equação.

Os *pixels* não classificados dos métodos não paramétricos podem ser reclassificados, conforme alguma regra paramétrica, ou, então, podem permanecer sem ser classificados. Como esse estudo compara métodos de classificação, a utilização de um método paramétrico, neste caso, poderia adicionar um resultado que não representasse o método em análise, prejudicando os dados finais. Assim, foi escolhida a segunda opção em que os *pixels* permanecem sem classificação.

A única opção de análise complementar para os métodos paramétricos é a classificação de *pixels* com valor de número digital igual a zero, à exceção do Maxver que também pode utilizar a opção das probabilidades da assinatura espectral das classes de treinamento.

Após realizar o processamento dos métodos de classificação supervisionada, as 137 amostras de treinamento foram agrupadas nas duas classes utilizadas nesse trabalho (vegetação, áreas antropizadas). A seguir, as áreas dos vinte assentamentos em cada uma das seis classificações foram extraídas no *Erdas*, para se processar as matrizes de confusão em cada método. O processamento de cada matriz de confusão teve 500 pontos distribuídos aleatoriamente, sendo que esse total foi dividido igualmente entre as duas classes, significando 250 pontos aleatórios para cada uma. Com as matrizes de confusão feitas, foi calculado o Índice de Acurácia e o Índice Kappa.

E para a comparação das classificações, foi utilizada a ferramenta do *Erdas Image Difference*. Como cada área de estudo possui seis classificações, foram feitas catorze comparações. Com o resultado das comparações foram contabilizados os *pixels* classificados de maneira diferente entre os métodos. Com esses números foi feito o cálculo para se obter a porcentagem de alteração pela área total da classificação, e gerar os gráficos.

## **6.4 Métodos de validação**

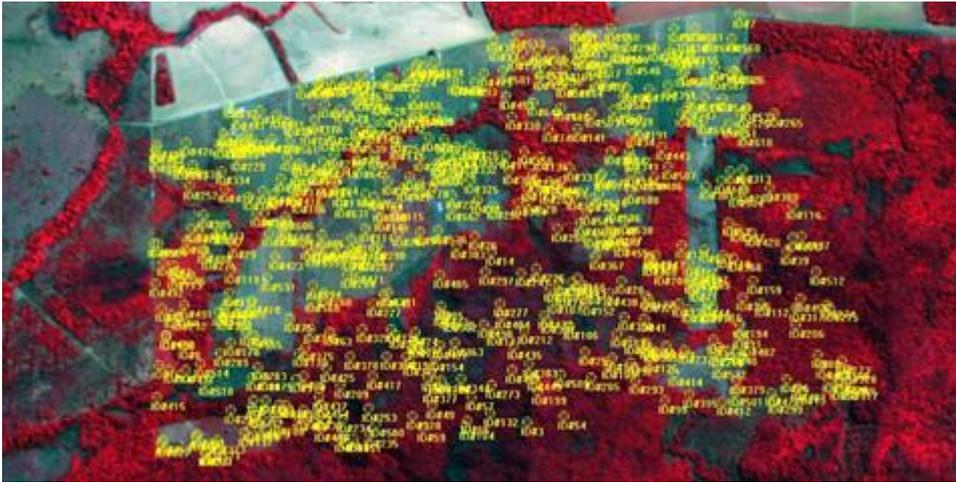
### **6.4.1 Matriz de confusão**

Para a obtenção do índice de acurácia e índice *Kappa* foi utilizada, no *software Erdas*, a ferramenta *Accuracy Assessment* que realiza a matriz de confusão, por meio da criação de pontos aleatórios na imagem base (imagem sem a classificação), utilizando como referência os limites da classificação e suas classes (Figura 45). Esses pontos são classificados pelo usuário de maneira que o mesmo não saiba a qual classe o ponto pertence. A(s) única(s) referência(s) para a classificação dos pontos é a imagem-base sozinha, ou como utilizado nesse trabalho, com o auxílio de um *shape* de verdade de campo, que no caso deste estudo, foi validado *in loco*.

Após a classificação dos pontos, a ferramenta emitiu o resultado da matriz de confusão com o número de pontos classificados certos de cada classe, os índices de acurácia de cada classe, do programa e do usuário, e o índice *Kappa* geral e por classe. No caso deste trabalho cada uma das classificações de cada área de estudo teve 500 pontos aleatórios distribuídos de maneira igual entre as duas classes (vegetação e área antropizada). 500 pontos representa um valor entre 0,2% até 1% dependendo do tamanho de cada uma das 20 áreas de estudo. Como foram utilizados seis métodos de classificação supervisionada em cada assentamento, isso totalizou 60 mil pontos de referência em todo o estudo.

Como o índices de acurácia é mostrado em porcentagem e o índice *Kappa* em valores que vão de 0 até 1, para padronizar os valores de ambos e facilitar a compreensão das análises, os valores do índice *Kappa* foram convertidos em porcentagem considerando 1 como sendo 100%, ou seja um resultado *Kappa* de 0,8765 ficou equivalente a 87,65%.

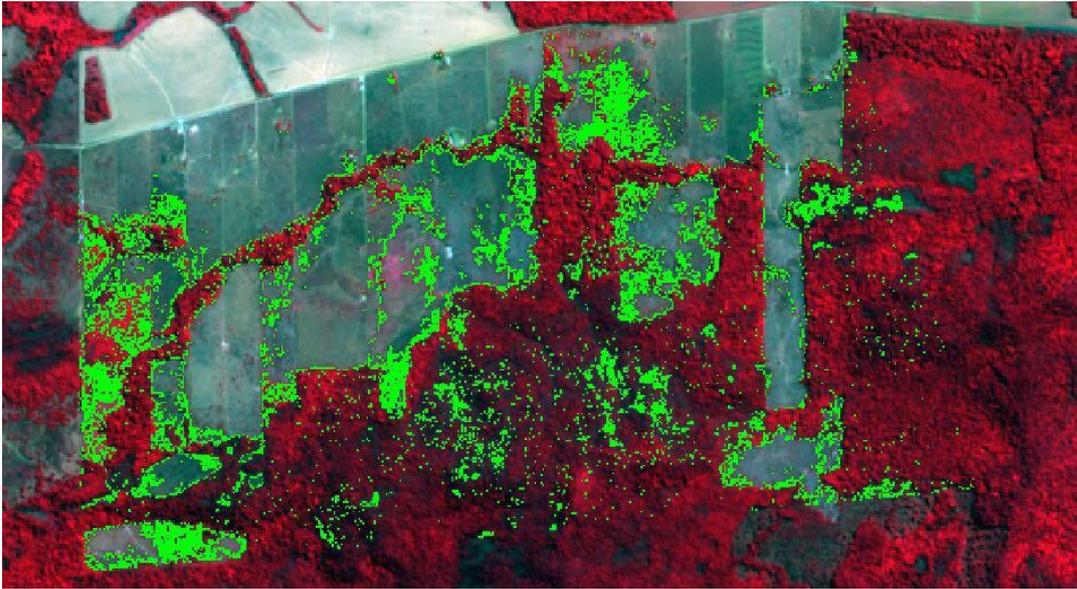
Figura 45 – Pontos da Matriz de Confusão



Fonte: do Autor

#### 6.4.2 *Image Difference*

Outro método utilizado para comparar os resultados das classificações, no *software Erdas*, foi o *Image Difference* (diferença de imagens) que compara duas imagens do mesmo local e destaca quais *pixels* estão diferentes na comparação, mas consegue apenas comparar duas imagens por vez. Devido a esse fator, para que todas as classificações pudessem ser comparadas entre si, foram realizadas catorze análises utilizando este método em cada área de estudo, totalizando 280 análises. Como resultado dessa análise, foi criada uma imagem com apenas os *pixels* que sofreram alteração (Figura 46). Para que se pudesse realizar uma análise mais precisa do que apenas uma análise visual do resultado, extraiu-se o número de *pixels* alterados de cada análise por meio do histograma e a porcentagem de diferença entre cada um dos métodos, utilizando como o total de *pixels* a contagem de *pixels* em cada área de estudo.

Figura 46 – Resultados do *Image Difference*

Fonte: do Autor

## 6.5 Área de estudo

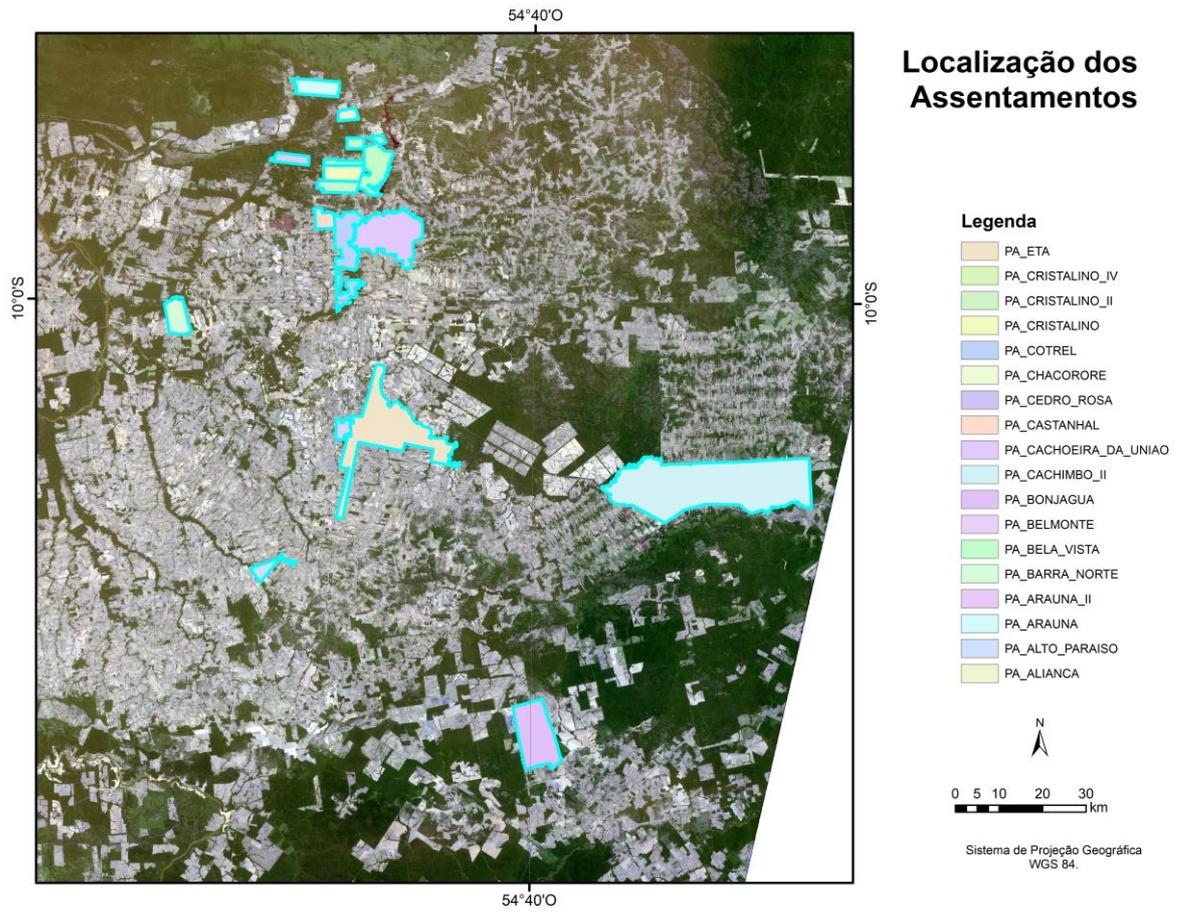
A área de estudo contém dois pontos orbitais inteiros do *Sentinel-2*, com 290 km no sentido de leste a oeste e 580 km no sentido de norte a sul, totalizando uma área de 168.200 km<sup>2</sup> (Figura 43), reunindo vinte assentamentos da Reforma Agrária, em sete municípios do norte do estado do Mato Grosso (Quadro 1).

Quadro 1 - Lista de assentamentos por municípios

Municípios	Assentamentos	Municípios	Assentamentos
Novo Mundo	PA Aliança	Peixoto de Azevedo	PA Belmonte
	PA Araúna		PA Cachimbo II
	PA Araúna II		PA ETA
	PA Barra Norte	Terra Nova do Norte	PA Alto Paraíso
	PA Bela Vista	Marcelândia	PA Boniaguar
	PA Castanhal	Nova Maringá	PA Chacorore
	PA Cotrel	Guarantã do Norte	PA Cachoeira da União
	PA Cristalino		PA Horizonte II
	PA Cristalino II		PA Iririzinho
	PA Cristalino IV	Nova Ubitatã	PA Cedro Rosa

Fonte: do Autor

Figura 43 – Localização em Mato Grosso do mosaico das duas cenas do *Sentinel-2*



Fonte: European Space Agency – ESA

## 7. RESULTADOS

A partir dos resultados dos seis métodos de classificação supervisionada nos vinte assentamentos, para realizar uma análise mais precisa dos mesmos, foram calculados a avaliação de acurácia e o Índice *Kappa*, por meio da matriz de confusão.

Ao se analisar os pontos das matrizes de confusão que apresentam discordância entre o que foi classificado e a verdade de campo, percebeu-se que os erros de classificação estavam concentrados nas bordas da classe de vegetação e das áreas antropizadas, ou seja, áreas em que as classes apresentam maior mistura. O método *Image Difference* também confirmou esse resultado ao apontar que as diferenças de classificação entre os métodos estão localizadas nas bordas das classes.

Esse tipo de erro na classificação era esperado, pois como há uma mistura entre as classes nos *pixels* das bordas entre a vegetação e as áreas antropizadas, a classe de vegetação se sobressai, por ter uma resposta maior na banda do infravermelho próximo, o que tende a levar os métodos a classificar para classe de vegetação, apesar de a maior parte da área do *pixel* não corresponder à vegetação. Diante desses aspectos, os seis métodos classificaram esses *pixels* de borda, em sua maioria, como pertencentes à classe de vegetação, porém em alguns dos assentamentos essa tendência de erro apresenta uma dinâmica menos acentuada e a maior concentração de erro está na classe de área antropizada.

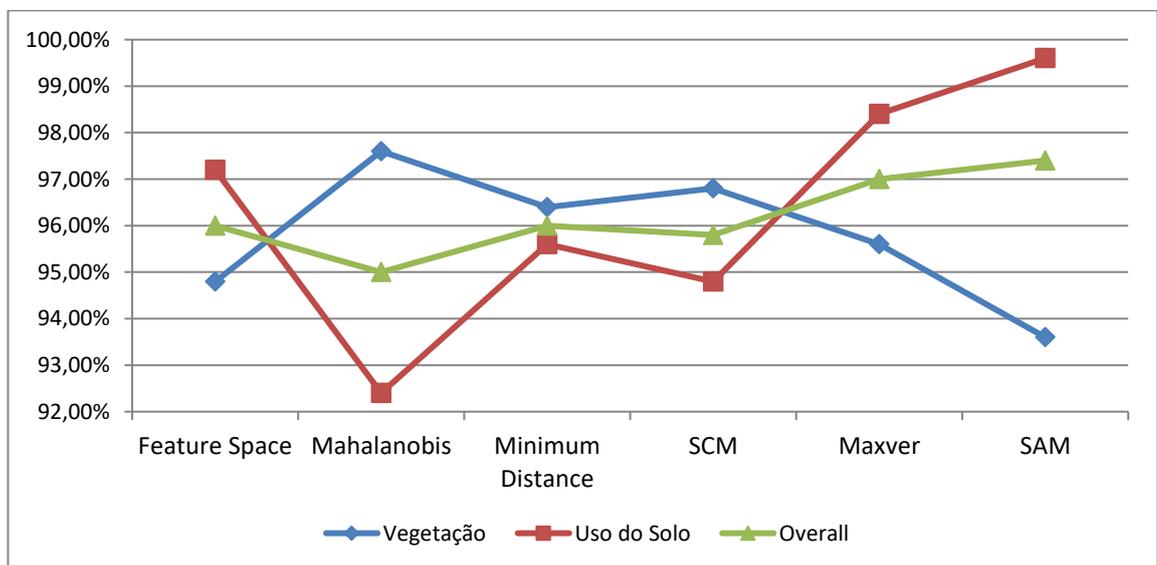
Devido ao grande número de análises, não seria possível compará-las pelo conjunto. Assim, optou-se por analisar as classificações por assentamento. Foram apresentados gráficos com os índices *Kappa* e *Accuracy Assessment*, e com os resultados do *Image Difference*. No caso dos dois primeiros, quanto maior for o valor encontrado mais precisa é a classificação. No caso do Gráfico *Image Difference*, quanto maior o valor apurado, maior é a diferença entre as classificações.

Para cada assentamento, foram formulados três tipos de gráficos. O primeiro é o de *Accuracy Assessment* em que são demonstrados os valores da acurácia da vegetação, do solo exposto e os valores gerais da acurácia, denominados como *overall*. O segundo gráfico expressa os valores do Índice *Kappa*, com três categorias: *Kappa* (valores gerais do Índice *Kappa*), vegetação (Índice *Kappa* da vegetação), solo (Índice *Kappa* da vegetação). O terceiro gráfico, *Image Difference*, compara os resultados entre os métodos de classificação. A porcentagem é calculada a partir do total de *pixels* do assentamento e do total de *pixels* de alteração entre os métodos,

## PA ALIANÇA

O PA Aliança demonstrou uma acurácia significativa ultrapassando os 95% de exatidão em termos gerais (Gráfico 1). O melhor resultado foi o do método de classificação SAM com 97,2%, mas suas classes variaram de maneira expressiva. O uso do solo atingiu quase 100%, enquanto a vegetação chegou próximo dos 94% no nível de acurácia. Considerando uma tendência de uma diferença mínima entre os resultados, o método *Minimum Distance* apresentou a menor variação nos resultados, além disso apresentou um índice de acurácia geral de 96%, com apenas 1,2% abaixo do melhor resultado, outro método que se saiu bem, por essa lógica, foi o SCM com uma diferença de 2% entre as classes e um resultado geral de cerca de 0,1% de diferença. O menor resultado da acurácia foi no método *Mahalanobis* que teve um resultado geral de 95%. O fator que causou esse resultado foi o uso do solo, que foi a classe com menor resultado dentre todos os métodos, com um índice de 92% de acurácia. Esse valor apesar de menor que os demais, não deixa de ser relevante.

Gráfico 1- *Accuracy Assessment* – PA Aliança

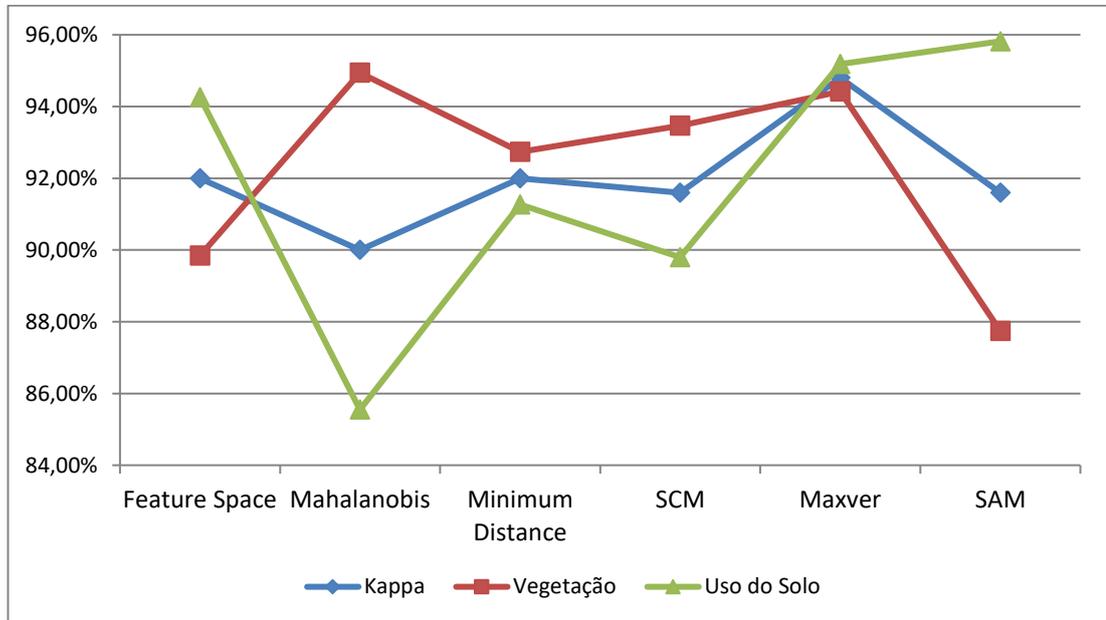


Fonte: do Autor

Já os resultados do Índice *Kappa* do PA Aliança (Gráfico 2) apresentaram uma dinâmica um pouco diferente que os níveis de acurácia. Nesse caso, o melhor desempenho foi o do Maxver apresentando um resultado de 95% com pouquíssima variação entre as classes. Os métodos de *Minimum Distance* e SCM seguiram os mesmos padrões do que no nível de

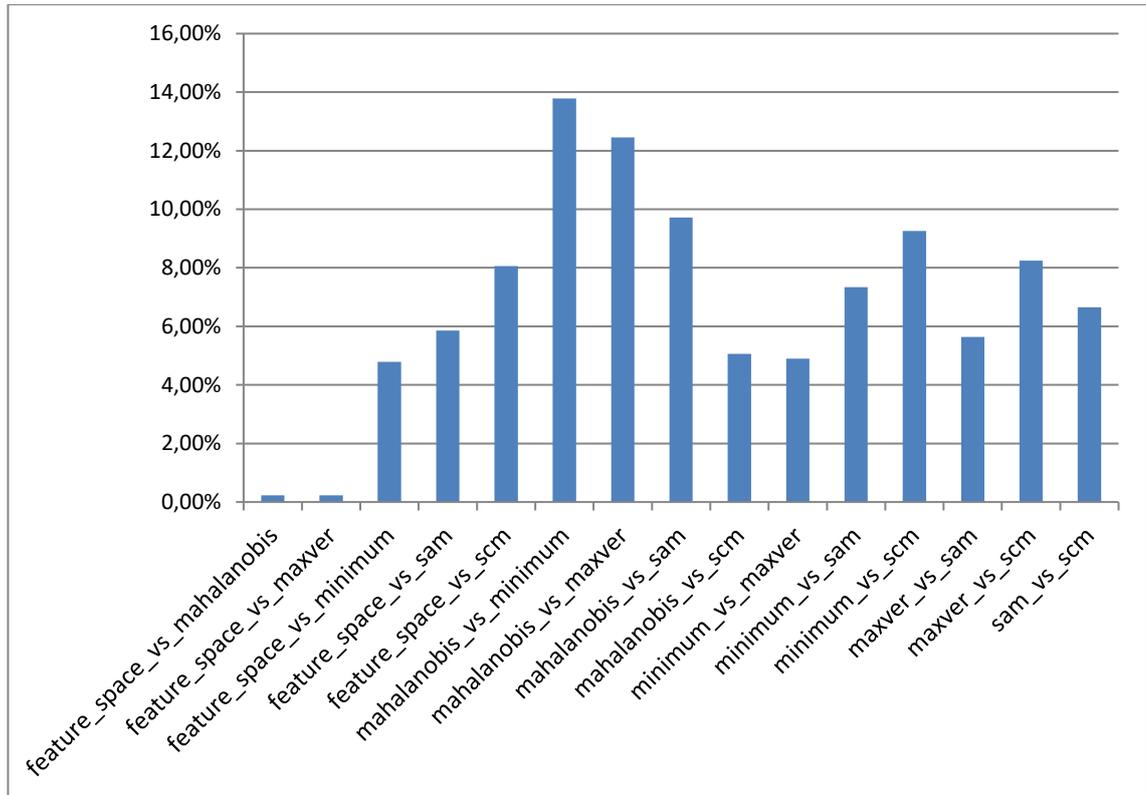
acurácia, porém com um resultado um pouco inferior, cerca de 92% para ambos. O método *Mahalanobis*, no índice *Kappa*, também teve o pior resultado entre todos os métodos com 90%.

Gráfico 2 – Índice *Kappa* – PA Aliança



Fonte: do Autor

O Gráfico 3 (*Image Difference*) do PA Aliança mostra uma relação interessante entre os métodos com melhores resultados, pois comparando-os, entre si, apresentaram uma variação pequena. Como esperado, um dos *outliers*, que, no caso, foi o *Mahalanobis* comparado ao Maxver. A diferença entre os dois melhores foi de 12,5% do total de *pixels*, confirmando, assim, os resultados do Índice *Kappa*.

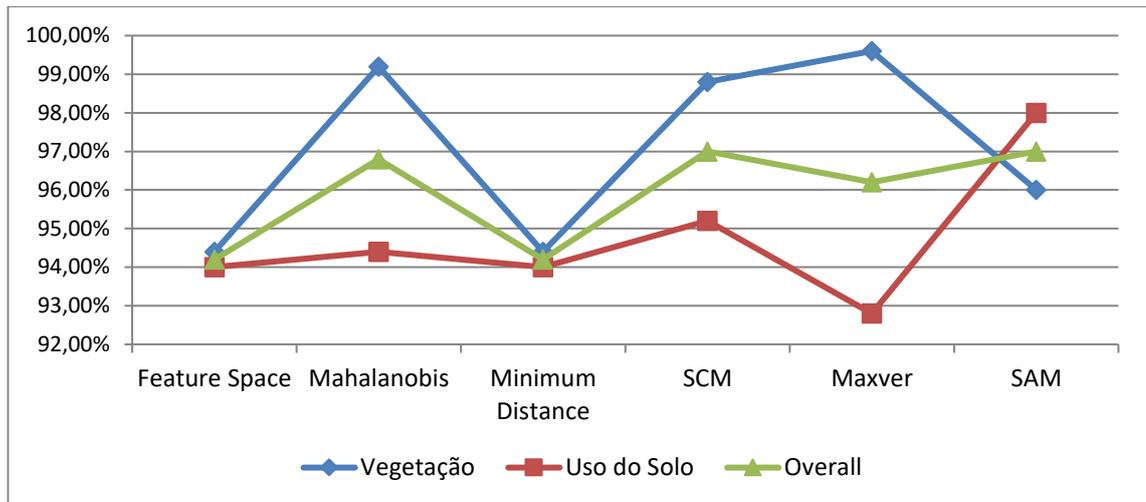
Gráfico 3 – *Image Difference* – PA Aliança

Fonte: do Autor

## PA ALTO PARAÍSO

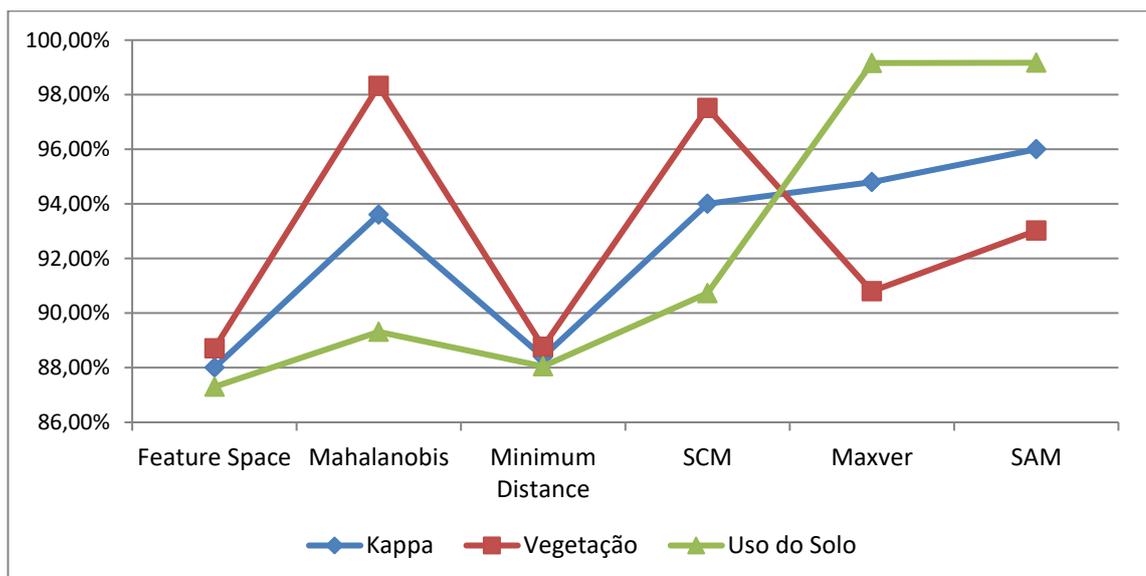
O PA Alto Paraíso seguiu a mesma dinâmica do PA Aliança no índice de acurácia (Gráfico 4). O melhor método foi o SAM com 97% de acurácia, com o uso do solo sendo o melhor resultado, algo que foge dos padrões dos outros métodos. O SCM possuiu um resultado igual ao do SAM, porém suas classes tiveram uma variação maior que o SAM, cerca de 4% de variação enquanto o SAM teve 2%. Os métodos *Feature Space* e *Minimum Distance* apresentaram a menor variação entre as classes, mas obtiveram os piores resultados de acurácia (94%).

Gráfico 4 - Accuracy Assessment – PA Alto Paraíso



Fonte: do Autor

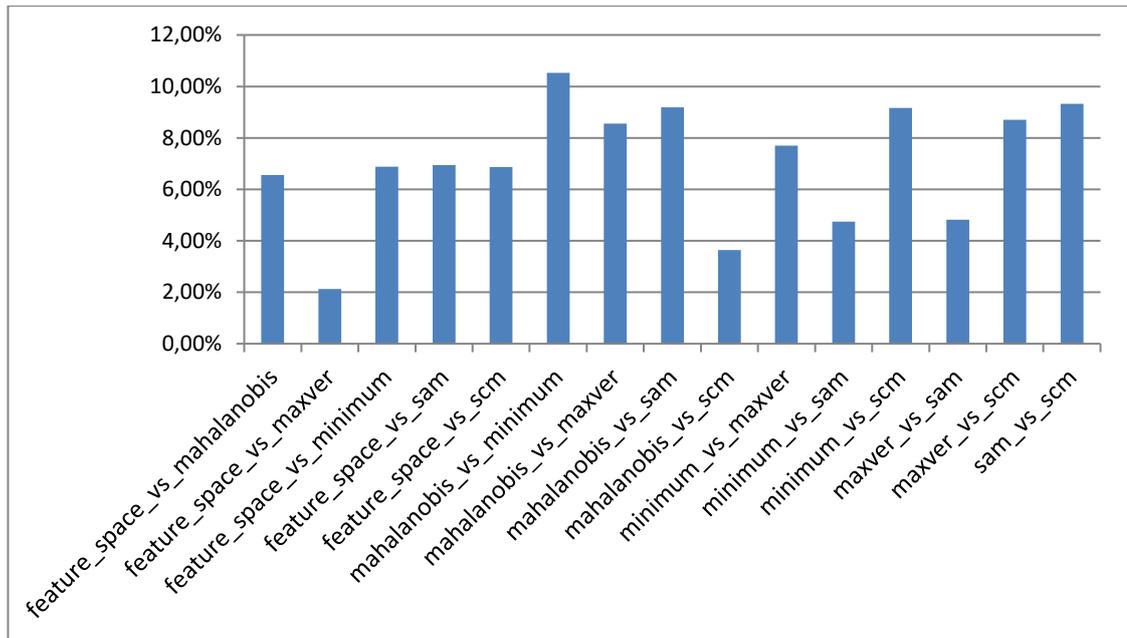
No Índice *Kappa*, as tendências se mantiveram com algumas diferenças entre o SAM e o SCM (Gráfico 5). A variação entre eles foi de 2%, sendo que o SAM teve o melhor resultado de 96%. Mas, por outro lado, a variação das classes de ambos passou a ser a mesma, algo próximo dos 1,8%. O Maxver assumiu o segundo melhor resultado com 95%, mas a sua variação das classes foi maior com 2,2%. Os demais métodos seguiram o mesmo padrão do nível de acurácia.

Gráfico 5 – Índice *Kappa* – Alto Paraíso

Fonte: do Autor

O Gráfico 6 (*Image Difference*) do PA Alto Paraíso corroborou com os resultados obtidos pelos Gráficos 4 e 5. Pois, ao se comparar os métodos com resultados mais baixos com aqueles com melhores índices, a diferença foi maior do que ao se comparar métodos com resultados bons.

Gráfico 6 – *Image Difference* – PA Alto Paraíso

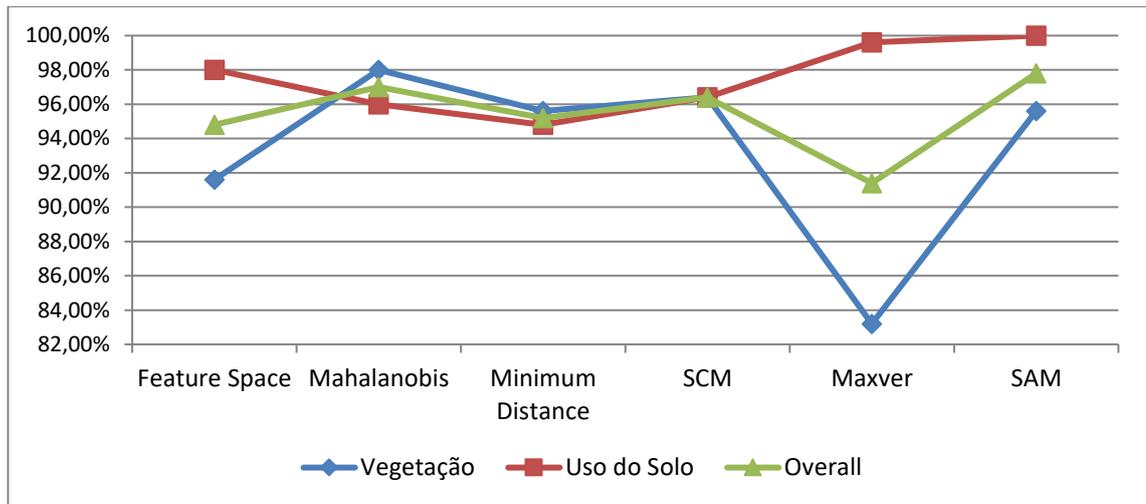


Fonte: do Autor

## PA ARAÚNA

O PA Araúna apresentou resultados semelhantes aos demais, com o SAM apresentando o melhor resultado 97,8%, *Mahalanobis* com o segundo melhor resultado, 97%, e tendo uma variação de 0,5% entre as suas classes. O SCM obteve o terceiro melhor resultado 96%, mas as suas classes não apresentaram variação, ambas tiveram como resultado um índice de 96% de acurácia. (Gráfico 7)

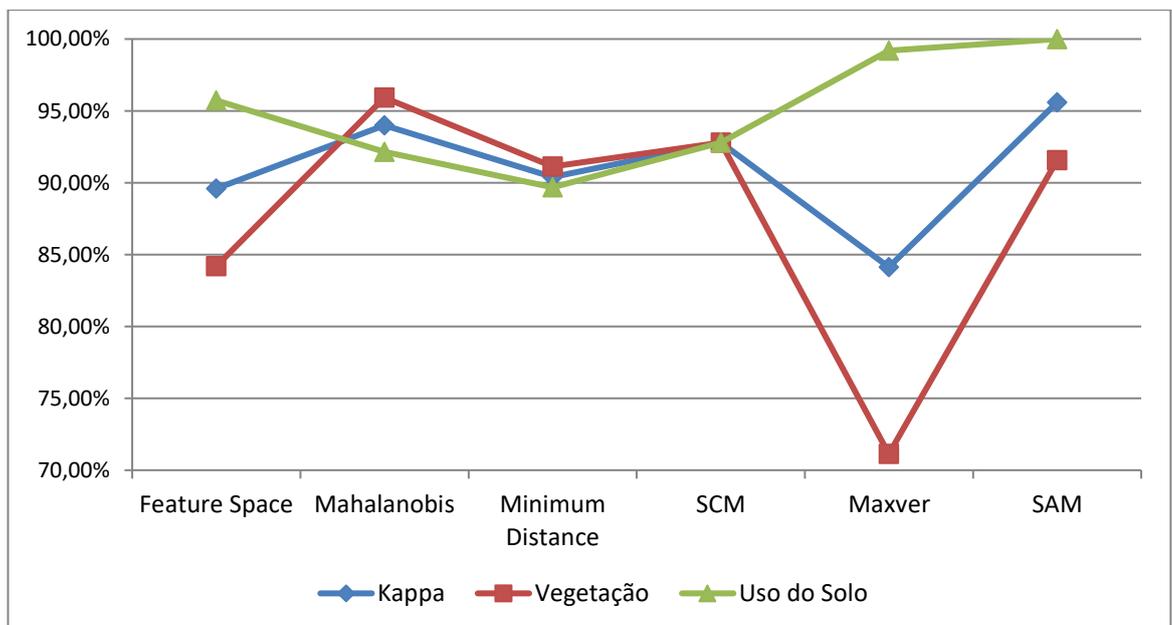
Gráfico 7 - Accuracy Assessment – PA Araúna



Fonte: do Autor

No Gráfico 8 (Índice *Kappa*) do PA Araúna, foi mantida a tendência do gráfico de acurácia com resultados um pouco menores, mas mantendo as proporções entre os resultados. O SAM teve um resultado de 95,6% e uma variação entre as classes de 8,5%. O *Mahalanobis* com 94% e uma variação das suas classes de 4%. O SCM com 92,8% no índice geral e sem variação nas suas classes.

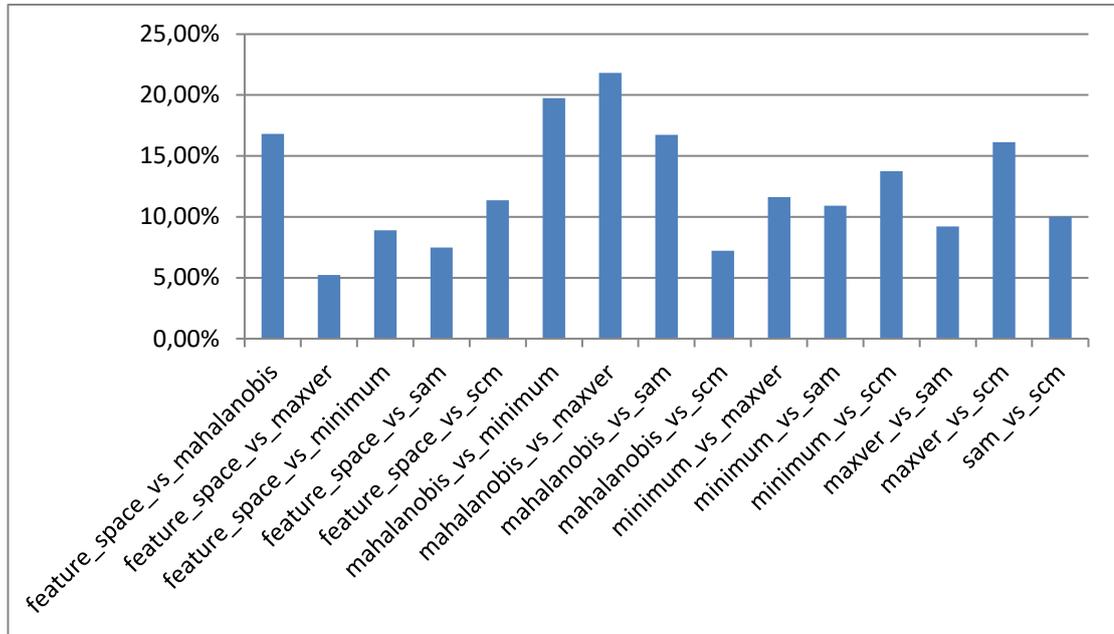
Gráfico 8 – Índice Kappa – PA Araúna



Fonte: do Autor

O Gráfico 9 (*Image Difference*) confirmou o resultados obtidos no índice de acurácia e no *Kappa*, da mesma forma que no PA Alto Paraíso. Porém, apresentando diferenças um pouco menores.

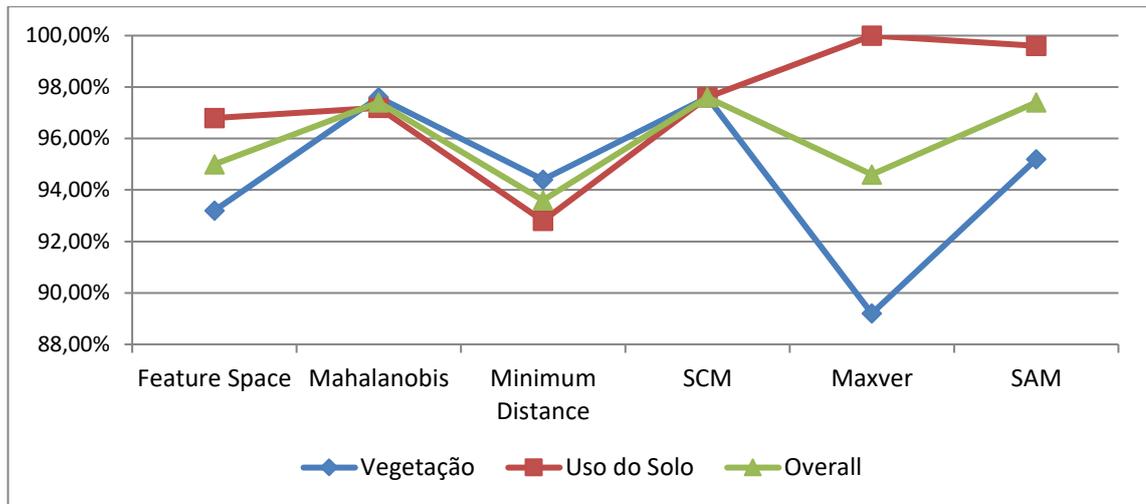
Gráfico 9 – *Image Difference* – PA Araúna



Fonte: do Autor

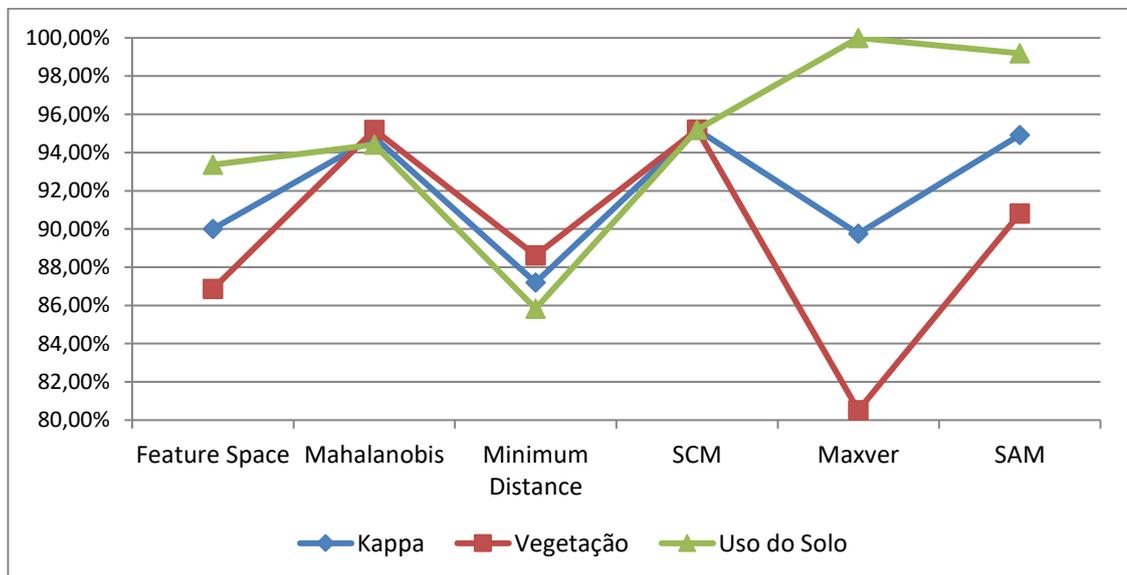
## PA ARAÚNA II

No PA Araúna II, houve uma mudança no método que apresentou melhor resultado. O SCM obteve 97,6% de índice geral e sem variação em suas classes. O *Mahalanobis* e o SAM tiveram o mesmo resultado com 97,4%, sendo que o *Mahalanobis* também não apresentou variação em suas classes, e o SAM apresentou uma diferença de 4% entre elas. A diferença de 0,2% entre os três melhores métodos não foi relevante, porém o fato de o SAM ter tido uma variação maior em suas classes tornou sua classificação menos confiável que as demais. (Gráfico 10)

Gráfico 10 - *Accuracy Assessment* – PA Araúna II

Fonte: do Autor

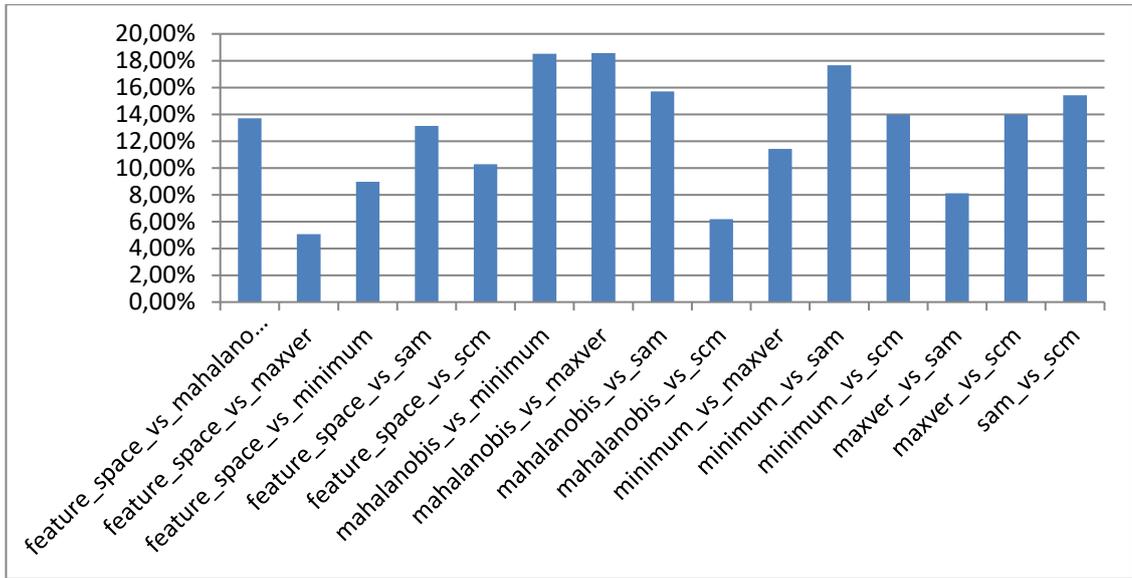
No Índice *Kappa* (Gráfico 11), a proporção dos resultados se manteve, com algumas partes destacando-se das demais, como o aumento da variação das classes do SAM e do *Mahalanobis*, de 8% e 0,9% de diferenças entre as classes respectivamente.

Gráfico 11 – Índice *Kappa* – PA Araúna II

Fonte: do Autor

O Gráfico 12 (*Image Difference*) PA Araúna II confirmou novamente os resultados obtidos nas análises do *Kappa* e da acurácia, com o SCM e o *Mahalanobis* variando apenas 6%.

Gráfico 12 – *Image Difference* – PA Araúna II

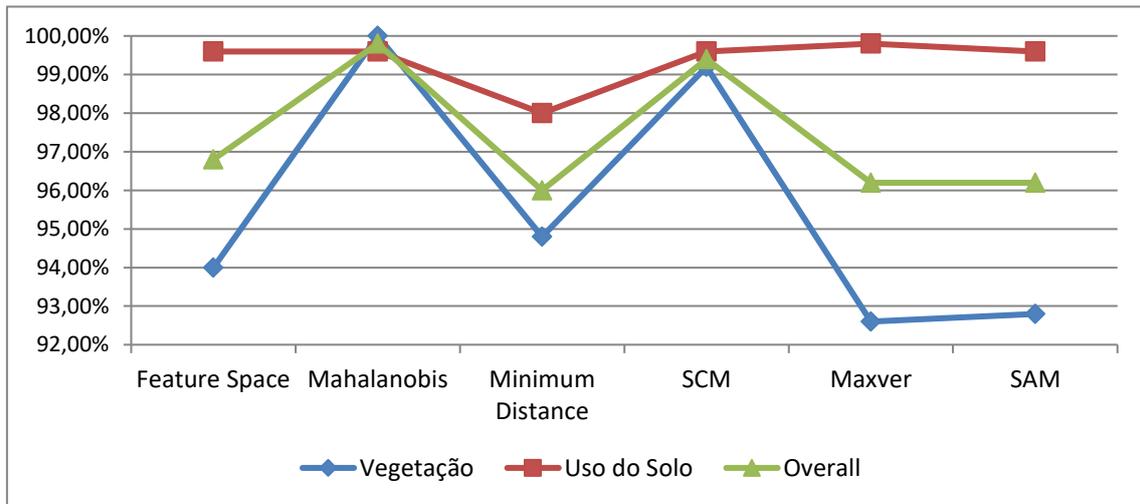


Fonte: do Autor

PA BARRA NORTE

No PA Barra Norte, o *Mahalanobis* teve o melhor resultado de acurácia com 99,8%, com a vegetação a 100% e o uso do solo a 99,6%. O *SCM* obteve 99,4% de índice geral e com variação de 0,4 em suas classes. O terceiro melhor resultado foi o *Feature Space* com 96,8% de índice geral, com 5,6% de variação. (Gráfico 13)

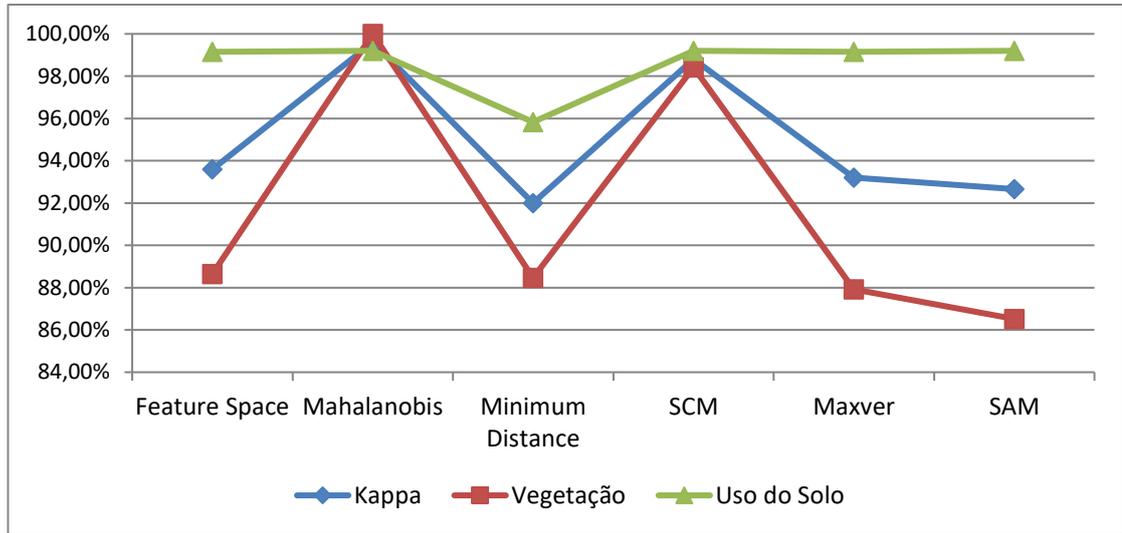
Gráfico 13 - *Accuracy Assessment* – PA Barra Norte



Fonte: do Autor

No Índice *Kappa* (Gráfico 14), a proporção dos resultados se manteve, com uma redução de 0,2% para o *Mahalanobis* com referência ao índice geral de acurácia e o *SCM* de 0,4%. O *Feature Space* teve uma redução de 3,2%, com uma variação de 10,51% entre as classes.

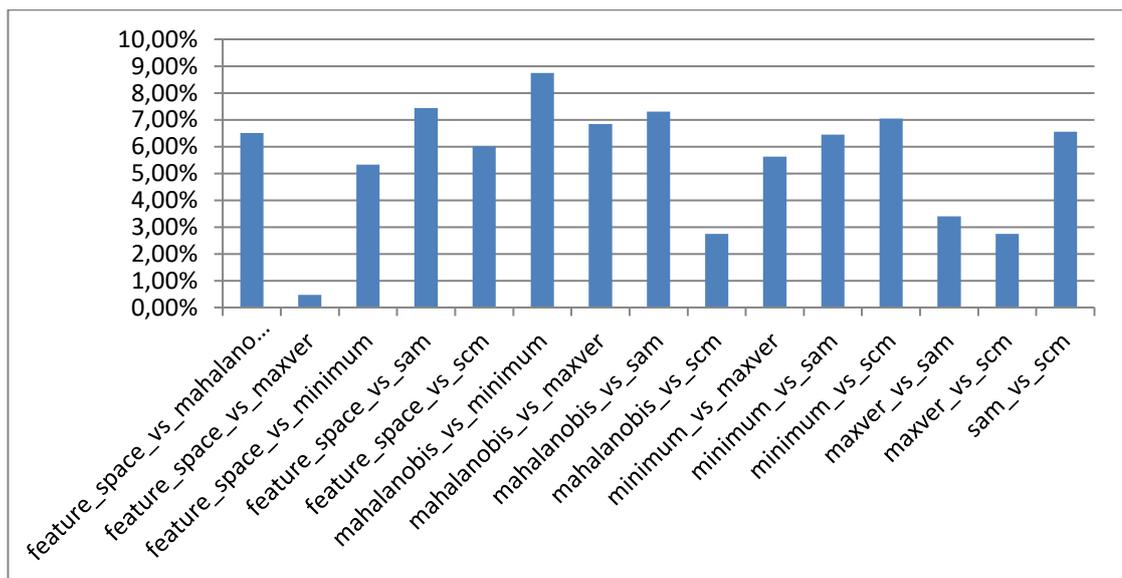
Gráfico 14 – Índice Kappa – PA Barra Norte



Fonte: do Autor

O Gráfico 15 (*Image Difference*) indica que houve uma variação de 2,75% entre o *SCM* e o *Mahalanobis*, confirmando os resultados anteriores.

Gráfico 15 – *Image Difference* – PA Barra Norte

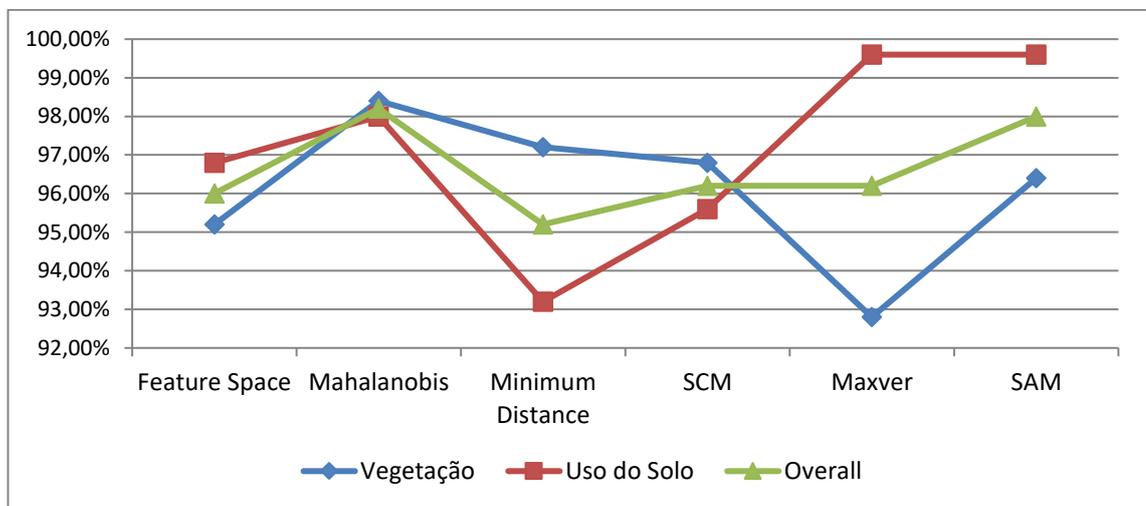


Fonte: do Autor

## PA BELA VISTA

No PA Bela Vista, o melhor resultado de acurácia continuou sendo do método *Mahalanobis*, com 98,2% de índice geral e uma variação de 0,4% entre as classes. O segundo melhor resultado é o do SAM, com 98% de índice geral e variação de 3,2%. O terceiro melhor resultado ficou entre o SCM e o Maxver, ambos com 96,2%, sendo que o SCM teve uma variação de 1,2% e o Maxver de 7,2%. (Gráfico 16)

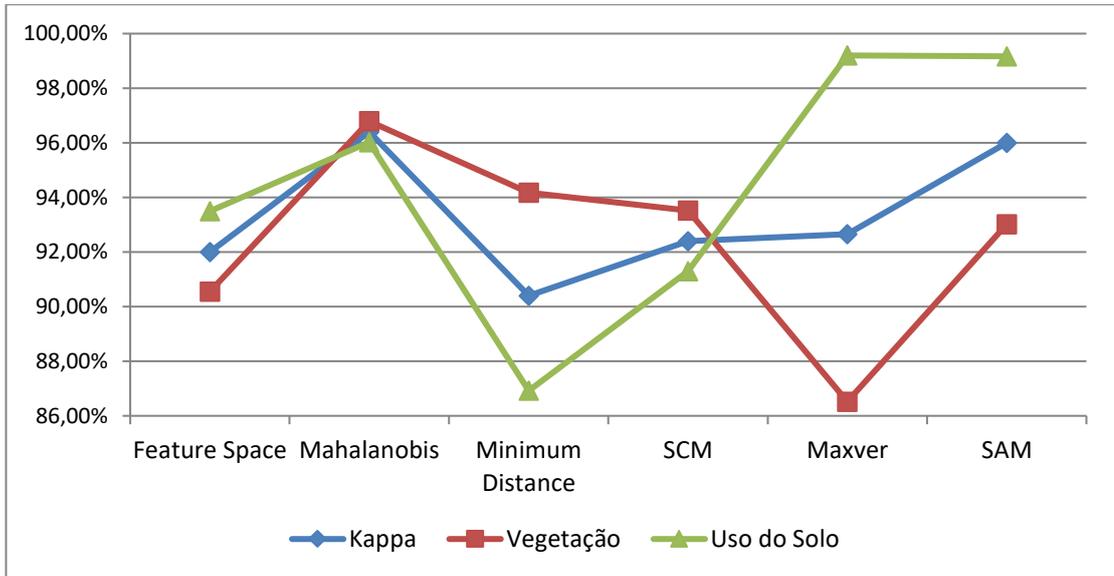
Gráfico 16 - *Accuracy Assessment* – PA Bela Vista



Fonte: do Autor

No Índice *Kappa* (Gráfico 17), o *Mahalanobis* (96,4%) e o SAM (96%) continuaram com os primeiro e segundo melhores resultados. A variação das classes no *Mahalanobis* foi de 0,77% e a do SAM de 6,15%. O terceiro melhor resultado foi do Maxver com 92,66% e variação de 2,68%. O quarto melhor foi o SCM com 92,4% e uma variação de 2,22%.

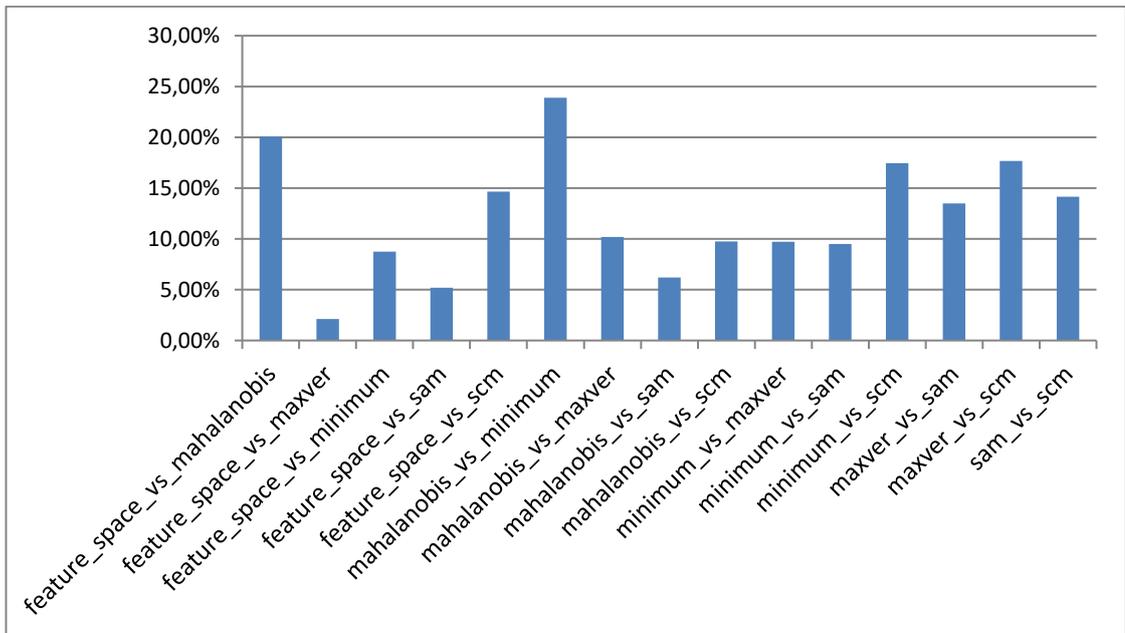
Gráfico 17 – Índice *Kappa* – PA Bela Vista



Fonte: do Autor

O Gráfico 18 (*Image Difference*) do PA Bela Vista corroborou com os resultados obtidos nas análises do *Kappa* e da acurácia. Comparando-se os dois melhores métodos, *Mahalanobis* e SAM, obteve-se uma diferença de 6,21%.

Gráfico 18 – *Image Difference* – PA Bela Vista

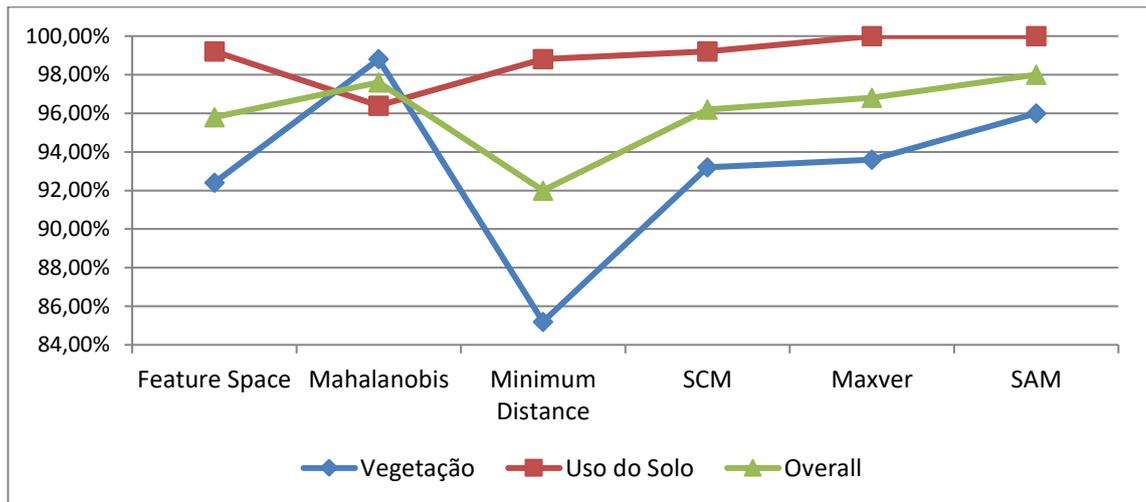


Fonte: do Autor

## PA BELMONTE

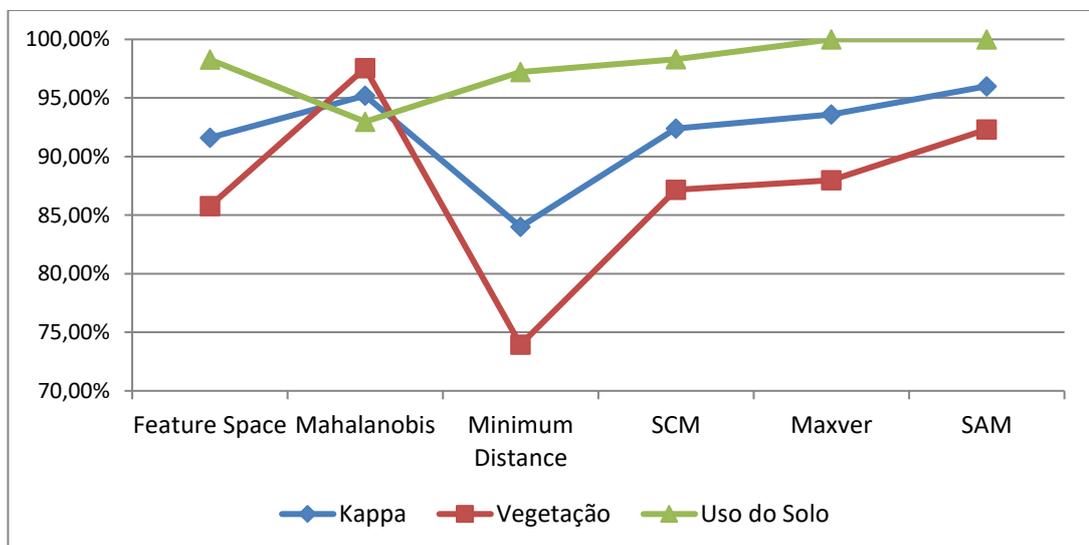
No PA Belmonte, o melhor resultado foi do SAM com 98% e variação de 4%, seguido do *Mahalanobis* com 97,6%, e variação de 2,4%. O terceiro foi do Maxver com 96,8% com variação de 6,4%. Em quarto lugar, o SCM com 96,2 e variação de 6%. (Gráfico 19)

Gráfico 19 - Accuracy Assessment – PA Belmonte



Fonte: do Autor

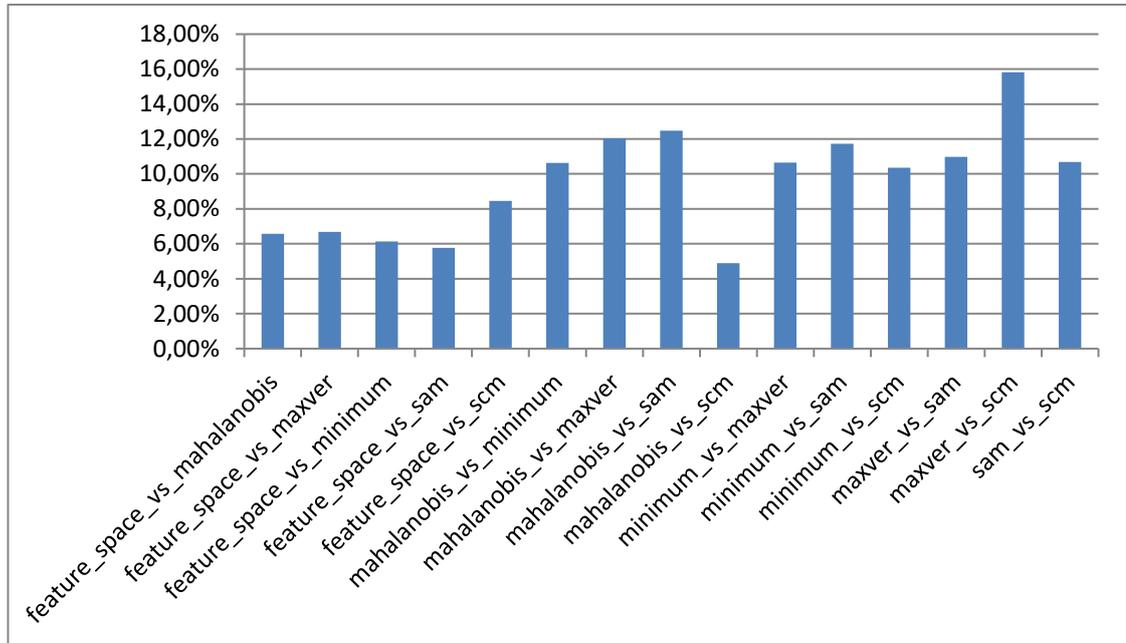
No Índice *Kappa* (Gráfico 20), a ordem do melhor para o pior se manteve: SAM (96%), *Mahalanobis* (95,2%), Maxver (93,6%) e SCM (92,4%). As variações representaram os seguintes valores respectivamente: 7,69%, 4,51%, 12,03%, 11,13%.

Gráfico 20 – Índice *Kappa* – PA Belmonte

Fonte: do Autor

O Gráfico 21 (*Image Difference*) PA Belmonte não confirma os resultados obtidos nas análises do *Kappa* e da acurácia. O *Mahalanobis* comparado ao SAM apresentou uma variação de 12,47%, enquanto o *Mahalanobis* comparado ao SCM apresentou uma diferença de 4,9%.

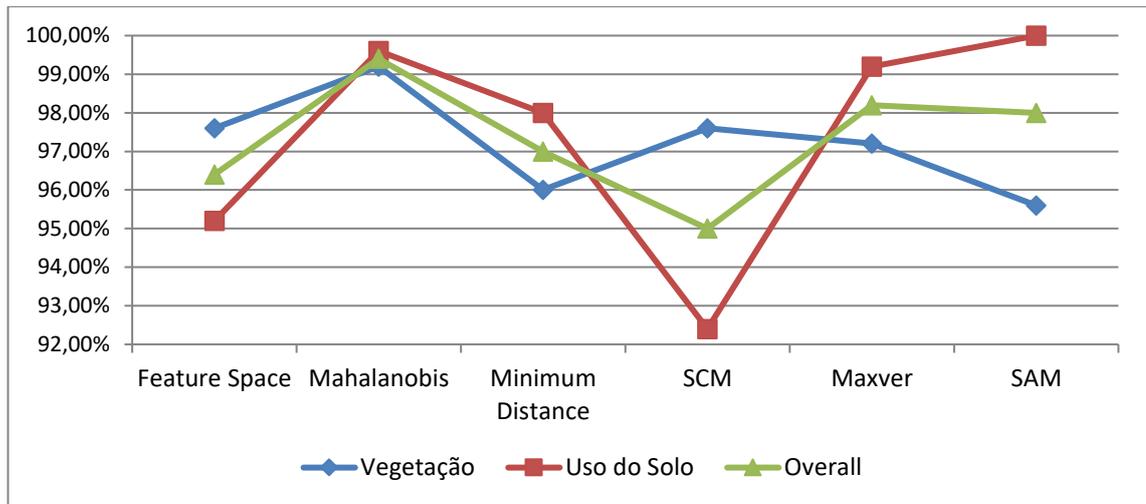
Gráfico 21 – *Image Difference* – PA Belmonte



Fonte: do Autor

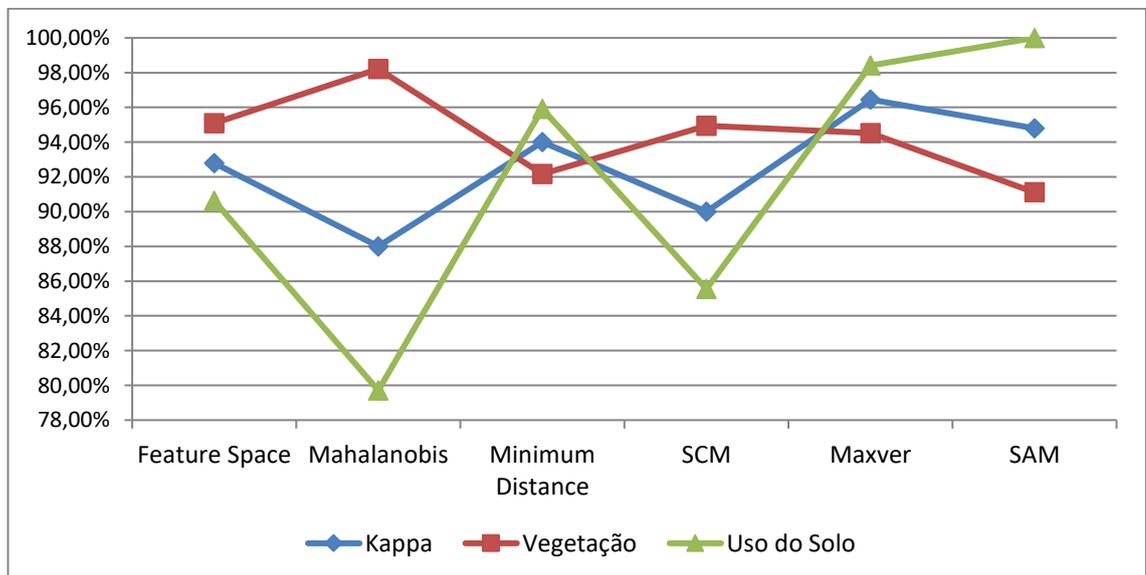
## PA BONJAGUA

No PA Bonjagua, houve uma mudança no método que apresentou melhor resultado. O *Mahalanobis* obteve 99,40% de índice geral, com uma variação de 0,4% entre as classes. O Maxver teve o segundo melhor resultado com 98,2% e uma variação de 2%. O SAM ficou em terceiro com 98%, com uma diferença de 4,4% entre as classes. O *Minimum Distance* obteve 97% de índice geral, com uma variação de 2% (Gráfico 22).

Gráfico 22 - *Accuracy Assessment* – PA Bonjagua

Fonte: do Autor

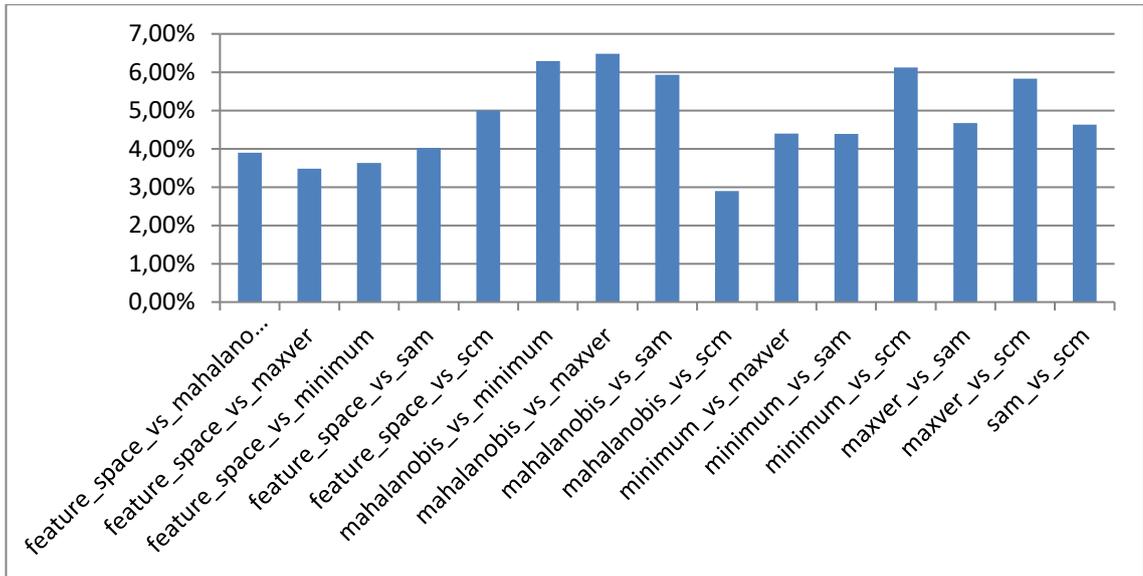
No Índice *Kappa* (Gráfico 23), o melhor resultado foi o Maxver com 96,45% de índice geral e uma variação de 4,1%. O segundo melhor foi o SAM com 94,8% e variação de 8,89%. O terceiro melhor resultado foi do *Minimum Distance* com 94% e uma variação de 3,76%.

Gráfico 23– Índice *Kappa* – PA Bonjagua

Fonte: do Autor

No Gráfico 24 (*Image Difference*), a comparação entre o Maxver e o SAM (os dois melhores) apresentou uma variação de 4,67%. Em contraposição, ao se comparar o *Mahalanobis* e o SCM obteve-se uma variação de 2,9%, mesmo tendo tido resultados *Kappa* abaixo dos demais.

Gráfico 24– *Image Difference* – PA Bonjagua

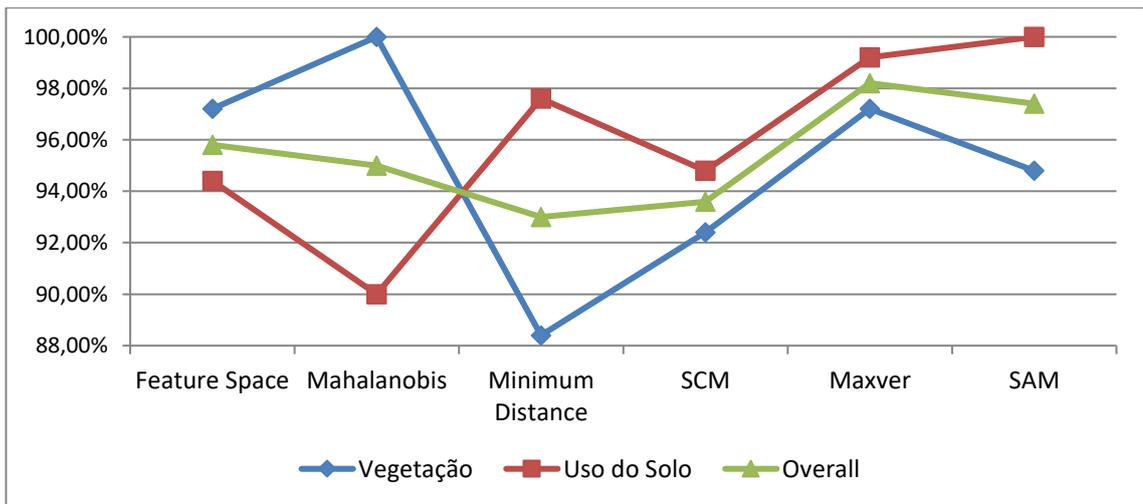


Fonte: do Autor

PA CACHIMBO II

No PA Cachimbo II, o melhor método foi o Maxver com uma variação de 2% e um índice geral de 98,2%. O SAM, com segundo melhor resultado, de 97,4% e uma variação de 5,2%. Em terceiro, o *Feature Space* obteve 95,8% de índice geral e 3% de variação. (Gráfico 25)

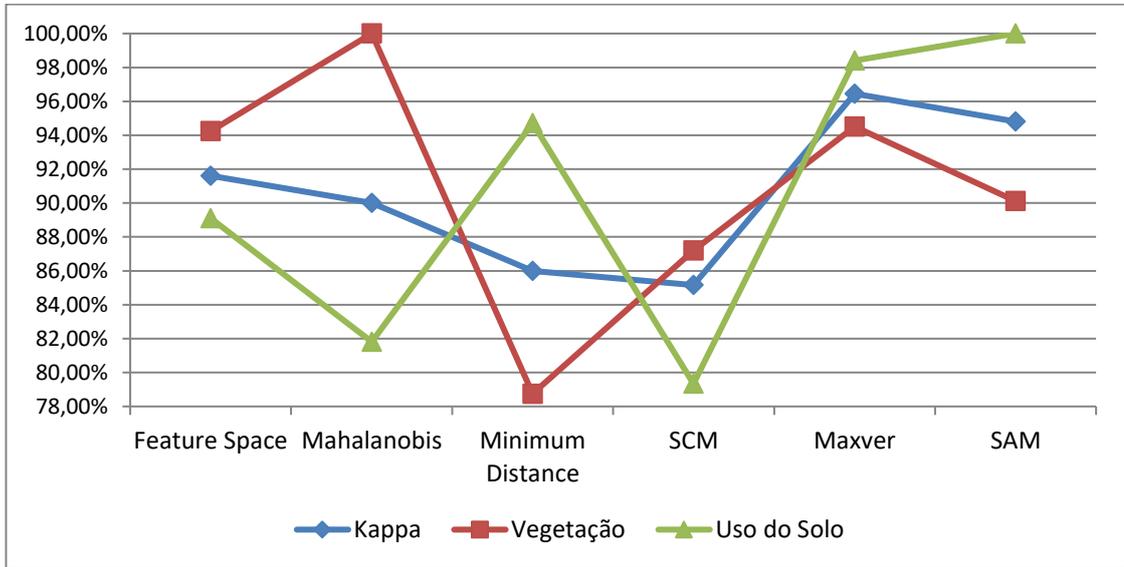
Gráfico 25 - *Accuracy Assessment* – PA Cachimbo II



Fonte: do Autor

No Índice *Kappa* do PA Cachimbo II (Gráfico 26), o melhor resultado foi o Maxver com 96,45% e com uma variação de 3,9%; seguido pelo SAM com 94,8% e uma variação de 9,89% de variação. Em terceiro, o *Feature Space* com 91,6% e uma variação de 4,87%.

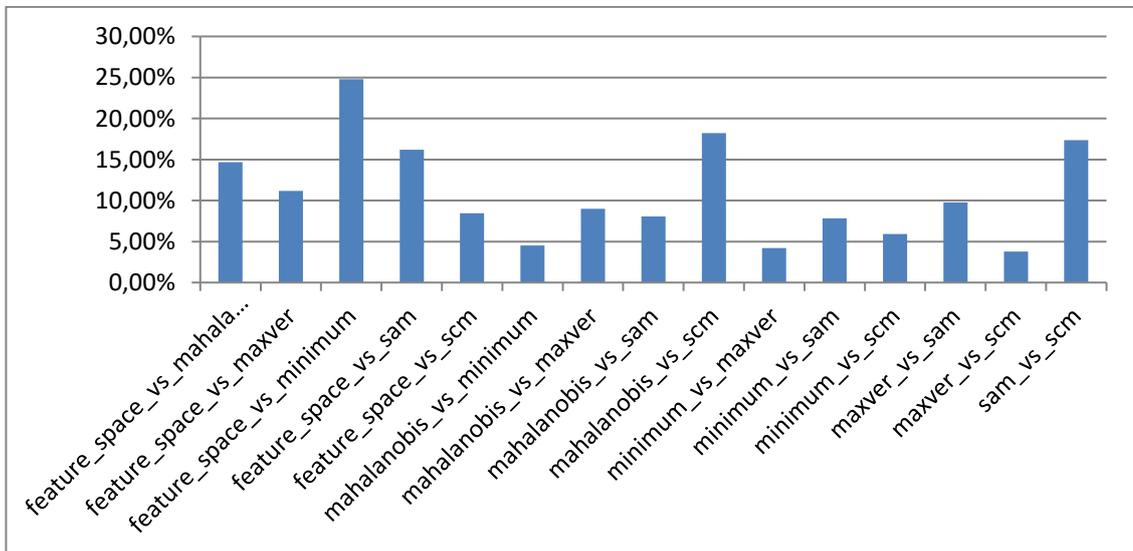
Gráfico 26 – Índice *Kappa* – PA Cachimbo II



Fonte: do Autor

No Gráfico 27 (*Image Difference*) do PA Cachimbo II, ao se comparar os resultados do Maxver com o SAM houve uma variação entre eles de 9,77%. Em contraposição, ao se comparar o *Mahalanobis* com o SCM obteve-se uma diferença de 18,22%. Isso demonstra que um resultado pode representar um *outlier* e, por isso, não representar a realidade.

Gráfico 27 – *Image Difference* – PA Cachimbo II

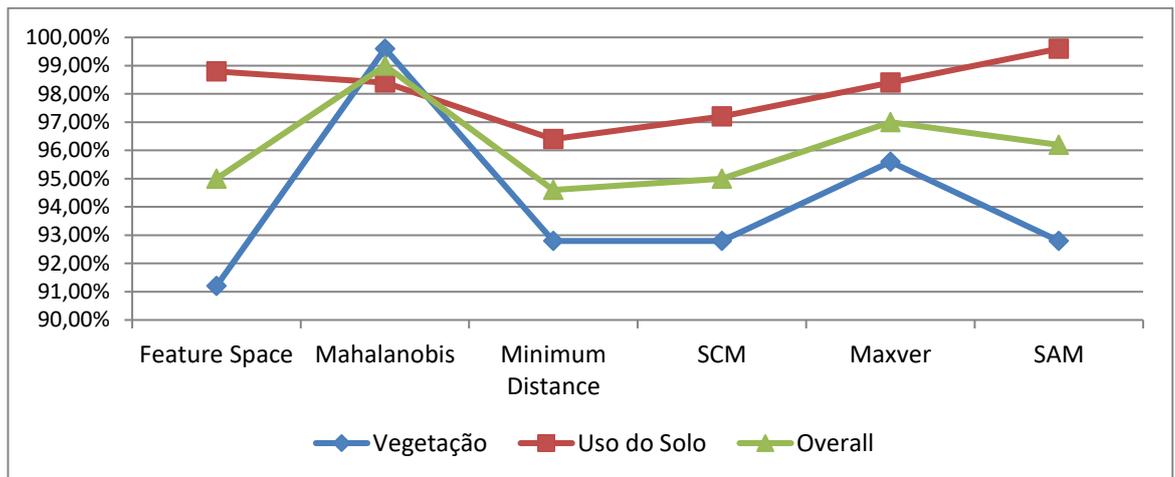


Fonte: do Autor

## PA CACHOEIRA DA UNIÃO

No PA Cachoeira da União, o método com melhor resultado foi o *Mahalanobis* com 99% de índice geral e uma variação de 0,2%. O segundo melhor foi o Maxver com 97% e 2,8%, respectivamente. O terceiro resultado foi o SAM com 96,2% de índice geral e uma variação de 6,8% de variação. (Gráfico 28)

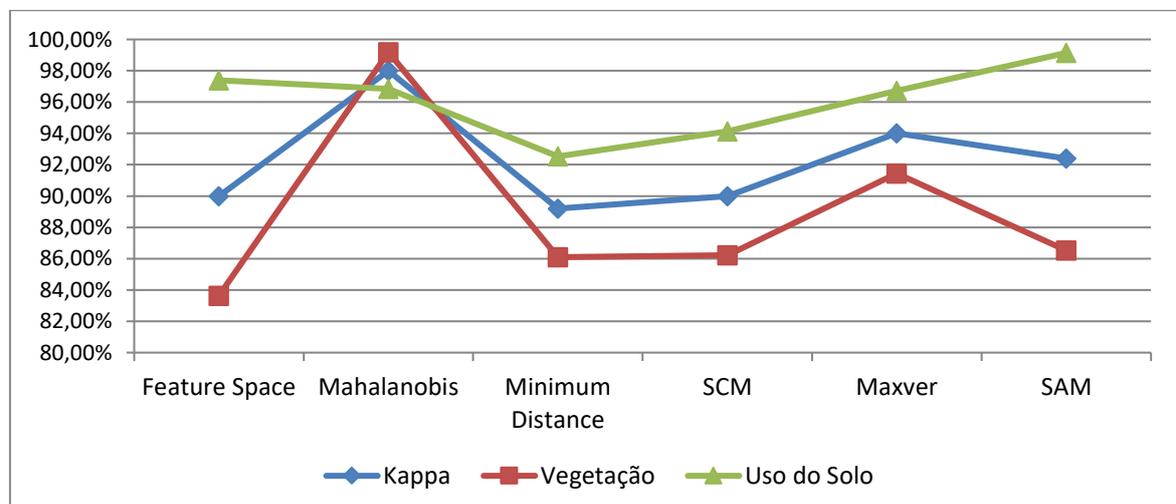
Gráfico 28 - *Accuracy Assessment* – PA Cachoeira da União



Fonte: do Autor

No Índice *Kappa* (Gráfico 29), os três melhores resultados permaneceram os mesmos que os do *Accuracy Assessment* do PA Cachoeira da União, sendo que o *Mahalanobis* obteve 98% de índice geral e 2,35% de variação, o Maxver 94% e 5,27, e o SAM 92,4% e uma variação de 12,62%.

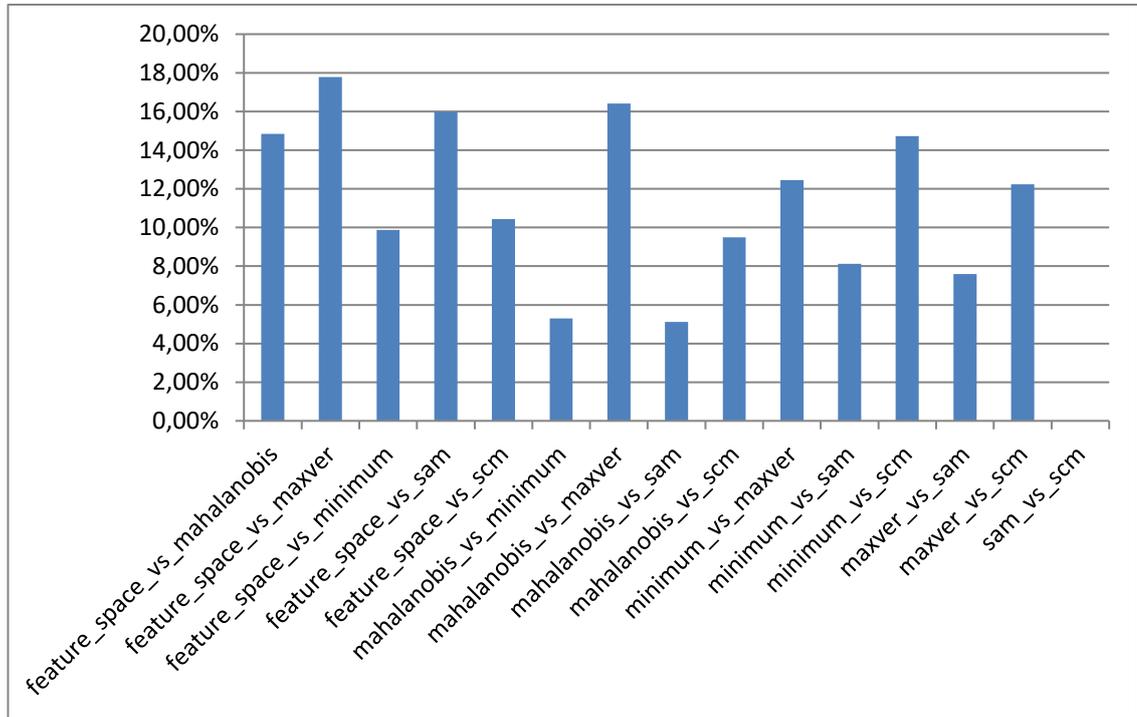
Gráfico 29 – Índice *Kappa* – PA Cachoeira da União



Fonte: do Autor

O Gráfico 30 (*Image Difference*) indica que, provavelmente, houve erros nas classificações feitas pelos métodos, pois houve uma grande variância entre o Método *Mahalanobis* e Maxver (16%).

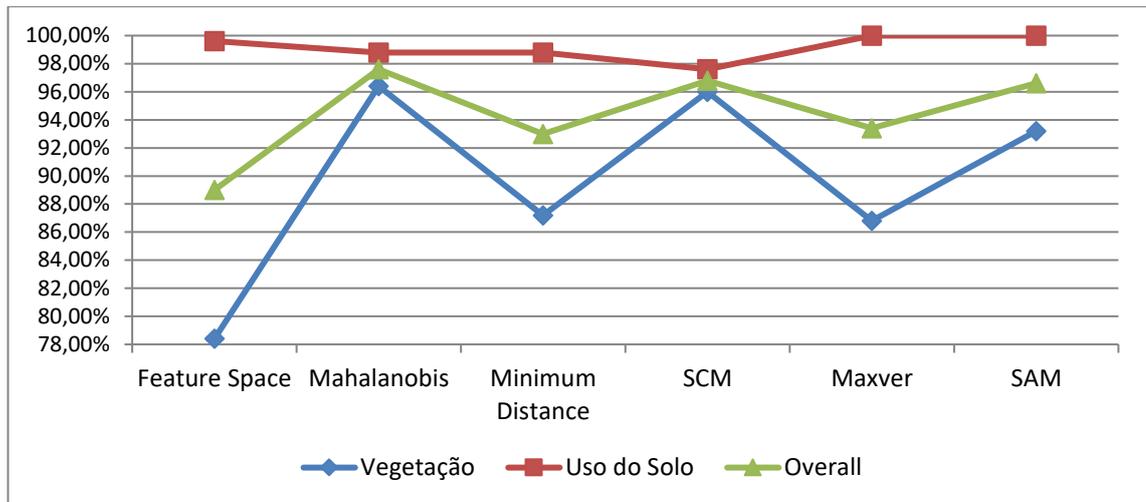
Gráfico 30 – *Image Difference* – PA Cachoeira da União



Fonte: do Autor

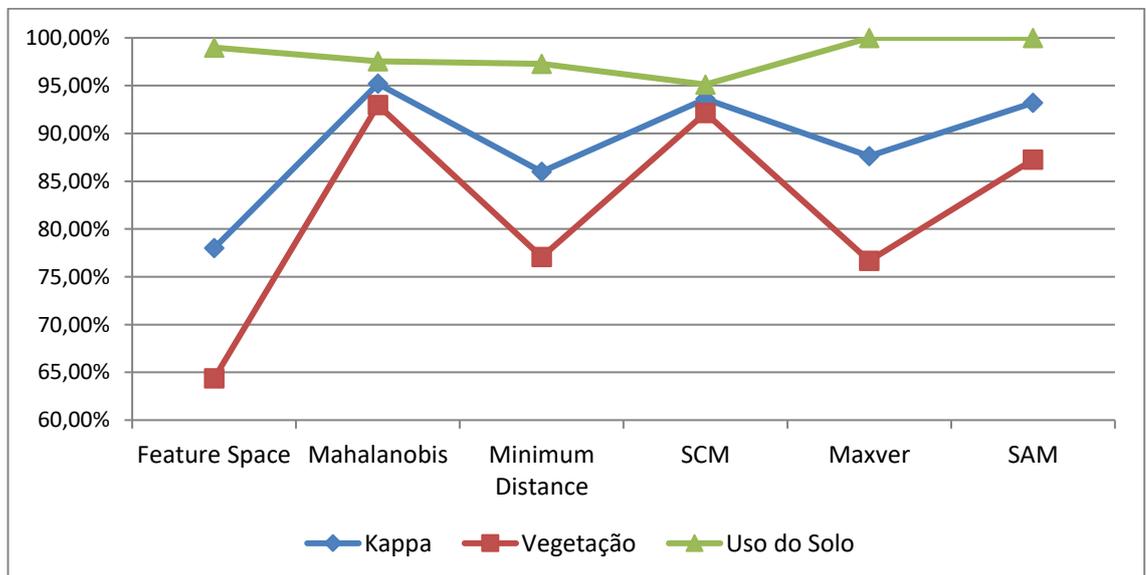
PA CASTANHAL

No PA Castanhal, os melhores resultados apresentados foram o *Mahalanobis*, SCM e o SAM, com os índices gerais de 97,6%, 96,8 e 96,6%, respectivamente, e uma variação de 2,4%, 1,6% e 6,8%, também respectivamente. O *Mahalanobis* e o SCM tiveram bons resultados e baixas variações nas classes, principalmente o SCM com 1,6%. (Gráfico 31)

Gráfico 31 - *Accuracy Assessment* – PA Castanhal

Fonte: do Autor

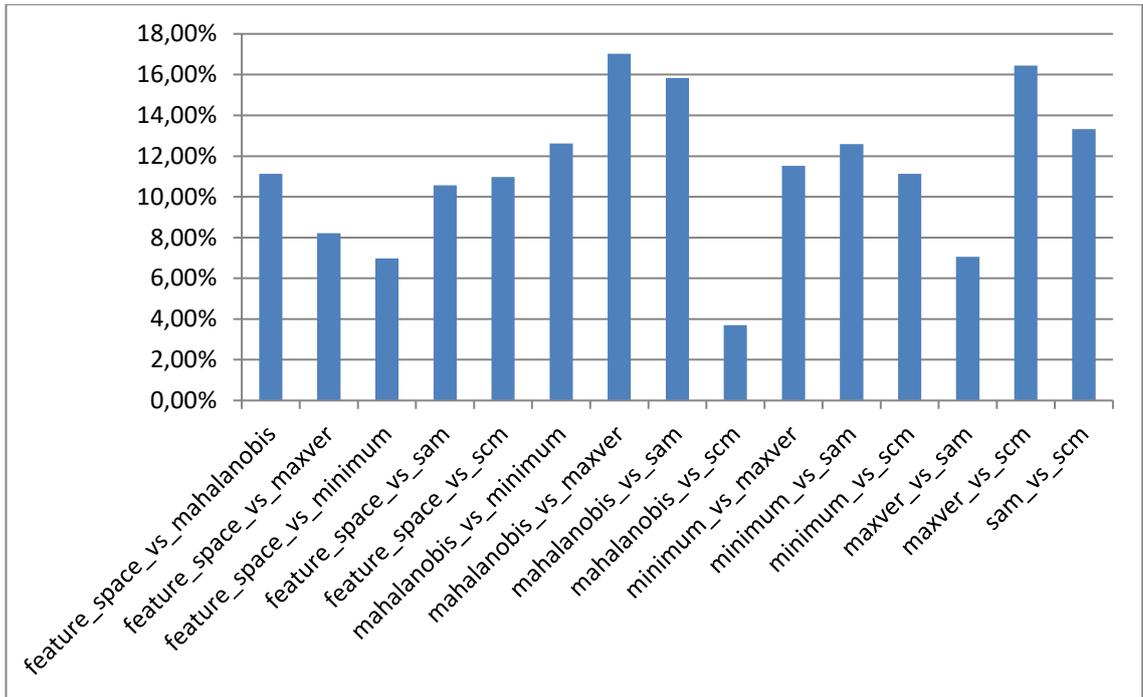
No Índice *Kappa* (Gráfico 32), a proporção dos resultados se manteve, com algumas partes a serem destacadas como a diminuição de todos os índices gerais. Em contraponto, a variação das classes aumentou nos três métodos (*Mahalanobis*, *SCM* e *SAM*).

Gráfico 32 – Índice *Kappa* – PA Castanhal

Fonte: do Autor

O Gráfico 33 (*Image Difference*) confirma os resultados obtidos nas análises do *Kappa* e da acurácia. Comparando o *Mahalanobis* com o *SCM* obteve-se uma variação de apenas 3,7%.

Gráfico 33 – Image Difference – PA Castanhal

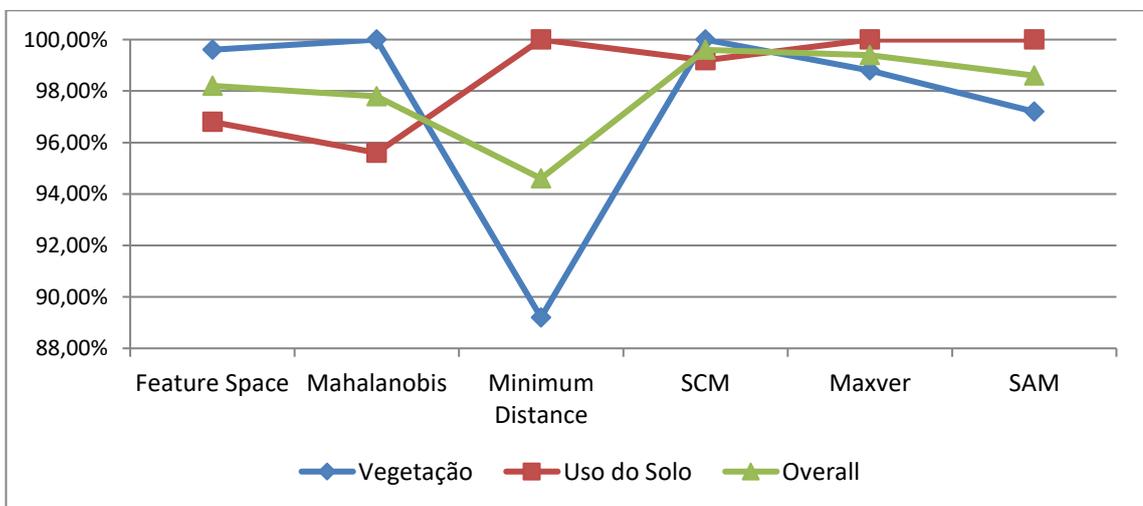


Fonte: do Autor

PA CEDRO ROSA

No PA Cedro Rosa, os melhores resultados foram SCM, Maxver e SAM. Com os índices gerais de 99,6%, 99,4% e 98,6%, respectivamente. As diferenças entre as classes foram de 0,8% para o SCM, 0,9% para o Maxver e 2,8% para o SAM. (Gráfico 34)

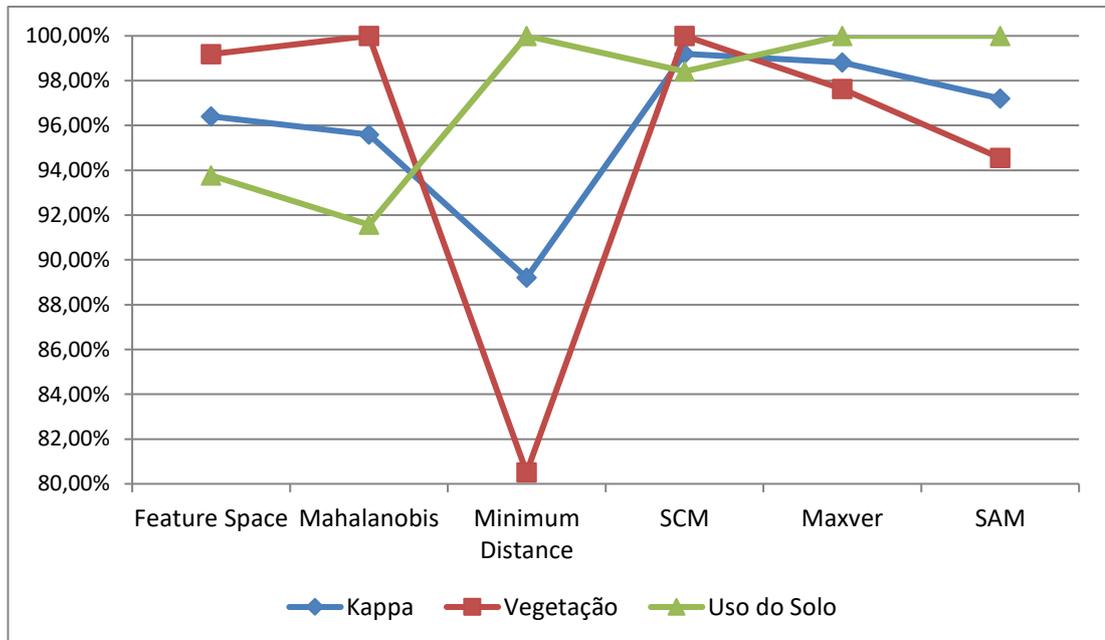
Gráfico 34 - Accuracy Assessment – PA Cedro Rosa



Fonte: do Autor

Os resultados Índice Kappa do Gráfico 35 mantiveram as proporções dos índices do Gráfico 34, com os valores de 99,2% (SCM), 98,81% (Maxver) e 97,2% (SAM). A variação foi de 1,59%, 2,37% e 5,45%.

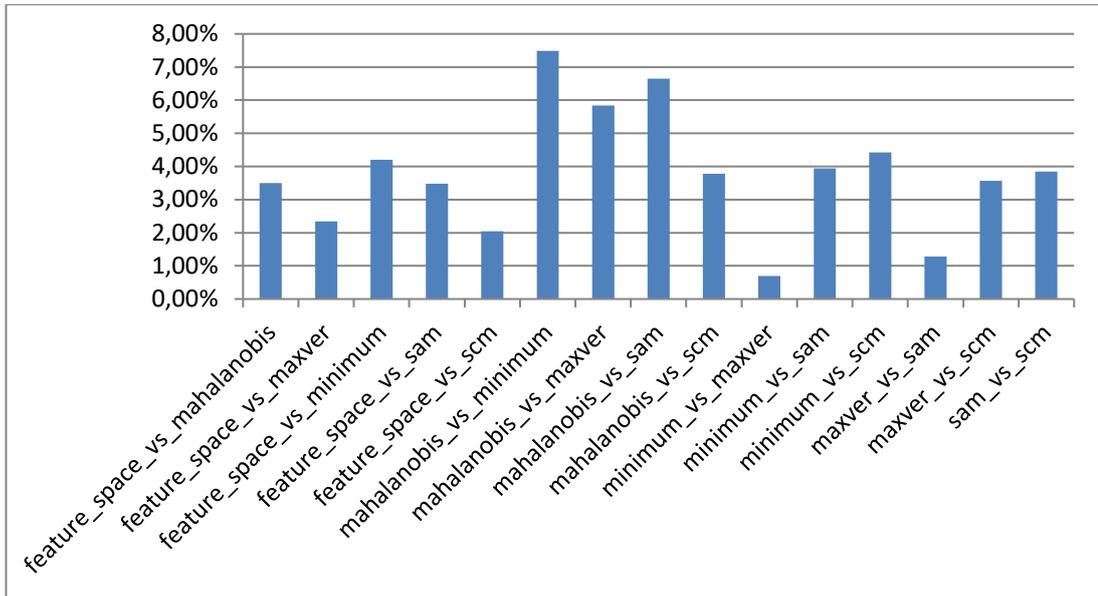
Gráfico 35 – Índice Kappa – PA Cedro Rosa



Fonte: do Autor

O Gráfico 36 (*Image Difference*) PA Cedro Rosa confirmou os resultados obtidos nas análises do *Kappa* e da acurácia. Com o SCM e o *Maxver* variando apenas 3,57%, o SCM com o SAM 3,84%, e o *Maxver* com o SAM 1,28%. Esses resultados demonstraram que as classificações foram bem processadas, demonstrando, assim, o baixo nível de erros.

Gráfico 36 – *Image Difference* – PA Cedro Rosa

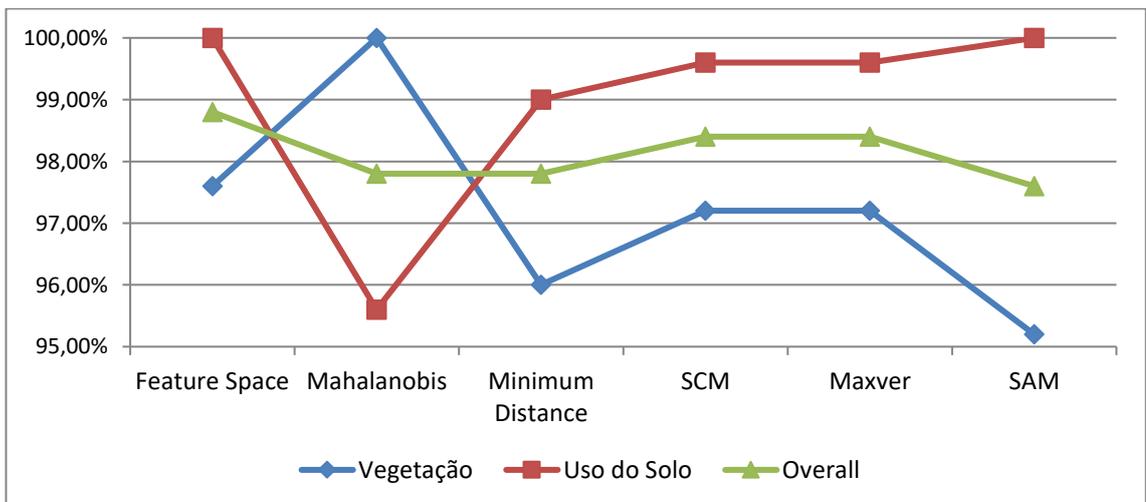


Fonte: do Autor

PA CHACORORE

No PA Chacorore, houve uma mudança no método que apresentou melhor resultado. O *Feature Space* obteve 98,8% de índice geral e 2,4% de variação nas classes. O SCM e o Maxver tiveram o mesmo resultado com 98,4%, e a mesma variação de 2,4% entre elas. O SAM teve o quarto resultado com 97,6% de índice geral e 4,8% de variação. (Gráfico 37)

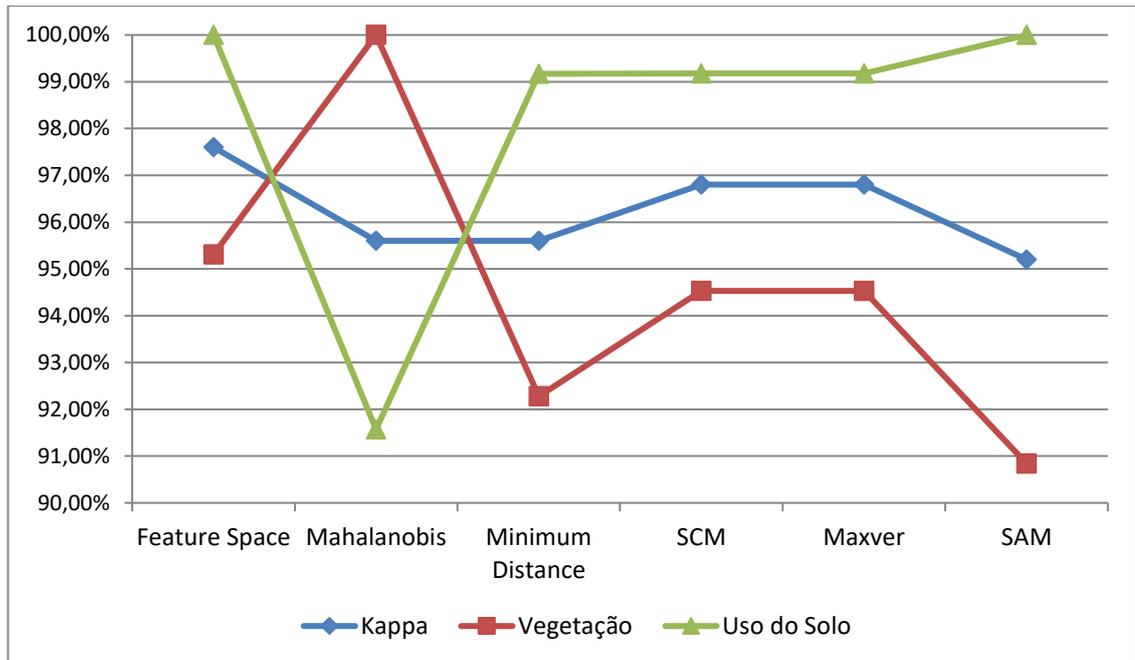
Gráfico 37 - *Accuracy Assessment* – PA Chacorore



Fonte: do Autor

No Índice *Kappa* (Gráfico 38), a proporção e a ordem dos resultados se mantiveram, sendo que o *Feature Space* obteve o resultado de 97,6%, o SCM e o Maxver com 96,8% e o SAM com 95,2%. As diferenças entre as classes aumentaram um pouco com 4,69% para o *Feature Space*, 4,65% para o SCM e o Maxver, e 4,36% para o SAM.

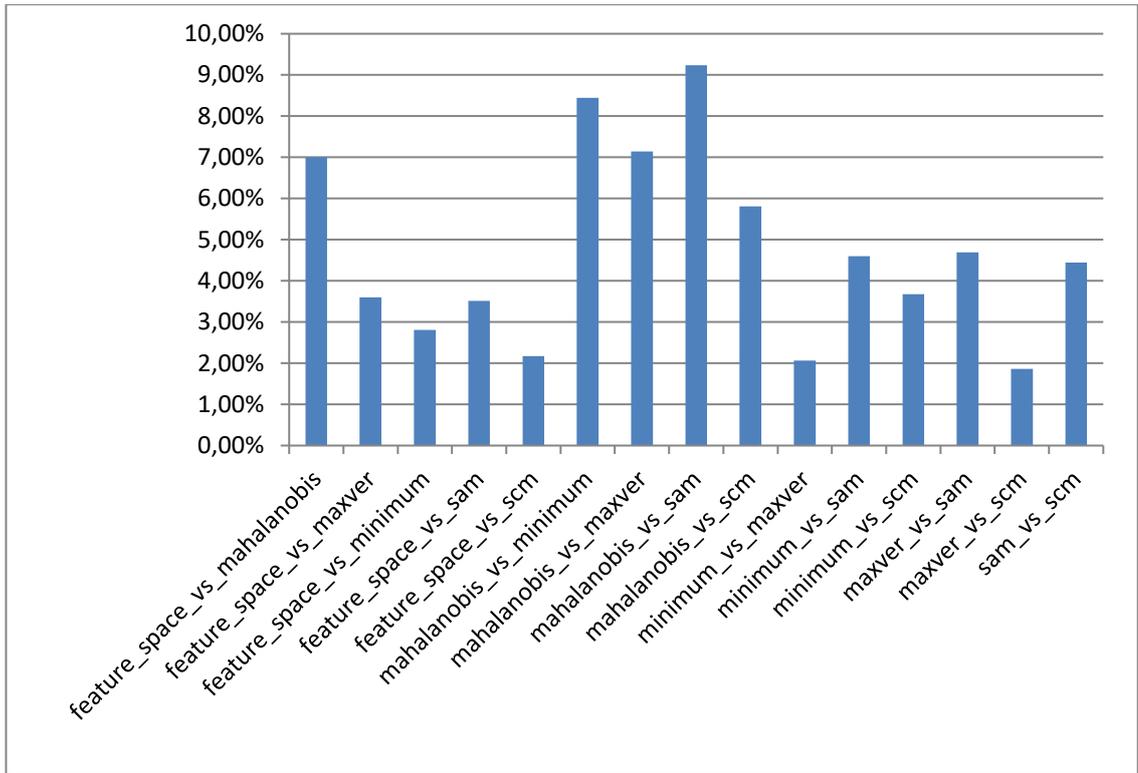
Gráfico 38 – Índice *Kappa* – PA Chacorore



Fonte: do Autor

O Gráfico 39 (*Image Difference*) confirma novamente os resultados obtidos nas análises do *Kappa* e da acurácia. Comparando o *Feature Space* com o SCM foi obtida uma variação de 2,17%. Já ao compará-lo com o Maxver foi obtida uma variação de 3,6%. Essa diferença na variação das comparações, apesar de ambos os métodos (SCM e Maxver) terem resultados iguais, pode ser explicada porque não necessariamente as classificações são as mesmas. O SAM comparado o *Feature Space* teve 3,51% e o comparando com o SCM alcançou 4,45%. Com relação ao SAM, o Maxver resultou em 4,69%.

Gráfico 39 – *Image Difference* – PA Chacorore

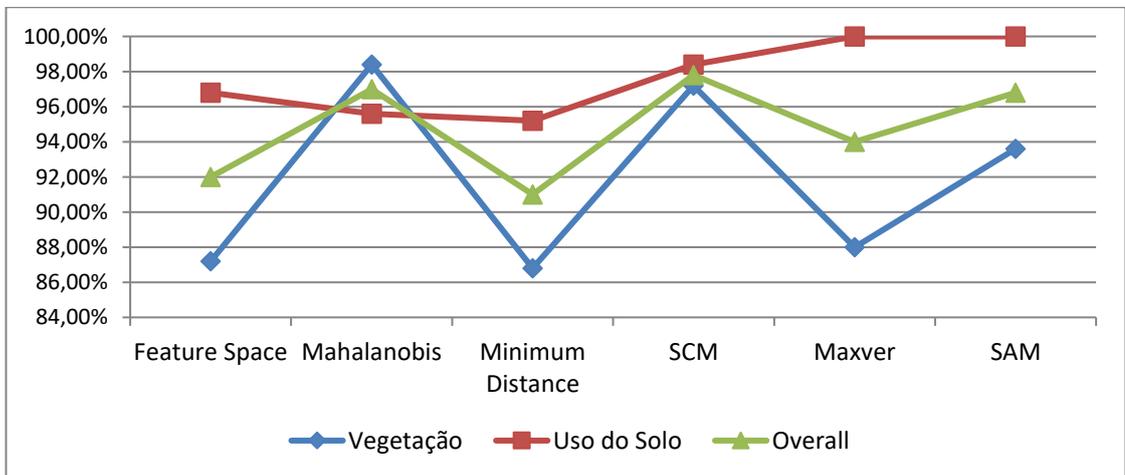


Fonte: do Autor

PA COTREL

No PA Cotrel, o SCM apresentou novamente o melhor resultado com 97,8% com apenas 1,2% de diferença ente as classes, o segundo melhor resultado foi o do *Mahalanobis* com 97% e uma variação de 2,8%, o terceiro melhor resultado foi o SAM com 96,8% e variando 6,4% em suas classes. (Gráfico 40)

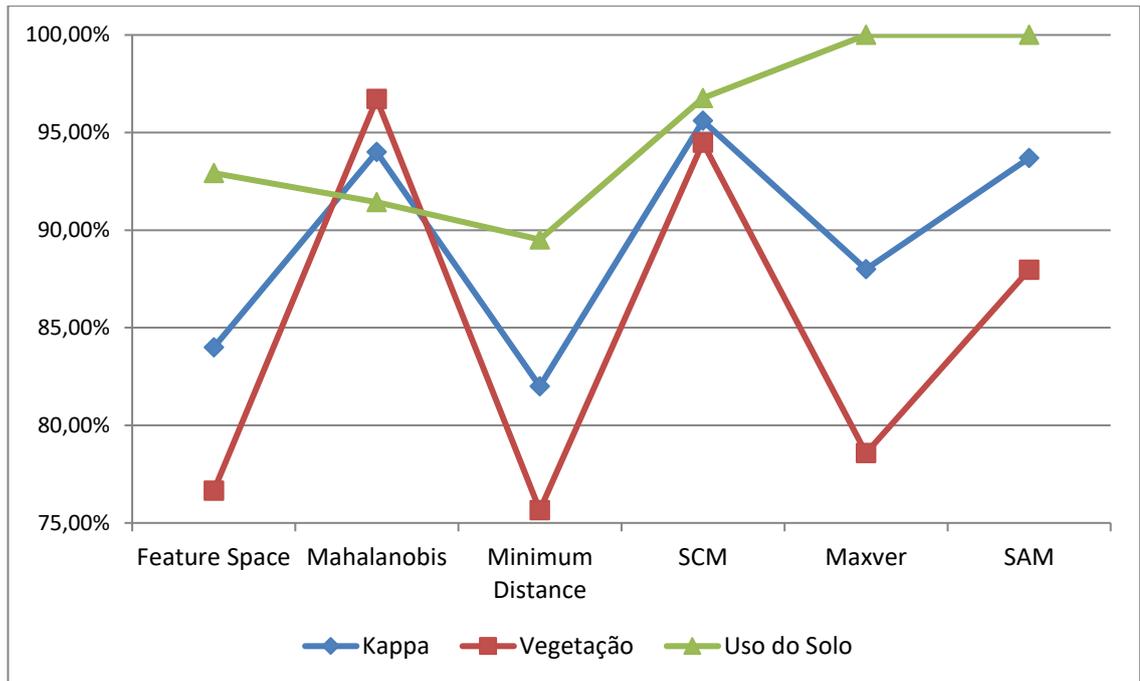
Gráfico 40 - *Accuracy Assessment* – PA Cotrel



Fonte: do Autor

No índice *Kappa*, foi mantida a proporção dos resultados obtidos no índice de acurácia. O SCM teve um índice *Kappa* de 95,6%, variando 2,29%; o *Mahalanobis* com um resultado *Kappa* de 94%, com uma variação de 5,27%; e o SAM com um resultado de 93,69% porém com uma variação de 12,03%. (Gráfico 41)

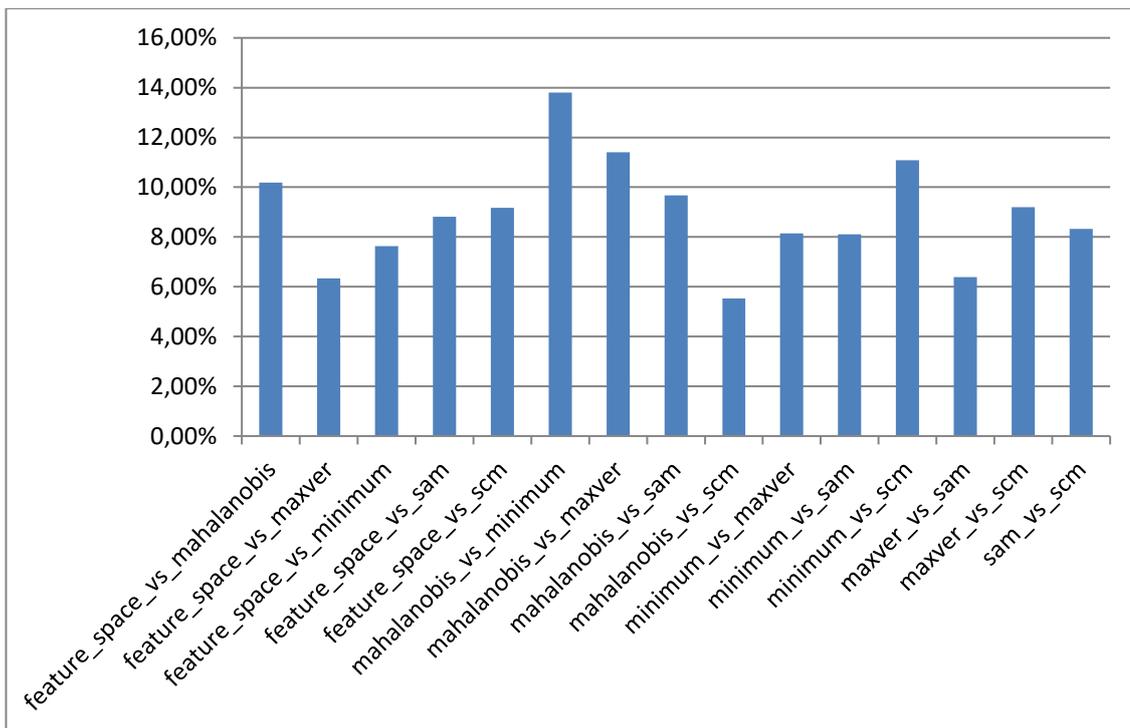
Gráfico 41 – Índice *Kappa* – PA Cotrel



Fonte: do Autor

O *Image Difference* comprovou os resultados obtidos, pois comparando o *Mahalanobis* com o SCM houve uma variação entre eles de 5,53%, a menor entre todas as comparações desse assentamento. Já comparando o SCM ao SAM obteve-se uma variação de 8,32%; e entre o *Mahalanobis* com o SAM houve uma variação de 9,67%. Essas variações podem ser explicadas devido aos valores que o SAM teve no Índice *Kappa* na classe de vegetação que foi um resultado ruim comparado ao SCM e *Mahalanobis* (Gráfico 42).

Gráfico 42 – *Image Difference* – PA Cotrel

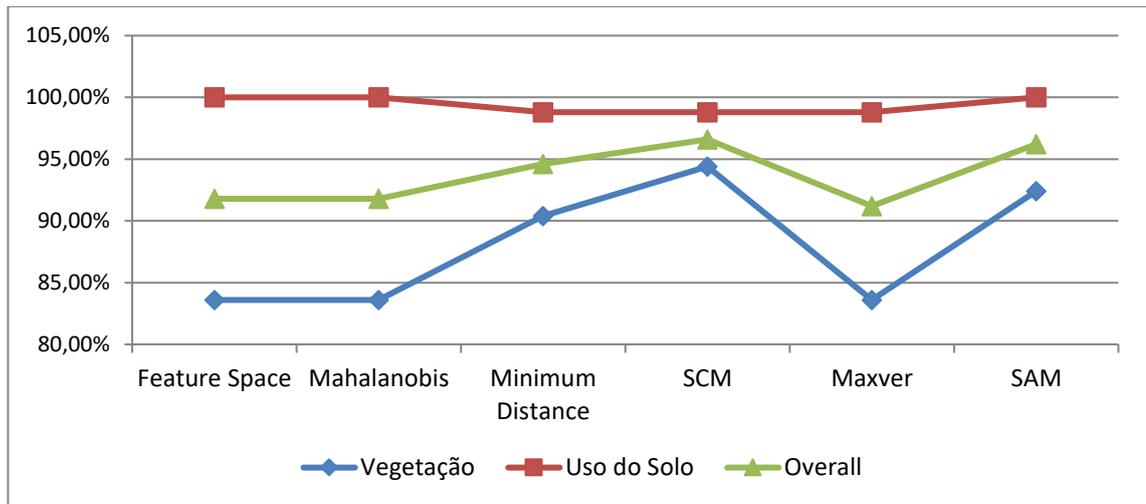


Fonte: do Autor

PA CRISTALINO

No PA Cristalino, a acurácia do SCM, mais uma vez, teve o melhor resultado, com um índice de 96,6% e uma variação de 4,4%, seguido dessa vez pelo SAM com 96,2% e uma variação de 7,6%. O terceiro melhor resultado foi o *Minimum Distance* com um resultado de 94,6% e uma variação de 8,4% (Gráfico 43)

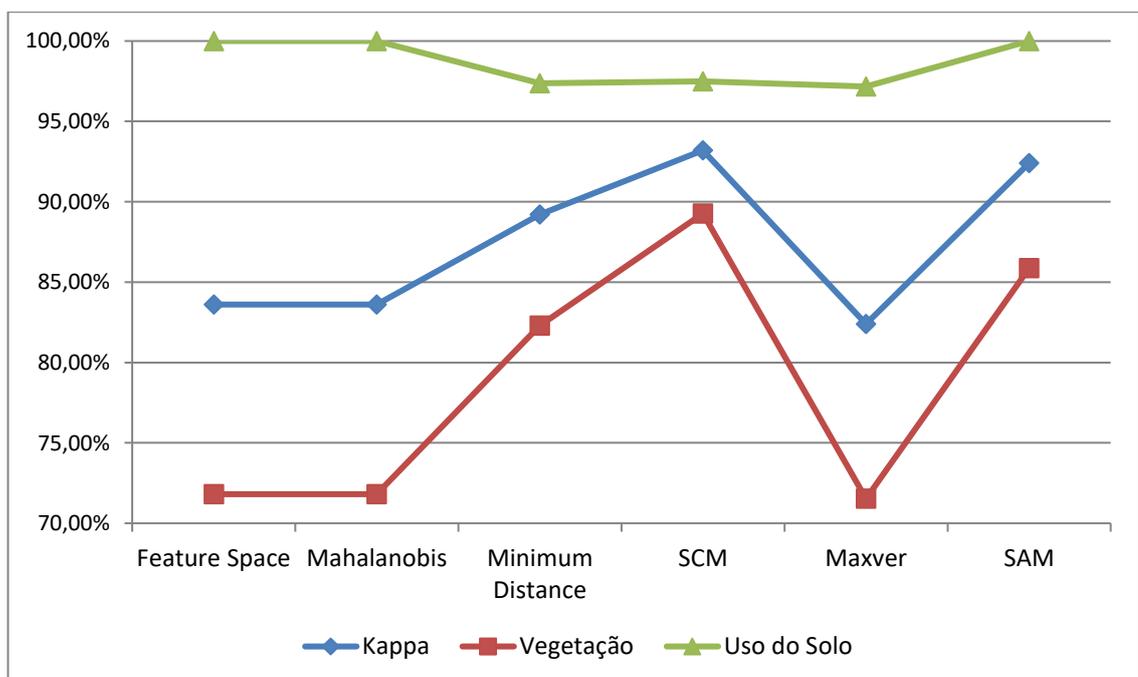
Gráfico 43- Accuracy Assessment – PA Cristalino



Fonte: do Autor

No Índice *Kappa*, as proporções se mantêm com pequenas variações nos resultados sem alterar a ordem. O SCM manteve-se como o melhor com um valor *Kappa* de 93,2% e uma variação de 8,22%. O SAM, com o segundo melhor resultado, atingiu um valor de 92,4%, com uma variação de 14,13%, entre suas classes. E o *Minimum Distance*, com o terceiro melhor resultado, teve um valor de 89,2% e uma variação de 15,11% (Gráfico 44).

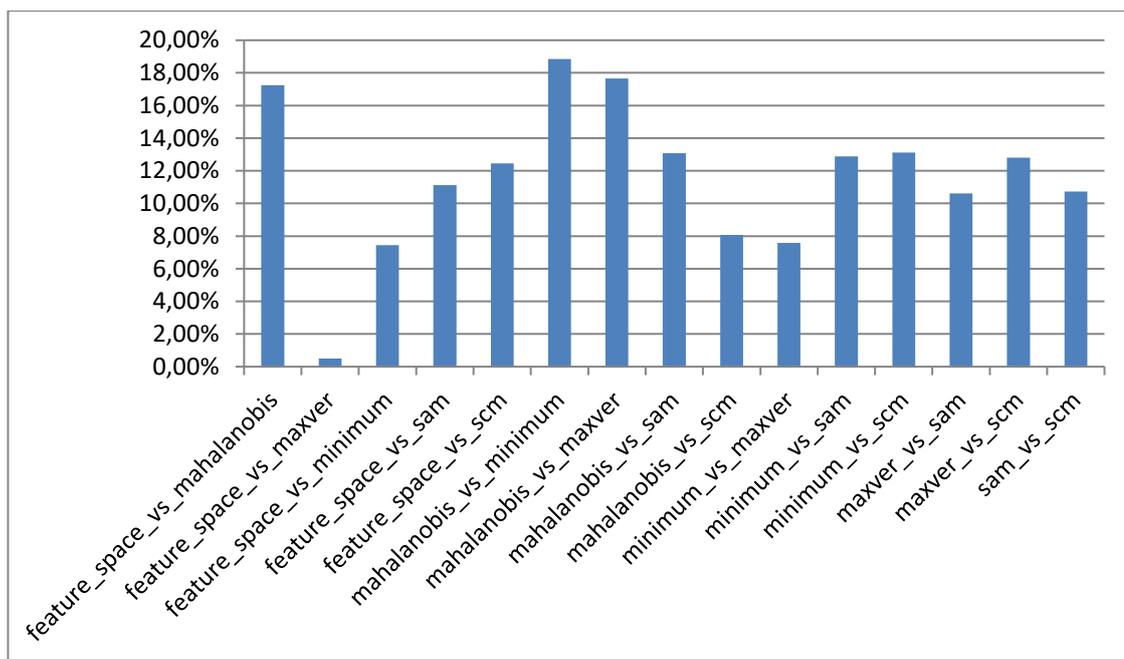
Gráfico 44– Índice Kappa – PA Cristalino



Fonte: do Autor

O Gráfico 45 (*Image Difference*) contribui para a comprovação dos resultados anteriores, porque mesmo que a comparação do SCM e do SAM tenha gerado um valor de 10,74%, ambos os métodos tiveram altos valores de variação entre as classes, o que explica essa diferença entre a comparação das classificações (Gráfico 45)

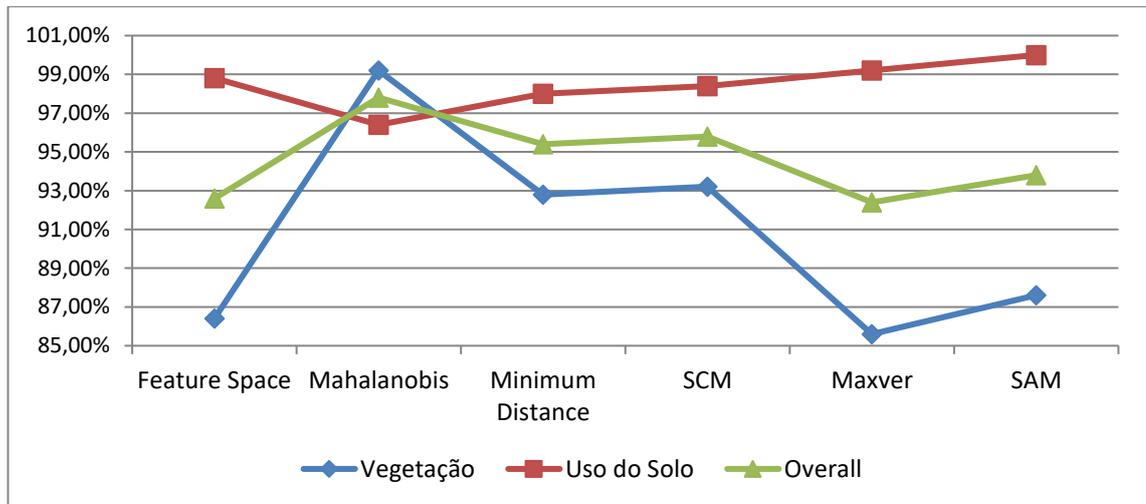
Gráfico -45– *Image Difference* – PA Cristalino



Fonte: do Autor

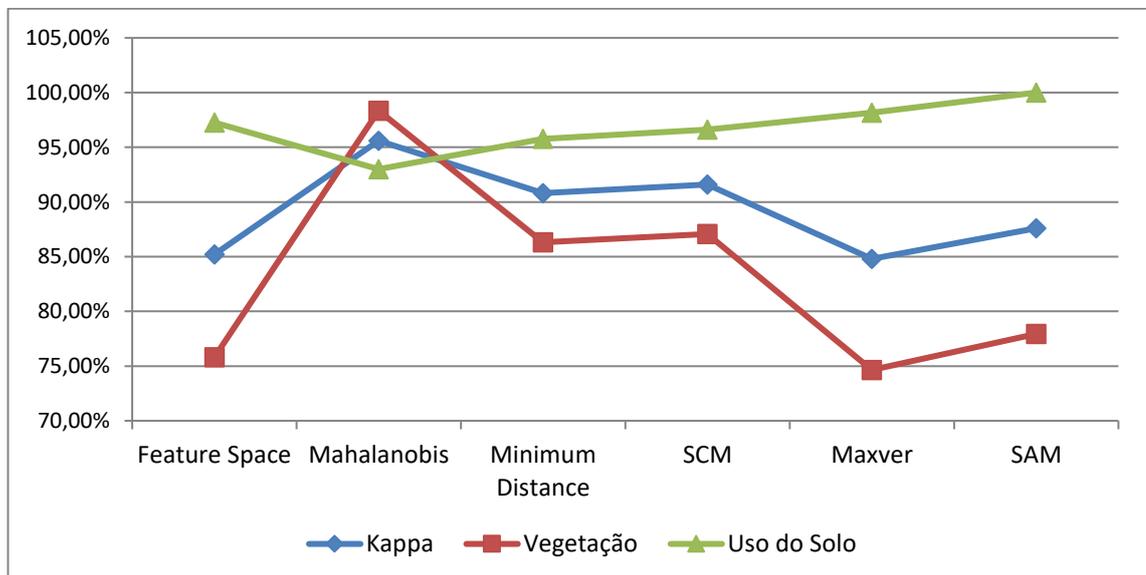
## PA CRISTALINO II

No PA Cristalino II, o *Mahalanobis* teve o melhor resultado no índice de acurácia geral com 97,8% e 2,8% de variação. O segundo melhor foi o SCM com 95,8% e variação de 4,8%. Na sequência, vem o *Minimum Distance* com 95,4% e 5,2% de variação. (Gráfico 46)

Gráfico 46 - *Accuracy Assessment* – PA Cristalino II

Fonte: do Autor

No Índice *Kappa*, as proporções foram mantidas sem alterar a ordem. O *Mahalanobis* com 95,6% e 5,35% de variação. O *SCM* com 91,6% e 9,55% de variação. E *Minimum Distance*, com 90,8% e 9,47% (Gráfico 47).

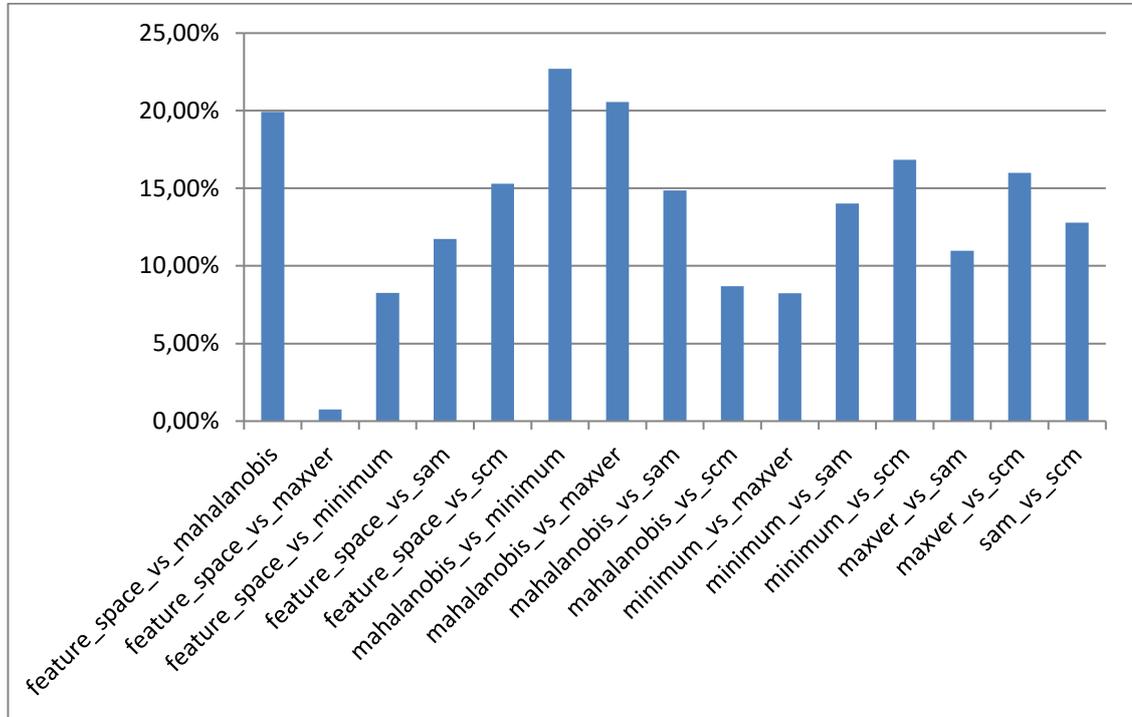
Gráfico 47 – Índice *Kappa* – PA Cristalino II

Fonte: do Autor

O *Image Difference* comprovou os resultados obtidos, pois comparando o *Mahalanobis* com o *SCM* houve uma variação entre eles de 8,7%. Tal variação pode ser explicada pela diferença de 11,28% existente na classe de vegetação de ambos. Já comparando o *Mahalanobis*

com o *Minimum Distance* obteve-se uma variação de 22,7%; e entre o *Minimum Distance* e o SCM houve uma variação de 16,83%. (Gráfico 48).

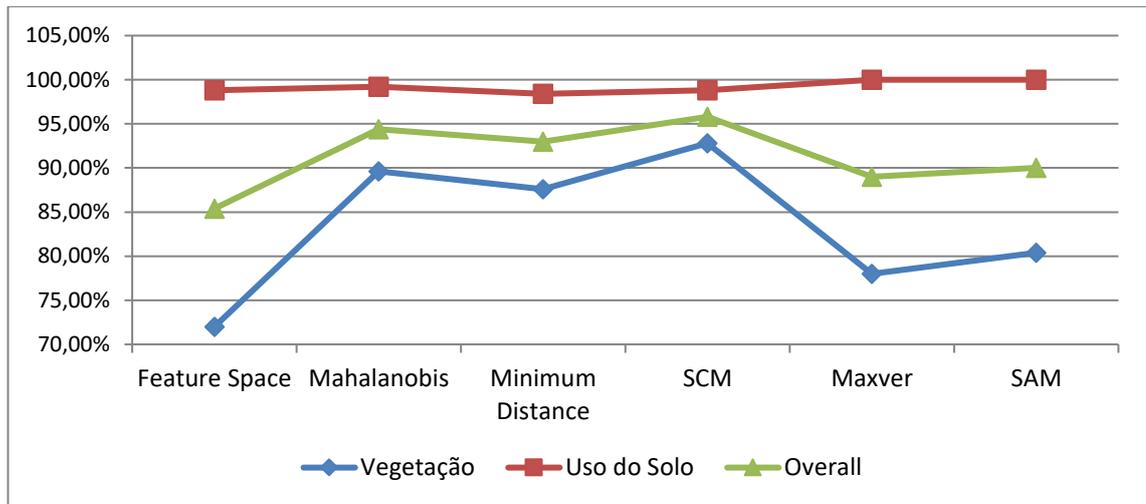
Gráfico 48 – *Image Difference* – PA Cristalino II



Fonte: do Autor

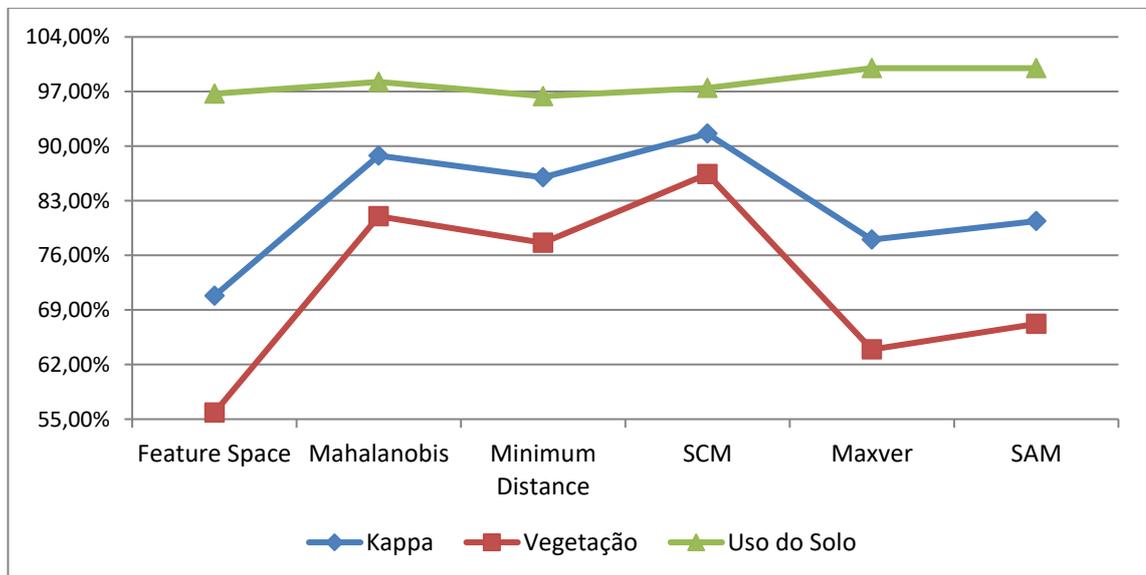
PA CRISTALINO IV

No PA Cristalino IV, o SCM obteve o melhor resultado com 95,8% de índice geral de acurácia e 6% de variação. O segundo melhor foi o *Mahalanobis* com 94,4% de índice geral e uma variação de 9,6%. Na sequência foi o *Minimum Distance* com uma resultado de 93% e uma variação de 10,8%. (Gráfico 49)

Gráfico 49 - *Accuracy Assessment* – PA Cristalino IV

Fonte: do Autor

No Índice *Kappa*, as posições se mantiveram, mas houve uma grande variação nos índices *Kappa*. O SCM com 91,6% de índice geral e uma variação de 11,03%. O *Mahalanobis* com 88,8% e 17,21% de variação. O *Minimum Distance* com 83% e 18,79% de variação. Essa grande variação se deve aos baixos resultados na classe de vegetação. (Gráfico 50)

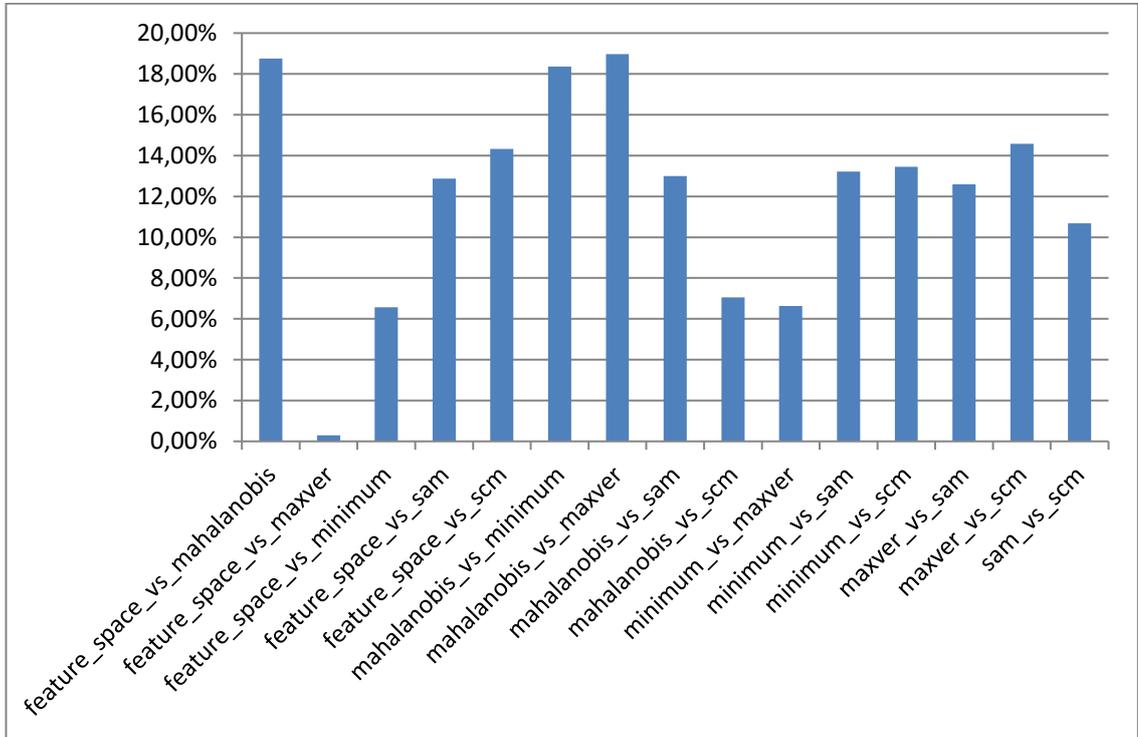
Gráfico 50 – Índice *Kappa* – PA Cristalino IV

Fonte: do Autor

O *Image Difference* comprovou os resultados obtidos, pois a comparação entre o SCM e o *Mahalanobis* apresentou uma diferença entre as classificações de 7,05%. Tal variação pode ser explicada pela diferença nos resultados na classe de vegetação de ambos. Já comparando o

SCM com o *Minimum Distance* obteve-se uma variação de 13,45%; e entre o *Mahalanobis* e o *Minimum Distance* houve uma variação de 18,98%. (Gráfico 51).

Gráfico 51 – *Image Difference* – PA Cristalino IV

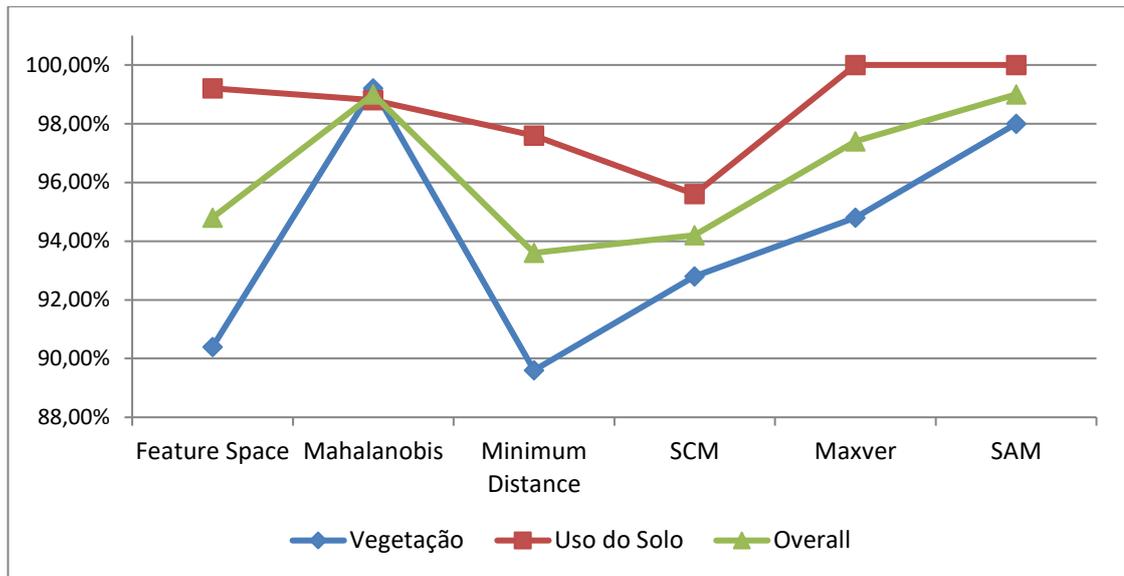


Fonte: do Autor

PA ETA

No PA ETA, o *Mahalanobis* e o SAM tiveram os melhores resultados na acurácia com 99%, sendo que o *Mahalanobis* teve uma variação de 0,4% e o SAM de 2%. O Maxver obteve 97,4% de acurácia e uma variação de 5,2%. (Gráfico 52)

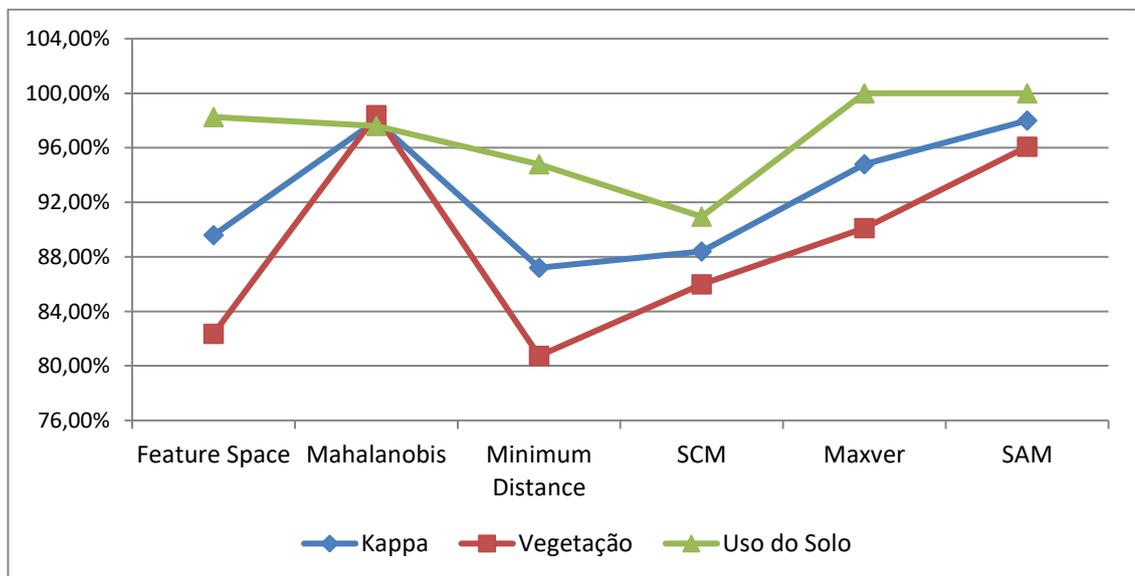
Gráfico 52 - Accuracy Assessment – PA ETA



Fonte: do Autor

No Índice *Kappa*, o *Mahalanobis* e o *SAM* continuam empatados com 98%, sendo que o *Mahalanobis* teve uma variação de 0,78% e o *SAM* de 3,92%. O *Maxver* teve 94,8%, com variação de 9,89%. (Gráfico 53)

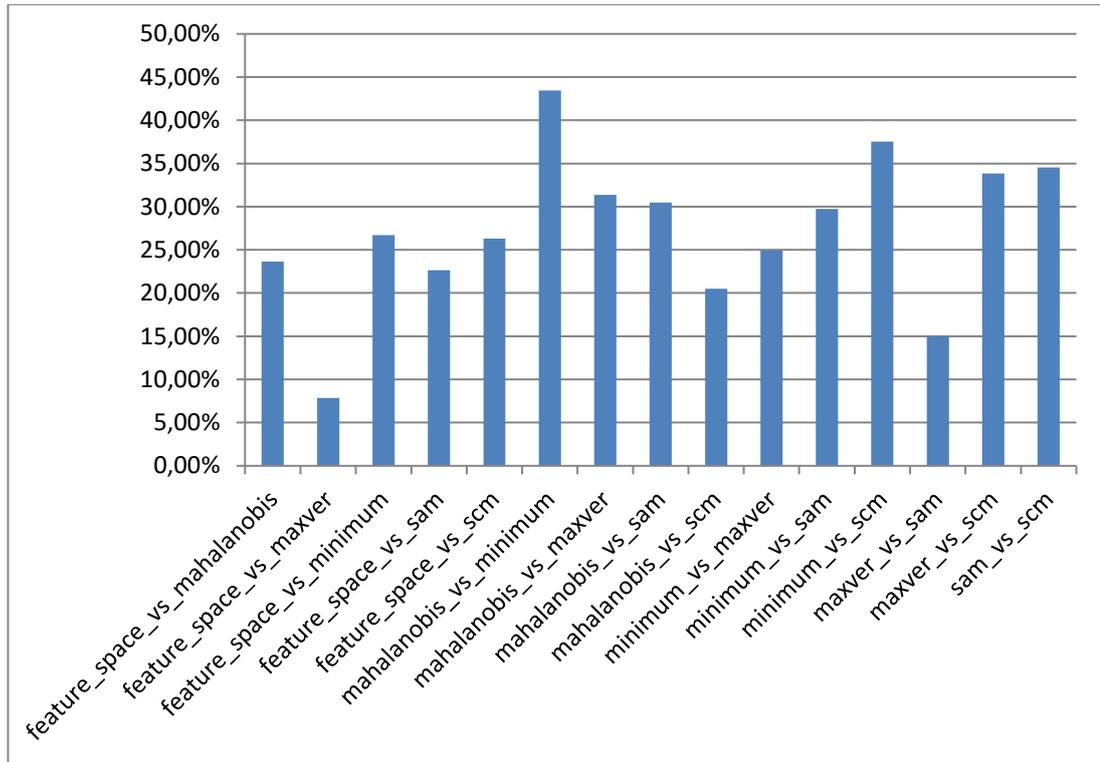
Gráfico 53 – Índice Kappa – PA ETA



Fonte: do Autor

O Gráfico 54 (*Image Difference*) não corrobora com os resultados anteriores. Exemplo disso, é a diferença das classificações entre o *Mahalanobis* e o *SAM* de 30,49%.

Gráfico 54 – Image Difference – PA ETA

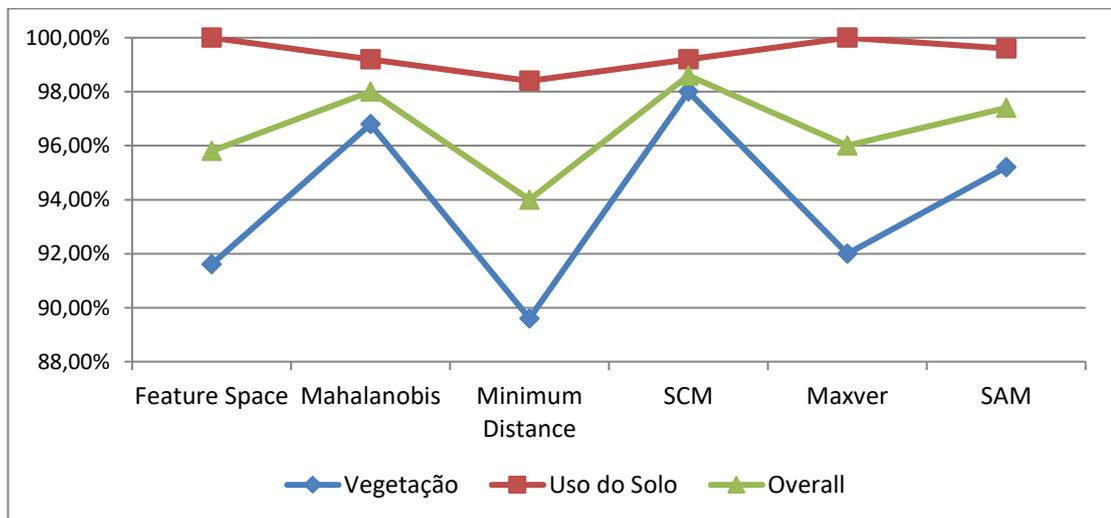


Fonte: do Autor

PA HORIZONTE II

No PA Horizonte II, o SCM obteve o melhor resultado com 98,6% de acurácia e uma variação de 1,2%. O Mahalanobis obteve 98% e 2,4%. O SAM, obteve o terceiro resultado, com 97,4% e variação de 4,4%. (Gráfico 55)

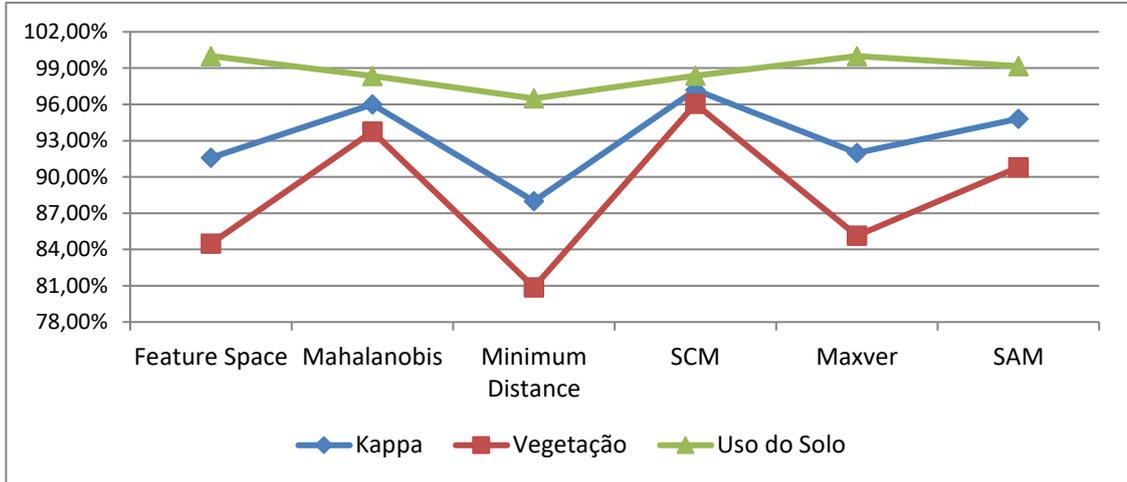
Gráfico 55 - Accuracy Assessment – PA Horizonte II



Fonte: do Autor

No Gráfico 56, as posições se mantiveram, com o SCM tendo um índice de 97,2% e uma variação de 2,33%. O Mahalanobis teve 96% e 4,39%, e o SAM teve 94,8% com uma variação de 8,36%. A classe de vegetação foi a que teve menor resultado para os três métodos.

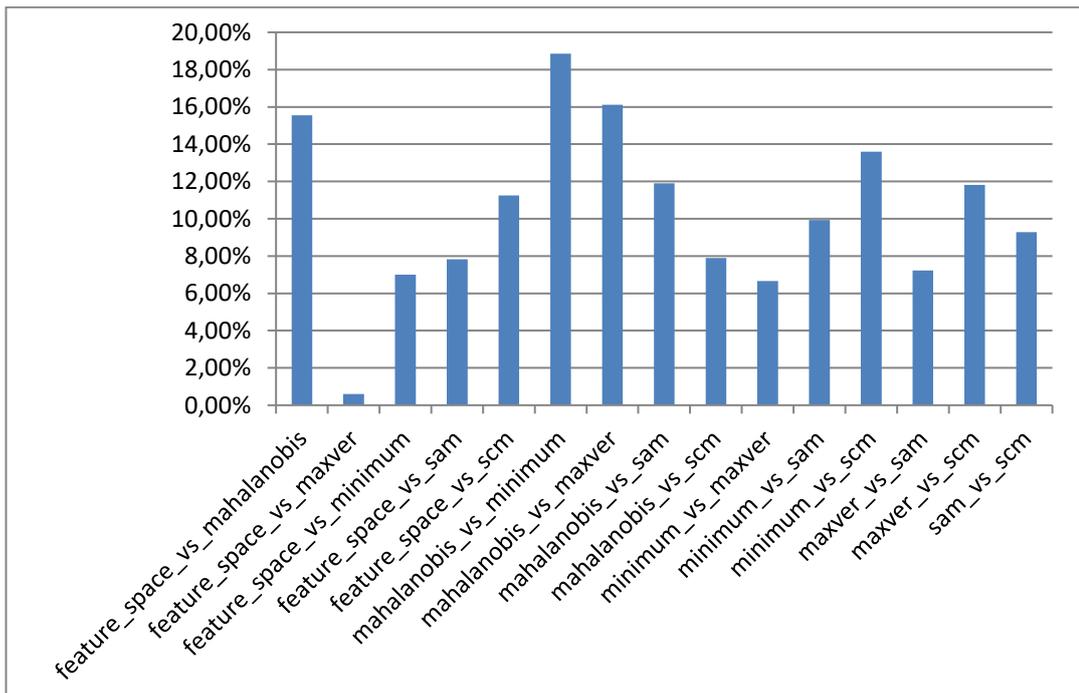
Gráfico 56 – Índice Kappa – PA Horizonte II



Fonte: do Autor

O Image Difference (Gráfico 57) confirma os resultados, pois ao se comparar o SCM com o Mahalanobis constatou-se uma diferença de 7,89%, comparando o SCM com o SAM 9,29%; e o Mahalanobis com o SAM 11,9%.

Gráfico 57 – Image Difference – PA Horizonte II

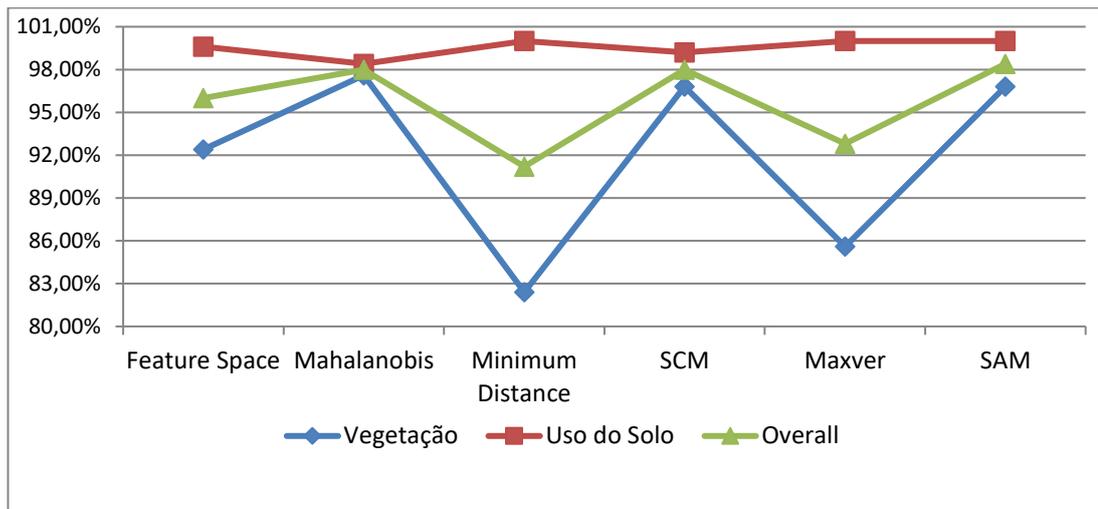


Fonte: do Autor

## PA IRIRIZINHO

No PA Iririzinho, o SAM teve o melhor resultado com 98,4% e uma variação de 3,2%. *Mahalanobis* e SCM obtiveram os mesmos resultados em acurácia com 98%, sendo que o *Mahalanobis* teve uma diferença de 0,8% e o SCM 2,4%. (Gráfico 58)

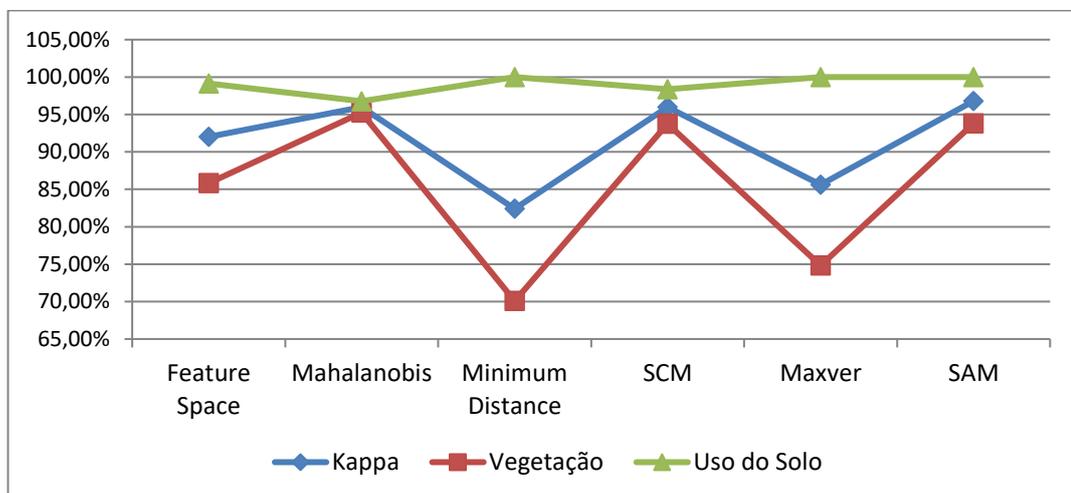
Gráfico 58 - Accuracy Assessment – PA Iririzinho



Fonte: do Autor

No Gráfico 59 (Índice *Kappa*), as posições foram mantidas, com o SAM tendo 96,8% e uma variação de 6,2%, o *Mahalanobis* e o SCM com 96%, sendo que o primeiro teve uma variação de 1,53% e o SCM, 4,61%. A classe com menores resultados foi, novamente, a vegetação.

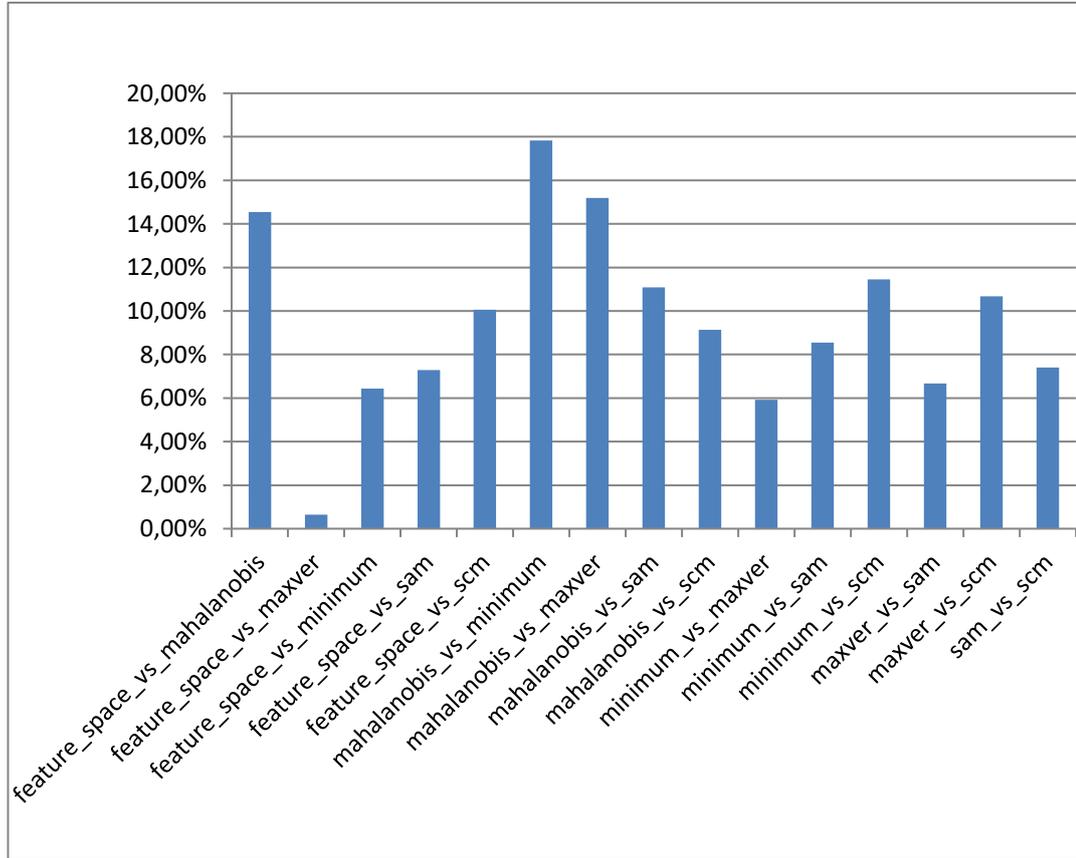
Gráfico 59 – Índice *Kappa* – PA Iririzinho



Fonte: do Autor

O *Image Difference* comprovou os resultados anteriores, pois ao se comparar o SAM com o SCM obteve-se uma diferença de 7,4%, o *Mahalanobis* com o SCM 9,13%, e o *Mahalanobis* com o SAM 11,9%.

Gráfico 60 – *Image Difference* – PA Iririzinho



Fonte: do Autor

## 8. DISCUSSÃO

Para consolidar as informações obtidas pelos Gráficos de 1 a 60, foram produzidas as Tabelas 5, 6, 7 e 8, reunindo os dados de acurácia; do *Kappa*; da diferença entre as classes da acurácia; e do *Kappa* de todos os assentamentos. Como as duas primeiras tabelas demonstraram uma predominância dos métodos *Mahalanobis*, *SCM* e *SAM*, foram produzidos os Gráficos 61 e 62 com as médias das quatro tabelas anteriores (5, 6, 7 e 8), para confirmar tal achado. Nas Tabelas 7 e 8, o *SAM* não demonstrou os melhores resultados, porém devido aos valores obtidos (Tabelas 5 e 6), ele foi considerado para as análises posteriores. É importante destacar que nas tabelas 7 e 8 e no Gráfico 62 quanto menor o resultado, melhor o desempenho do método, pois quanto menor a diferença entre as classes mais consistente foi a classificação. Nas Tabelas 5 e 6 estão destacados, com a célula na cor cinza, os métodos de classificação com os maiores valores. Já nas Tabelas 7 e 8, estão destacados os menores valores, pois são os que indicam os melhores resultados.

Tabela 5 – Resultados gerais da acurácia em todos os assentamentos

<b>Assentamento</b>	<b><i>Feature Space</i></b>	<b><i>Mahalanobis</i></b>	<b><i>Minimum Distance</i></b>	<b>SCM</b>	<b>Maxver</b>	<b>SAM</b>
PA Aliança	96,00%	95,00%	96,00%	95,80%	97,00%	97,40%
PA Alto Paraíso	94,20%	96,80%	94,20%	97,00%	96,20%	97,00%
PA Araúna	94,80%	97,00%	95,20%	96,40%	91,40%	97,80%
PA Araúna II	95,00%	97,40%	93,60%	97,60%	94,60%	97,40%
PA Barra Norte	96,80%	99,80%	96,00%	99,40%	96,20%	96,20%
PA Bela Vista	96,00%	98,20%	95,20%	96,20%	96,20%	98,00%
PA Belmonte	95,80%	97,60%	92,00%	96,20%	96,80%	98,00%
PA Bonjagua	96,40%	99,40%	97,00%	95,00%	98,20%	98,00%
PA Cachimbo II	95,80%	95,00%	93,00%	93,60%	98,20%	97,40%
PA Cachoeira da União	95,00%	99,00%	94,60%	95,00%	97,00%	96,20%
PA Castanhal	89,00%	97,60%	93,00%	96,80%	93,40%	96,60%
PA Cedro Rosa	98,20%	97,80%	94,60%	99,60%	99,40%	98,60%
PA Chacorore	98,80%	97,80%	97,80%	98,40%	98,40%	97,60%
PA Cotrel	92,00%	97,00%	91,00%	97,80%	94,00%	96,80%
PA Cristalino	91,80%	91,80%	94,60%	96,60%	91,20%	96,20%
PA Cristalino II	92,60%	97,80%	95,40%	95,80%	92,40%	93,80%
PA Cristalino IV	85,40%	94,40%	93,00%	95,80%	89,00%	90,00%
PA Eta	94,80%	99,00%	93,60%	94,20%	97,40%	99,00%
PA Horizonte II	95,80%	98,00%	94,00%	98,60%	96,00%	97,40%
PA Iririzinho	96,00%	98,00%	91,20%	98,00%	92,80%	98,40%

Fonte: do Autor

Tabela 6 – Resultados gerais do Índice *Kappa* em todos os assentamentos

<b>Assentamento</b>	<b><i>Feature Space</i></b>	<b><i>Mahalanobis</i></b>	<b><i>Minimum Distance</i></b>	<b>SCM</b>	<b>Maxver</b>	<b>SAM</b>
PA Aliança	92,00%	90,00%	92,00%	91,60%	94,80%	91,60%
PA Alto Paraíso	88,00%	93,60%	88,40%	94,00%	94,80%	96,00%
PA Araúna	89,60%	94,00%	90,40%	92,80%	84,13%	95,60%
PA Araúna II	90,00%	94,80%	87,20%	95,20%	89,75%	94,92%
PA Barra Norte	93,60%	99,60%	92,00%	98,80%	93,20%	92,66%
PA Bela Vista	92,00%	96,40%	90,40%	92,40%	92,66%	96,00%
PA Belmonte	91,60%	95,20%	84,00%	92,40%	93,60%	96,00%
PA Bonjagua	92,80%	88,00%	94,00%	90,00%	96,45%	94,80%
PA Cachimbo II	91,60%	90,00%	86,00%	85,16%	96,45%	94,80%
PA Cachoeira da União	90,00%	98,00%	89,20%	90,00%	94,00%	92,40%
PA Castanhal	78,00%	95,20%	86,00%	93,60%	87,62%	93,20%
PA Cedro Rosa	96,40%	95,60%	89,20%	99,20%	98,81%	97,20%
PA Chacorore	97,60%	95,60%	95,60%	96,80%	96,80%	95,20%
PA Cotrel	84,00%	94,00%	82,00%	95,60%	88,00%	93,69%
PA Cristalino	83,60%	83,60%	89,20%	93,20%	82,40%	92,40%
PA Cristalino II	85,20%	95,60%	90,80%	91,60%	84,80%	87,60%
PA Cristalino IV	70,80%	88,80%	86,00%	91,60%	78,00%	80,40%
PA Eta	89,60%	98,00%	87,20%	88,40%	94,80%	98,00%
PA Horizonte II	91,60%	96,00%	88,00%	97,20%	92,00%	94,80%
PA Iririzinho	92,00%	96,00%	82,40%	96,00%	85,63%	96,80%

Fonte: do Autor

Tabela 7 – Variação dos resultados da acurácia nas classes em todos os assentamentos

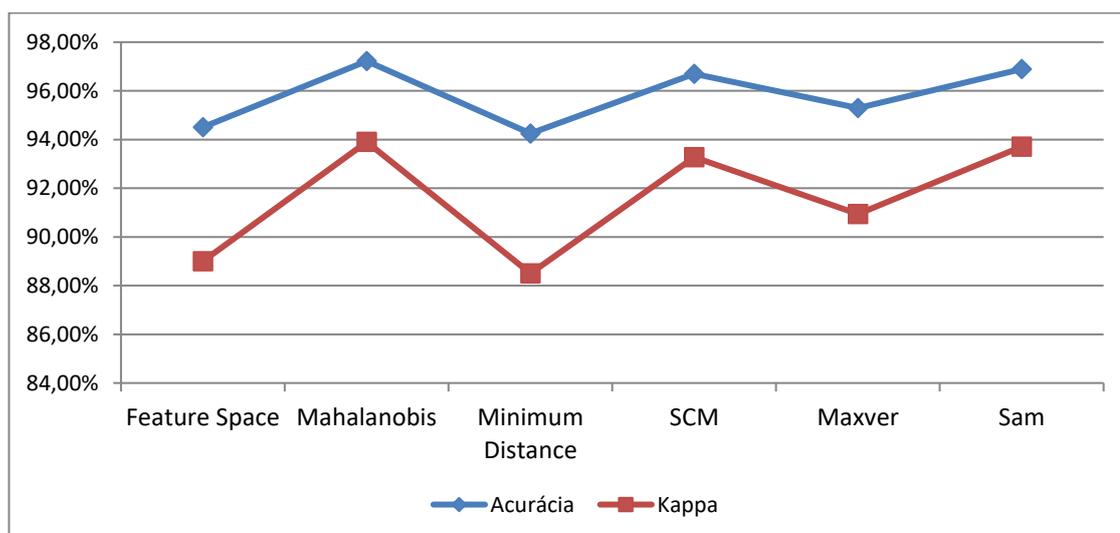
<b>Assentamento</b>	<b><i>Feature Space</i></b>	<b><i>Mahalanobis</i></b>	<b><i>Minimum Distance</i></b>	<b>SCM</b>	<b>Maxver</b>	<b>SAM</b>
PA Aliança	2,40%	5,20%	0,80%	2,00%	2,80%	6,00%
PA Alto Paraíso	0,40%	4,80%	0,40%	3,60%	6,80%	2,00%
PA Araúna	6,40%	2,00%	0,80%	0,00%	16,40%	4,40%
PA Araúna II	3,60%	0,40%	1,60%	0,00%	10,80%	4,40%
PA Barra Norte	5,60%	0,40%	3,20%	0,40%	7,20%	6,80%
PA Bela Vista	1,60%	0,40%	4,00%	1,20%	6,80%	3,20%
PA Belmonte	6,80%	2,40%	13,60%	6,00%	6,40%	4,00%
PA Bonjagua	2,40%	0,40%	2,00%	5,20%	2,00%	4,40%
PA Cachimbo II	2,80%	10,00%	9,20%	2,40%	2,00%	5,20%
PA Cachoeira da União	7,60%	1,20%	3,60%	4,40%	2,80%	6,80%
PA Castanhal	21,20%	2,40%	11,60%	1,60%	13,20%	6,80%
PA Cedro Rosa	2,80%	4,40%	10,80%	0,80%	1,20%	2,80%
PA Chacorore	2,40%	4,40%	3,00%	2,40%	2,40%	4,80%
PA Cotrel	9,60%	2,80%	8,40%	1,20%	12,00%	6,40%
PA Cristalino	16,40%	16,40%	8,40%	4,40%	15,20%	7,60%
PA Cristalino II	12,40%	2,80%	5,20%	5,20%	13,60%	12,40%
PA Cristalino IV	26,80%	9,60%	10,80%	6,00%	22,00%	19,60%
PA Eta	8,80%	0,40%	8,00%	2,80%	5,20%	2,00%
PA Horizonte II	4,20%	1,20%	4,40%	0,60%	4,00%	2,20%
PA Iririzinho	7,20%	0,80%	17,60%	2,40%	14,40%	3,20%

Fonte: do Autor

Tabela 8 - Variação dos resultados do Índice *Kappa* nas classes em todos os assentamentos

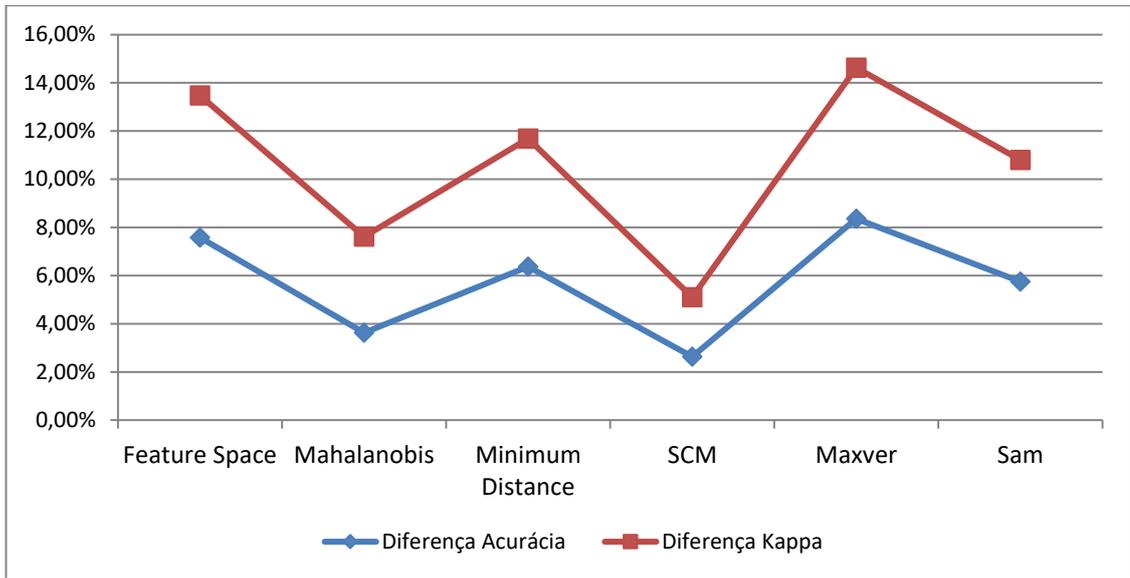
Assentamento	<i>Feature Space</i>	<i>Mahalanobis</i>	<i>Minimum Distance</i>	SCM	Maxver	SAM
PA Aliança	4,42%	9,39%	1,47%	3,67%	0,76%	8,08%
PA Alto Paraiso	1,41%	9,01%	0,71%	6,78%	8,36%	6,15%
PA Araúna	11,52%	3,76%	1,45%	0,00%	28,07%	8,43%
PA Araúna II	6,49%	0,76%	2,79%	0,00%	19,49%	8,40%
PA Barra Norte	10,51%	0,80%	7,37%	0,79%	11,23%	12,68%
PA Bela Vista	2,95%	0,77%	7,25%	2,22%	12,68%	6,15%
PA Belmonte	12,51%	4,57%	23,28%	11,13%	12,03%	7,69%
PA Bonjagua	4,45%	18,50%	3,76%	9,39%	3,90%	8,89%
PA Cachimbo II	5,13%	18,18%	15,96%	7,86%	3,90%	9,89%
PA Cachoeira da União	13,76%	2,35%	6,43%	7,93%	5,27%	12,62%
PA Castanhal	34,62%	4,57%	20,23%	2,99%	23,32%	12,73%
PA Cedro Rosa	5,41%	8,43%	19,49%	1,59%	2,37%	5,45%
PA Chacorore	4,69%	8,43%	6,89%	4,65%	4,65%	9,16%
PA Cotrel	16,28%	5,27%	13,87%	2,29%	21,43%	12,03%
PA Cristalino	28,18%	28,18%	15,09%	8,22%	25,64%	14,13%
PA Cristalino II	21,46%	5,35%	9,47%	9,55%	23,50%	22,06%
PA Cristalino IV	40,88%	17,21%	18,79%	11,03%	36,07%	32,78%
PA Eta	15,90%	0,78%	14,04%	4,96%	9,89%	3,92%
PA Horizonte II	15,50%	4,61%	15,61%	2,33%	14,85%	8,36%
PA Iririzinho	13,32%	1,53%	29,93%	4,61%	25,17%	6,20%

Fonte: do Autor

Gráfico 61 – Média da acurácia e do Índice *Kappa*, por método de classificação

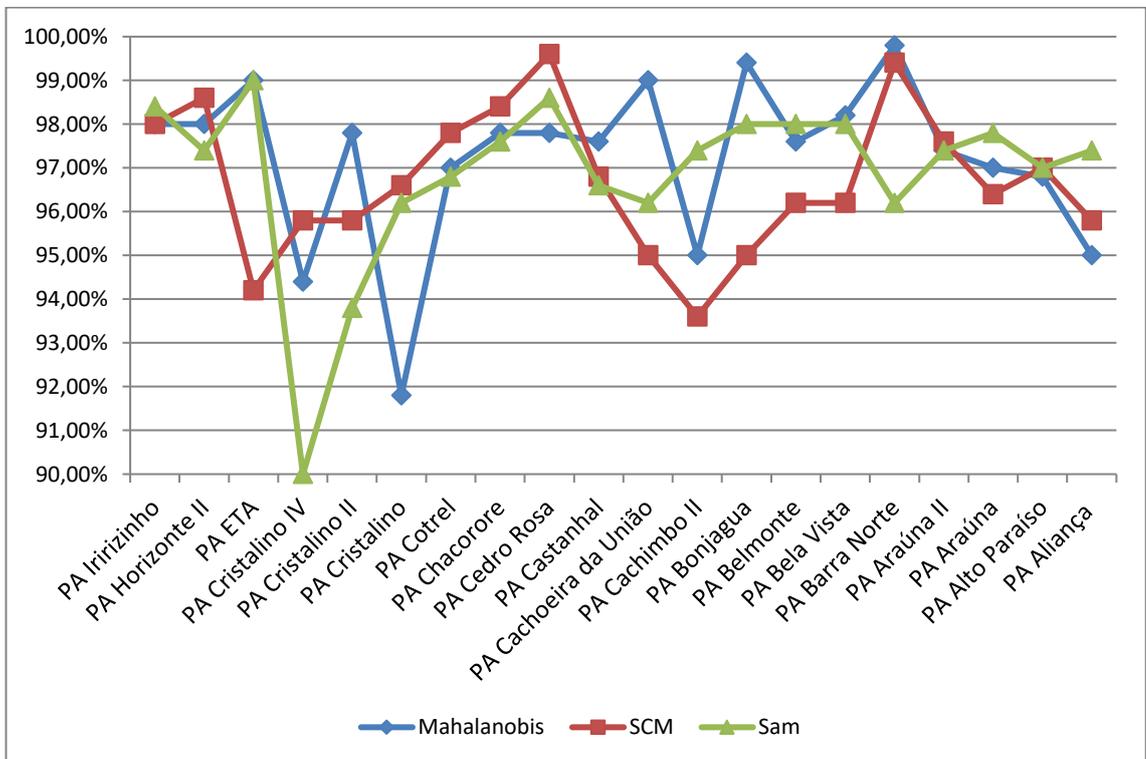
Fonte: do Autor

Gráfico 62 – Média da diferença da acurácia e do Índice *Kappa* nas classes, por método de classificação



Fonte: do Autor

Gráfico 63 – Resultado da acurácia dos três melhores métodos de classificação



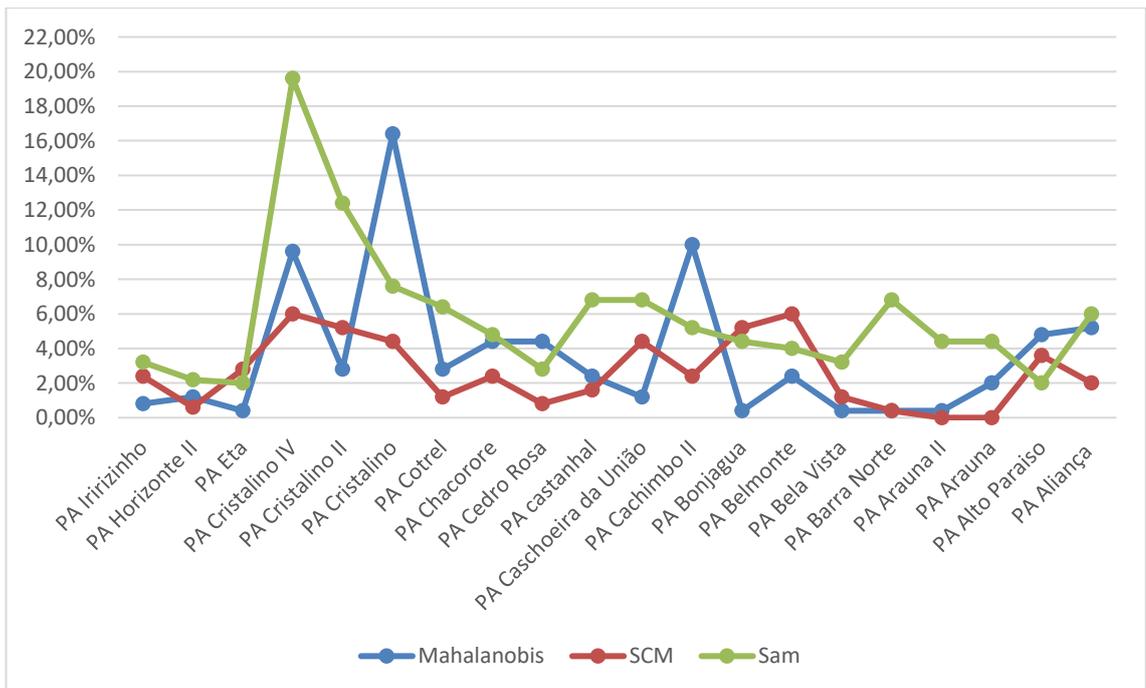
Fonte: do Autor

Gráfico 64 – Resultado do Índice *Kappa* dos três melhores métodos de classificação

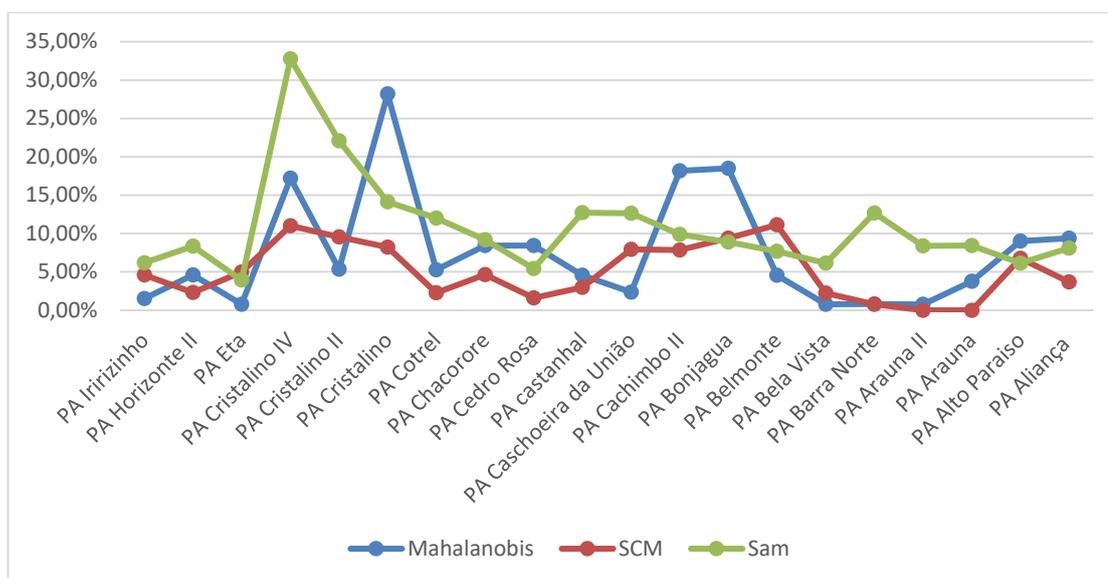


Fonte: do Autor

Gráfico 65 – Diferença da acurácia nas classes dos três melhores métodos de classificação



Fonte: do Autor

Gráfico 66 – Diferença do Índice *Kappa* nas classes dos três melhores métodos de classificação

Fonte: do Autor

Com a análise dos Gráficos 61 e 62, comprovou-se que os três métodos citados (*Mahalanobis*, SCM e SAM) obtiveram melhores resultados que os demais. Mesmo assim, ainda não foi possível afirmar qual entre os três se sobressaiu. Para extrair tal informação, foram construídos Gráficos com os valores brutos de acurácia (Gráfico 63) e Índice *Kappa* (Gráfico 64), bem como com as diferenças nas classes (Gráficos 65 e 66).

No Gráfico 63, os três métodos tiveram sete melhores resultados no Índice de acurácia, sendo que SCM e SAM empataram no PA Alto Paraíso com 97%. Porém, o *Mahalanobis* atingiu a melhor média entre todos os assentamentos com 97,22% (Gráfico 61). O SAM obteve 96,89% e o SCM, 96,69%.

O SCM e SAM obtiveram os oito melhores resultados no *Kappa*, empatando no PA Aliança, com 91,6%. O *Mahalanobis* teve seis melhores resultados, empatando com o SAM, no PA ETA, com 98% (Gráfico 64). Analisando o Gráfico 61, o *Mahalanobis* teve a melhor média com 93,9%, seguido do SAM com 93,7% e o SCM com 93,28%.

No Gráfico 65, o SCM apresentou doze dos melhores resultados, o *Mahalanobis* oito dos melhores, empatando com o SCM no PA Barra Norte, com 0,4 de diferença de acurácia nas classes; e o SAM teve um melhor resultado. O Gráfico 62 demonstrou que o SCM teve a melhor média de 2,63%, o *Mahalanobis* com 3,62% e o SAM com 5,75%.

No Gráfico 66, o SCM obteve doze dos melhores resultados, o *Mahalanobis* seis e o SAM apenas 2. Analisando o Gráfico 62, observou-se que o SCM obteve a melhor média (5,10%), o *Mahalanobis* teve 7,62% e o SAM, 10,79%.

Analisando as variações dos resultados do Gráfico 61, observou-se que as diferenças dos resultados da acurácia entre o *Mahalanobis* e o SAM foi 0,33%, a do *Mahalanobis* com o SCM foi de 0,53, e a do SAM com o SCM foi de 0,2%. Esses valores demonstram que todos os métodos tiveram médias muito próximas e se o trabalho se baseasse apenas nessa variável, não seria possível determinar qual o melhor método.

Prosseguindo as análises, na avaliação das médias dos resultados do Índice *Kappa*, comparando o *Mahalanobis* com o SAM, que tiveram os melhores resultados, houve uma diferença de 0,2%; comparando o *Mahalanobis* com o SCM obteve-se uma variação de 0,62%; e o SCM ao SAM, 0,42%. As diferenças das médias permanecem pequenas entre si.

Comparando os resultados do Gráfico 62, constatou-se que a variação da média dos resultados de acurácia nas classes entre o SCM e o *Mahalanobis* foi de 0,99%, entre o SCM e o SAM de 3,12%, e entre *Mahalanobis* e SAM de 3,62%. Essas diferenças são mais expressivas, porque ao se subtrair as duas classes tem-se um resultado que elimina possíveis erros do índice geral. As análises do CAR necessitam de dados consistentes em cada classe para mensurar o uso e a ocupação do solo. Assim, o resultado do SCM de 2,63%, apresentado anteriormente, é o mais significativo dentre os três.

Analisando as diferenças das médias das variações do *Kappa* nas classes (vegetação e área antropizada), novamente o SCM obteve o melhor resultado, com 5,10%. Comparando o SCM com o *Mahalanobis* tem-se uma diferença de 2,52%; comparando o SCM ao SAM, 5,69%; e o *Mahalanobis* ao SAM, 5,69%. Novamente, a diferença entre os métodos foram expressivas e o SCM destacou-se.

Os resultados alcançados neste trabalho foram comparados aos encontrados na literatura, para validar os Índices *Kappa* e os valores de acurácia, obtidos nos três métodos com melhores resultados, *Mahalanobis*, SAM e SCM, além do Maxver que, embora, não tenha alcançado resultados significativos, é um dos métodos mais difundido na literatura, neste tipo de análise, principalmente considerando a aplicação no *Sentinel-2*.

Os resultados encontrados para o Índice *Kappa* no *Mahalanobis*, neste trabalho, foram de 83,6% no PA Cristalino, sendo o menor *Kappa*, e 99,6%, como maior, no PA Barra Norte, com uma média de 93,9%. Como não foram encontradas na literatura pesquisas referentes à aplicação do *Mahalanobis* no *Sentinel-2*, a comparação será realizada com base em artigos que utilizaram outros satélites. Em Cattani et al., (2013), realizado no município de Cascavel/ PR/

Brasil, utilizando cenas do *Rapideye* obteve-se um Índice *Kappa* de 91,81%. Em Ustuner et al. (2016), aplicando também o *Rapideye*, em uma área de agricultura da Turquia, atingiu-se o resultado para o Índice *Kappa* do *Mahalanobis* de 72,76%. Em Masse,(2013), utilizando cenas do SPOT -5 (2007), *Landsat 5* (2010), *Formosat 2* (2009), para áreas de estudo na França, nos Pirineus, no Marrocos, e na Argélia, foram obtidas médias de Índice *Kappa* para o *Mahalanobis* no SPOT de 63%; no *Landsat5* de 47%; e no *Formosat 2* de 66%.

Quanto aos resultados de acurácia para o *Malahanobis*, neste trabalho, foram encontrados de 91,8% no PA Cristalino, sendo o menor valor, e 99,8%, como maior, no PA Barra Norte, com uma média de 97,22%. Como citado, a aplicação do *Mahalanobis* será comparada com artigos que utilizaram outros satélites. Em Cattani et al. (2013), que utilizou cenas do *Rapideye*, o resultado da acurácia foi de 88%. Em Ustuner et al. (2016), aplicando também o *Rapideye*, o valor da acurácia no *Mahalanobis* foi de 76,31%. Em Masse (2013), utilizando cenas do SPOT -5 (2007), *Landsat 5* (2010), *Formosat 2* (2009), foram obtidas médias de valor de acurácia para o *Mahalanobis* no SPOT de 67,09%, no *Landsat5* de 51,23%, e no *Formosat2* de 67,82%.

Com esses valores do Índice *Kappa* e de acurácia no método de classificação *Mahalanobis*, é possível perceber que os resultados obtidos nesse trabalho, com o *Sentinel-2*, foram superiores aos demais artigos encontrados na literatura utilizando outros satélites. Nesse estudo, o *Sentinel-2*, quando aplicado o *Mahalanobis*, teve resultados superiores ao do *Rapideye* que possui uma resolução espacial quatro vezes maior e resolução espectral semelhante.

Para o método de classificação SAM, Mohajane et al. (2017) obteve no seu mapeamento com o *Sentinel-2*, no Marrocos, o Índice *Kappa* de 98,89%. Também foi encontrado em Okiemute (2016), simulando o *Sentinel-2*, por meio do satélite *QuickBird*, em uma área da Inglaterra, valores de *Kappa* variando entre 50 a 71,1%. Comparando os resultados obtidos pelo SAM no *Sentinel-2*, com resultados obtidos por outros satélites, Ustuner et al. (2016), aplicando o *Rapideye*, em uma área de agricultura da Turquia, atingiu o resultado para o SAM de 83,97%. Em Azar et al. (2017), utilizando o *Landsat 8*, no norte da Itália, obteve-se o resultado para o *Kappa* do SAM variando entre 56,3 a 77,8%. Shivakumar (2017), também utilizando o *Landsat 8*, no norte de Canara/ Índia, alcançou uma variação do *Kappa* entre 57,7% e 65,68. No caso deste estudo, o menor valor do Índice *Kappa* foi no PA Horizonte II com 80,4% e o maior no PA ETA 98%, com uma média de 93,7%.

Com referência aos níveis de acurácia, Mohajane et al. (2017), utilizando o SAM, obteve no seu mapeamento com o *Sentinel-2* 99,72%. Também foi encontrado em Okiemute (2016), simulando o *Sentinel-2*, por meio do satélite *QuickBird*, resultados de acurácia variando entre 38 a 78%. Comparando os resultados obtidos em acurácia pelo SAM no *Sentinel-2*, com

resultados obtidos por outros satélites, Ustuner et al. (2016), aplicando o *Rapideye*, atingiu o resultado para o SAM de 81,79%. Em Azar et al. (2017), utilizando o *Landsat 8*, obteve o resultado para a acurácia do SAM variando entre 63,7 a 81,6%. Neste trabalho, o menor valor de acurácia foi obtido no PA Cristalino IV com 90% e o maior no PA ETA com 99%, com média de 96,89%.

Como visto, os resultados do SAM neste trabalho estiveram dentro dos padrões para o satélite *Sentinel-2* e foram consideravelmente superiores quando comparados com outros satélites.

Os resultados encontrados para o Índice *Kappa* no SCM, neste trabalho, foram de 85,16% no PA Cachimbo II, como menor valor, e 99,2% no PA Cedro Rosa, como maior valor, com uma média de 93,28%. Quanto aos níveis de acurácia, neste estudo, mantiveram-se os mesmos assentamentos. O menor valor foi obtido no PA Cachimbo II com 93,6% e o maior no PA Cedro Rosa com 99,6%, com média de 96,69%. Como não foram encontradas na literatura pesquisas referentes à aplicação do SCM no *Sentinel-2*, a comparação será realizada com base no artigo de Shivakumar (2017), que utilizou o *Landsat 8*, no norte de Canara/ Índia, alcançando uma variação do *Kappa* entre 63,85% e 68,85%, e um índice de acurácia de 73%. O SCM é um método ainda pouco utilizado apesar de no estudo ter alcançado índices altos de acurácia de *Kappa*, e os resultados encontrados neste trabalho serem superiores aos da literatura.

No caso do Maxver, o menor Índice *Kappa* deste trabalho foi no PA Cristalino IV com 78% e o maior valor foi nos PA Cachimbo II e Bonjagua com 96,45%, com uma média dos resultados de 90,94%. Em Buchholz; Marconcini; Fernández-Prieto (2012), realizado no sul da Espanha, utilizando cenas do *Sentinel-2*, obteve-se um Índice *Kappa* de 87,3%. Elhag & Boteva (2016). , com área de estudo localizada na Grécia, aplicando cenas do *Sentinel-2*, alcançou um resultado do Índice *Kappa* para o Maxver de 69,3%. Okiemute (2016), simulando o *Sentinel-2*, por meio do satélite *QuickBird*, em uma área da Inglaterra, obteve uma variação entre 40 a 66% de Índice *Kappa*. Comparando os resultados obtidos pelo Maxver no *Sentinel-2*, com resultados obtidos por ele com outros satélites, tem-se que em Ustuner et al. (2016), aplicando o *Rapideye*, em uma área de agricultura da Turquia, atingiu o resultado para o Maxver, no Índice *Kappa*, de 83,97%. Em Azar et al. (2017), utilizando o *Landsat 8*, no norte da Itália, foi obtido o resultado para o valor do *Kappa* variando entre 73,7 a 91,2%.

Quanto à acurácia no método de classificação Maxver, os resultados se mantiveram nos mesmos assentamentos. Ou seja, o PA Cristalino IV teve o índice mais baixo, 89%, e os PA Cachimbo II e Bonjagua tiveram os índices mais altos, 98,2%. Em Buchholz; Marconcini; Fernández-Prieto (2012), utilizando cenas do *Sentinel-2*, obteve-se um nível de acurácia de

89,91%. Elhag & Boteva (2016)., aplicando cenas do *Sentinel-2*, alcançou um resultado de acurácia de 65,82%. Okiemute (2016), simulando o *Sentinel-2*, por meio do satélite *QuickBird*, obteve uma variação entre 52 a 73,34%. Comparando os resultados obtidos pelo Maxver no *Sentinel-2*, com resultados obtidos por ele com outros satélites, tem-se que em Ustuner et al. (2016), aplicando o *Rapideye*, atingiu o índice de acurácia de 82,58%. Em Azar et al. (2017), utilizando o *Landsat 8*, foi obtido a variação entre 78 a 92,7%.

Diante de tais dados, conclui-se que os resultados alcançados pelo Maxver nas áreas de estudo foram, em sua maioria, maiores do que os encontrados na literatura tanto para os trabalhos utilizando o *Sentinel-2* quanto para os de outros satélites.

Os resultados obtidos nesse trabalho podem ser explicados, em sua maior parte, por quatro fatores. Área de estudo que possibilita uma grande quantidade de *pixels* de treinamento, o número de classes acima do usual, quando se trata desses seis métodos, o fato de que as 137 classes terem sido reduzidas a apenas duas, e a qualidade de imagem do *Sentinel-2*. Esses fatores influenciaram nos resultados das classificações, porque houve uma maior quantidade de *pixels* nas áreas de treinamento, e quanto mais essas áreas de treinamento foram divididas em classes, tornou-se mais fácil para os métodos de classificação supervisionada a obtenção de um melhor resultado, diminuindo, assim, a existência de erros na classificação. Aliado, a isso, temos o processo de transformação de todas as classificações em apenas duas, o que diminui ainda mais os erros de classificação, por limitar os possíveis erros no processo de obtenção das verdades de campo.

## 9. CONSIDERAÇÕES FINAIS

Este estudo comprovou a potencialidade do uso das imagens do *Sentinel-2* para dar suporte ao CAR e otimizar o processo de análise, visto que os benefícios são relevantes tanto para o contribuinte, quanto para o governo, pois as imagens estão disponíveis e gratuitas desde junho de 2015. Antes desta data, poderão ser usadas no Cadastro as cenas do *Landsat 5 TM* que também são gratuitas e estão disponíveis desde 1984. A opção pelo *Sentinel-2* justifica-se pela qualidade de resolução espacial e espectral das imagens que é superior ao *Landsat 5 TM*. Além disso, a área imageada pelo *Sentinel-2* é maior, diminuindo, assim, o tempo de revisita.

Selecionadas as duas cenas do *Sentinel-2*, englobando os vinte assentamentos rurais da área de estudo localizados no norte do estado do Mato Grosso, foram feitos os processos para identificar o método de classificação supervisionada mais adequado para utilização nas análises multitemporais da questão do uso e cobertura do solo empregadas no CAR.

Cumriu-se o objetivo, também, de comprovar a eficácia e a aplicabilidade das imagens do satélite *Sentinel-2* no processo de análise multitemporais do CAR, pois com os resultados obtidos foi possível atestar que as cenas deste satélite auxiliaram nos melhores índices obtidos pelos métodos de classificação supervisionada.

Quanto aos métodos de classificação, após vários cruzamentos de dados estatísticos, recomenda-se o uso do *Spectral Correlation Mapper* (SCM) e do *Mahalanobis Distance*, pois ambos apresentaram os melhores resultados. O SCM demonstrou uma menor variação nos índices de acurácia e Índice *Kappa*, entre as classes (vegetação e área antropizada), e o *Mahalanobis* melhores resultados gerais. Porém, considerando-se que para as análises do CAR é necessário um método com resultados mais consistentes (com pouca variação entre as classes), os melhores resultados do SCM destacaram-se. Entretanto, é importante destacar que não foi encontrado na literatura outra aplicação deste método com o satélite *Sentinel-2*.

Com o diagnóstico mais eficiente, o CAR conseguirá emitir um resultado melhor para o proprietário do imóvel rural e para o governo, sobre as questões fundiárias e o avanço do desmatamento. Consequentemente, esse melhor uso dos recursos públicos desonerará o contribuinte e tornará mais eficiente o Cadastro.

Contudo, é pertinente realizar algumas ressalvas. A primeira é que mais estudos devem ser realizados em outras partes do Brasil, de preferência em cada bioma, para

verificar se os dois métodos continuarão a ter bons resultados, garantindo, assim, um bom aproveitamento pelos governos. A segunda é a realização de testes com menos classes de treinamento e com um menor número amostral de *pixels*, para averiguar qual seria o limite de redução dos parâmetros de treinamento.

## 10. REFERÊNCIAS BIBLIOGRÁFICAS

ALENCAR, A. et al. Desmatamento nos Assentamentos da Amazônia: histórico, tendências e oportunidades. **IPAM - Instituto de Pesquisa Ambiental da Amazônia**, p. 93, 2016.

ALVES, A. C.; CONCEIÇÃO, P. E. DE A. Levantamento do uso e ocupação do solo por meio de imagens TM-Landsat-5 e ADS-80 para o município de Manaus/AM. **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, n. 1, p. 5881–5888, 2015.

ANDRADE, M. P. DE; RIBEIRO, C. B. DE M.; LIMA, R. N. DE S. Avaliação do uso e ocupação do solo na bacia hidrográfica do rio Paraíba do Sul na primeira década do século XXI a partir de imagens MODIS - Land Cover. **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, p. 1961–1968, 2015.

ARAÚJO, S. M. V. G. DE; JURAS, I. A. G. M. Debate sobre a nova lei florestal: análise dos textos aprovados na câmara e no senado. In: Comitê Brasil em Defesa das Florestas e do Desenvolvimento Sustentável (Org.). Código Florestal e a ciência: o que nossos legisladores ainda precisam saber. **Comitê Brasil**, p. 105–116, 2012.

AZAR, R. et al. European Journal of Remote Sensing Assessing in-season crop classification performance using satellite data: a test case in Northern Italy. **European Journal of Remote Sensing**, v. 49, p. 361–380, 2017.

BARROS, K. **SIMCAR: Como vai funcionar o Novo Cadastro Ambiental Rural? | NOTÍCIAS DE MATO GROSSO**. Disponível em: <<http://www.noticiasdematogrosso.com.br/simcar-como-vai-funcionar-o-novo-car/>>. Acesso em: 26 out. 2017.

BECKER, B. K. Modelos e cenários para a Amazônia: o papel da ciência Revisão das políticas de ocupação da Amazônia: é possível identificar modelos para projetar cenários? O PROJETO GEOPOLÍTICO PARA A MODERNIDADE E AS REDES TÉCNICAS. **Parceiras Estrategicas**, v. 12, p. 135–159, 2001.

BECKER, B. K. **Amazônia sem extremismo**. Disponível em: <<http://revistapesquisa.fapesp.br/2004/08/01/amazonia-sem-extremismo/>>. Acesso em: 15 out. 2017.

BRANCALION, P. H. S. S. et al. Análise crítica da Lei de Proteção da Vegetação Nativa (2012), que substituiu o antigo Código Florestal: atualizações e ações em curso. **Natureza e Conservacao**, v. 14, p. e1–e16, abr. 2016.

BRASIL. **LEI Nº 4.771, DE 15 DE SETEMBRO DE 1965**. Institui o novo Código Florestal, , 1965. Disponível em: <<http://www.car.gov.br/leis/LEI4771.pdf>>. Acesso em: 8 jul. 2016

BRASIL. **Mapa de Biomas e de Vegetação**. Disponível em: <<https://ww2.ibge.gov.br/home/presidencia/noticias/21052004biomashtml.shtm>>. Acesso em: 26 out. 2017.

BRASIL. **Manual de Operação do Simlam Público**. [s.l: s.n.].

BRASIL. **DECRETO Nº 7.029, DE 10 DE DEZEMBRO DE 2009**. Disponível em: <[http://www.planalto.gov.br/ccivil\\_03/\\_ato2007-2010/2009/decreto/d7029.htm](http://www.planalto.gov.br/ccivil_03/_ato2007-2010/2009/decreto/d7029.htm)>. Acesso em: 26 out. 2017.

BRASIL. **Bioma Amazônico**. Disponível em: <<https://www.ibflorestas.org.br/bioma-amazonico.html>>. Acesso em: 27 out. 2017.

BRASIL. **LEI Nº 12.651, DE 25 DE MAIO DE 2012** Dispõe sobre a proteção da vegetação nativa; altera as Leis nos 6.938, de 31 de agosto de 1981, 9.393, de 19 de dezembro de 1996, e 11.428, de 22 de dezembro de 2006; revoga as Leis nos 4.771, de 15 de setembro de 1965, e 7.754, de 14 de abril de 1989, e , 2012a. Disponível em: <<http://www.car.gov.br/leis/LEI12651.pdf>>. Acesso em: 8 jul. 2016

BRASIL. **DECRETO Nº 7.830, DE 17 DE OUTUBRO DE 2012**. Disponível em: <[http://www.planalto.gov.br/ccivil\\_03/\\_Ato2011-2014/2012/Decreto/D7830.htm](http://www.planalto.gov.br/ccivil_03/_Ato2011-2014/2012/Decreto/D7830.htm)>. Acesso em: 26 out. 2017c.

BRASIL. **RapidEye**. Disponível em: <[http://www.sat.cnpm.embrapa.br/conteudo/missao\\_rapideye.php](http://www.sat.cnpm.embrapa.br/conteudo/missao_rapideye.php)>. Acesso em: 23 abr. 2016a.

BRASIL. **Landsat**. Disponível em: <[http://www.sat.cnpm.embrapa.br/conteudo/missao\\_landsat.php](http://www.sat.cnpm.embrapa.br/conteudo/missao_landsat.php)>. Acesso em: 23 abr. 2016b.

BRASIL. Instrução Normativa n2/MMA, 6 de maio de 2014. v. 31, p. 11, 2014.

BRASIL. **CAR- Cadastro Ambiental Rural**. Disponível em: <<http://www.car.gov.br/#/sobre>>. Acesso em: 23 abr. 2016a.

BRASIL. **Semad- Secretaria de Estado de Meio Ambiente e Desenvolvimento Sustentável**. Disponível em: <<http://www.meioambiente.mg.gov.br/cadastro-ambiental-rural/1886>>. Acesso em: 21 abr. 2016b.

BRASIL. Módulo de cadastro. 2016c.

BRASIL. **Produtor terá 90 dias para fazer adequações no novo sistema de Cadastro Ambiental Rural - Notícias - mt.gov.br**. Disponível em: <<http://www.mt.gov.br/-/7628282-produtor-tera-90-dias-para-fazer-adequacoes-no-novo-sistema-de-cadastro-ambiental-rural>>. Acesso em: 26 out. 2017a.

BRASIL. **Novo sistema garantirá agilidade e segurança no plano de exploração florestal - Notícias - mt.gov.br**. Disponível em: <<http://www.mt.gov.br/-/5753206-novo-sistema-garantira-agilidade-e-seguranca-no-plano-de-exploracao-florestal>>. Acesso em: 26 out. 2017b.

BRASIL. **LEI COMPLEMENTAR Nº 592, DE 26 DE MAIO DE 2017**. Disponível em:

<<http://app1.sefaz.mt.gov.br/0425762E005567C5/9733A1D3F5BB1AB384256710004D4754/2934486634343A9C8425812F005B9C6E>>. Acesso em: 26 out. 2017c.

BRASIL. **Sema esclarece dúvidas sobre atualização ao novo sistema Simcar - Notícias - mt.gov.br**. Disponível em: <<http://www.mt.gov.br/-/7635468-sema-esclarece-duvidas-sobre-atualizacao-ao-novo-sistema-simcar>>. Acesso em: 26 out. 2017d.

BRASIL. **Sema leva informações sobre o novo sistema Simcar a entidades do setor produtivo - Notícias - mt.gov.br**. Disponível em: <<http://www.mt.gov.br/-/7768361-sema-leva-informacoes-sobre-o-novo-sistema-simcar-a-entidades-do-setor-produtivo>>. Acesso em: 26 out. 2017e.

BRASIL. **Novo sistema garantirá praticidade aos usuários dos serviços da Sema - Notícias - mt.gov.br**. Disponível em: <<http://www.mt.gov.br/-/7596528-novo-sistema-garantira-praticidade-aos-usuarios-dos-servicos-da-sema>>. Acesso em: 26 out. 2017f.

BRASIL. **Manual de operação do sistema Cadastro Ambiental Rural Mato-Grossense**. [s.l: s.n.].

BUCHHOLZ, T.; MARCONCINI, M.; FERNÁNDEZ-PRIETO, D. **On the effectiveness of Sentinel-2 data for land-cover mapping: Comparison with landsat and spot imagery**. European Space Agency, (Special Publication) ESA SP. **Anais...2012**

CATTANI, C. E. V. et al. Desempenho de algoritmos de classificação supervisionada para imagens dos satélites RapidEye. **Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, p. 8005–8010, 2013.

CONGALTON, R. G.; GREEN, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. 1999.

COSTA, F. D. A. Políticas Econômicas e Desenvolvimento Regional Sustentável : Uma avaliação das aplicações do Fundo Constitucional de Financiamento do Norte ( FNO ) na agricultura familiar da Amazônia ( o caso do Pará ). **Paper so NAEA**, p. 28, 2000.

CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. Instituto de Geociências Departamento de Metalogênese e Geoquímica, p. 170, 1992.

DE CARVALHO, O. A. et al. Spectral Correlation Mapper ( SCM ): An Improvement on the Spectral Angle Mapper ( SAM ). **JPL Publication**, v. 9, n. 00–18, p. 1–9, 1999.

DELALIBERA, H. C.; WEIRICH NETO, P. H.; LOPES, A. R. C.; ROCHA, C. H. Alocação de reserva legal em propriedades rurais: do cartesiano ao holístico. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 12, n. 3, p. 286–292, 2008.

ELHAG, M.; BOTEVA, S. Mediterranean Land Use and Land Cover Classification Assessment Using High Spatial Resolution Data. **IOP Conference Series: Earth and Environmental Science**, v. 44, n. 4, p. 42032, out. 2016.

ESA. **Sentinel-2 - Missions - Instrument Payload - Sentinel Handbook**. Disponível em: <<https://sentinel.esa.int/web/sentinel/missions/sentinel-2/instrument-payload>>. Acesso em: 13 set. 2017a.

ESA. **Sentinel-2 - ESA Operational EO Missions - Earth Online - ESA**. Disponível em: <<https://earth.esa.int/web/guest/missions/esa-operational-eo-missions/sentinel-2>>. Acesso em: 13 set. 2017b.

ESA. **Sentinel-2 - Overview - Sentinel Online**. Disponível em: <<https://sentinel.esa.int/web/sentinel/missions/sentinel-2/overview>>. Acesso em: 27 out. 2017c.

ESRI. **Accuracy Assessment for Image Classification—Help | ArcGIS Desktop**. Disponível em: <<http://desktop.arcgis.com/en/arcmap/latest/manage-data/raster-and-images/accuracy-assessment-for-image-classification.htm>>. Acesso em: 27 out. 2017.

FITZ, P. R. **Geoprocessamento sem complicação**. São Paulo: Oficina de Textos, 2008.

GODAR, J.; TIZADO, E. J.; POKORNY, B. Who is responsible for deforestation in the Amazon? A spatially explicit analysis along the Transamazon Highway in Brazil. **Forest Ecology and Management**, v. 267, p. 58–73, mar. 2012.

GUIDOTTI, V. et al. Código Florestal: Contribuições para a regulamentação dos programas de regularização ambiental (PRA). **Imaflora**, v. 4, p. 12, 2016.

ISABEL DE CASTRO, A. et al. Airborne multi-spectral imagery for mapping cruciferous weeds in cereal and legume crops. **Springer**, p. 302–321, 2011.

JUNIOR, C. S. MAPBIOMAS. **MapBiomass General “Handbook”**, v. 1, p. 15, 2017.

JUNIOR, O. A. DE C.; SILVA, N. C. DA. Implementação do módulo de mistura espectral Spectral Multiple Correlation Mapper. **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto**, n. 1994, p. 5643–5650, 2007.

KAUANO, E. E.; PASSOS, E. Análise do uso da terra em áreas de preservação permanente na bacia hidrográfica do Rio da Gama, Tijucas do Sul – PR. **Revista Acadêmica de Ciências Agrárias e Ambientais**, p. 181–190, 2008.

KRUSE, F. A. et al. **The spectral image processing system (SIPS)-interactive visualization and analysis of imaging spectrometer data**. AIP Conference Proceedings. **Anais...AIP**, 1993a Disponível em: <<http://scitation.aip.org/content/aip/proceeding/aipcp/10.1063/1.44433>>. Acesso em: 26 jun. 2016

LABBASSI, K. et al. **EO Data to support the Optimal Management of Irrigation Water in Western Morocco : Potential of Sentinel-2 Type Observation**. Sentinel-2 Preparatory Symposium. **Anais...2012**

LANDIS, J. R.; KOCH, G. G. The Measurement of Observer Agreement for Categorical Data. v. 33, mar. 1977.

LAUDARES, SORITA DE A. S. S. DE A.; SILVA, K. G. DA; BORGES, L. A. C. Cadastro Ambiental Rural: uma análise da nova ferramenta para regularização ambiental no Brasil. **Desenvolvimento e Meio Ambiente**, v. 31, n. 0, p. 111–122, 2014.

LE TOURNEAU, F.-M.; BURSZTYN, M. Assentamentos Rurais na Amazônia: contradições entre a política agrária e a política ambiental. **Ambiente & sociedade**, v. 13, n. 1, p. 111–130, 2010.

LILLESAND, K. R. W. REMOTE SENSING AND IMAGE INTERPRETATION. **Geological Magazine**, v. 132, n. 2, p. 248–249, 1 mar. 1995.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. Remote sensing and image interpretation. 2004.

LIMA, E. et al. Searching for Sustainability: Forest Policies, Smallholders, and the Trans - Amazon Highway. **Environment: Science and Policy for Sustainable Development**, v. 48, n. 1, p. 26–38, jan. 2006.

MAPBIOMAS. **MapBiomias Produtos**. Disponível em: <<http://mapbiomas.org/pages/about/products>>. Acesso em: 27 out. 2017.

MASSE, A. **Développement et automatisation de méthodes de classification à partir de séries temporelles d'images de télédétection - Application aux changements ? d'occupation des sols et à l'estimation du bilan carbone**. [s.l.: s.n.].

MENESES, P. R.; ALMEIDA, T. DE. Introdução ao processamento de imagem de sensoriamento remoto. **Cnpq/Unb**, p. 266, 2012.

MERRY, F. et al. **Collective action without collective ownership: community associations and logging on the Amazon frontier**The International Forestry Review Commonwealth Forestry Association, , 2006. Disponível em: <<https://www.jstor.org/stable/43740278>>. Acesso em: 11 ago. 2017

MOHAJANE, M. et al. Mapping Forest Species in the Central Middle Atlas of Morocco (Azrou Forest) through Remote Sensing Techniques. **ISPRS International Journal of Geo-Information**, v. 6, n. 9, p. 275, 3 set. 2017.

MORAES, R. M. DE. **Processamento de Imagens de Sensoriamento Remoto**. Disponível em: <<http://www.de.ufpb.br/~ronei/procimagem/procimagem.htm>>. Acesso em: 27 out. 2017.

MOTA, K. **Uma nova iniciativa para utilizar imagens do SENTINEL – 2 | Processamento Digital**. Disponível em: <<http://www.processamentodigital.com.br/2016/09/22/uma-nova-iniciativa-para-utilizar-imagens-do-sentinel-2/>>. Acesso em: 27 out. 2017.

MÜLLER, S. I. M. G.; DALMOLIN, Q.; ARAKI, H. Comparação entre os métodos de

máxima verossimilhança, distância mínima e o método de Fisher para reconhecimento de padrões em imagens coloridas. **Boletim de Ciências Geodésicas**, v. 4, n. 1, p. 3–13, 1999.

NEPSTAD, D. C. et al. Interactions among Amazon land use, forests and climate: prospects for a near-term forest tipping point. p. 1737–1746, 2008.

NUNES, D. DA C. et al. Impacto da Lei de Proteção da Vegetação Nativa na Conservação de Recursos Hídricos em um Assentamento Rural em Nova Venécia - Espírito Santo. **Fronteiras: Journal of Social, Technological and Environmental Science**, v. 6, n. 2, p. 167, 2017.

OLIVEIRA, A. U. DE. **Amazonia, Integrar para não entregar : políticas públicas e amazonia**. [s.l: s.n.].

PASQUIS, R. et al. “ REFORMA AGRÁRIA ” NA AMAZÔNIA : Após quase 40 anos de colonização oficial , o Brasil ainda ocupa o segundo lugar no ranking mundial de concentração de terras . No País , de dimensões continentais ( 16 vezes maior que a França ), 49 % das terras rura. **Cadernos de Ciência & Tecnologia**, v. 22, n. 1, p. 83–96, 2005.

QUARTAROLI, C. F.; BATISTELLA, M. Classificação Digital de Imagens de Sensoriamento Remoto: Tutorial Básico. **Embrapa**, p. 53, 2006.

REES, W. G. W. G. Rees 1990. Physical Principles of Remote Sensing. Topics in Remote Sensing Series no. 1. xiv + 247 pp. Cambridge, New York, Port Chester, Melbourne, Sydney: Cambridge University Press. Price £35.00, US \$65.00 (hard covers), £13.95, US \$24.95 (paperb. **Geological Magazine**, v. 128, n. 3, p. 296, 1 maio 1991.

RENZA, D. et al. Unsupervised change detection in a particular vegetation land cover type using spectral angle mapper. **Advances in Space Research**, v. 59, p. 2019–2031, 2017.

RICHARDS, A. J. A comparison of methods for monitoring multi-temporal vegetation change using thematic mapper imagery. **Remote Sensing of Environment**, 1986a.

RICHARDS, J. A. Remote Sensing Digital Image Analysis: an introduction. Springer-Verlag p. 286 , 1986. analysis: an introduction. **Springer-Verlag**, p. 286, 1986b.

SANTOS, É. P. DOS; PIROLI, E. L. Detecção de mudanças no uso e cobertura da terra utilizando Land Change Modeler: o caso da bacia hidrográfica do Ribeirão do Rebojo, Pontal do Paranapanema, SP, Brasil. **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, n. 1, p. 1391–1398, 2015.

SAUER, S. O significado dos assentamentos de reforma agrária no Brasil. **Núcleo de Estudos Agrários e Desenvolvimento Rural – NEAD: Brasília, DF**, 2005.

SCHONS, S. Z.; AZEVEDO, A.; ALENCAR, A. Pronaf na Amazônia: quais os desafios? Boletim Amazônia em Pauta. **IPAM - Instituto de Pesquisa Ambiental da Amazônia**, 2013.

SHIVAKUMAR, B. R. **Performance Evaluation of Spectral Angle Mapper and Spectral Correlation Mapper Classifiers over Multiple Remote Sensor Data (PDF Download Available)**. Disponível em: <[https://www.researchgate.net/publication/314258426\\_Performance\\_Evaluation\\_of\\_Spectral\\_Angle\\_Mapper\\_and\\_Spectral\\_Correlation\\_Mapper\\_Classifiers\\_over\\_Multiple\\_Remote\\_Sensor\\_Data](https://www.researchgate.net/publication/314258426_Performance_Evaluation_of_Spectral_Angle_Mapper_and_Spectral_Correlation_Mapper_Classifiers_over_Multiple_Remote_Sensor_Data)>. Acesso em: 27 out. 2017.

SILVA, J. A. A.; AL., E. O Código Florestal e a Ciência: contribuições para o diálogo. 2012.

SOARES-FILHO, B. S. Impacto da revisão do Código Florestal : como viabilizar o grande desafio adiante? **Desenvolvimento sustentável - subsecretaria/SAE**, p. 28, 2013.

SOARES FILHO, B. et al. Cracking Brazil's Forest Code. **SCIENCE**, v. 344, 2014.

SOUTH, S.; QI, J.; LUSCH, D. P. Optimal classification methods for mapping agricultural tillage practices. **Remote Sensing of Environment**, v. 91, p. 90–97, 2004.

SOUZA, P. G. D. E. **Fomento Florestal Em Pequenas Propriedades Rurais No Brasil : Estratégias E Efetividade Fomento Florestal Em Pequenas Propriedades Rurais No Brasil : Estratégias E Efetividade**. [s.l: s.n.].

SPAROVEK, G. **A Qualidade Dos Assentamentos Da Reforma Agrária Brasileira**. [s.l: s.n.].

SZMRECSANYI, T.; DELGADO, G.; RAMOS, P. QUESTÃO AGRÁRIA NO BRASIL : Perspectiva Histórica e Configuração Atual. **Incra**, p. 131, 2005.

USTUNER, M. et al. COMPARISON OF CROP CLASSIFICATION METHODS FOR THE SUSTAINABLE AGRICULTURE MANAGEMENT. **Journal of Environmental Protection and Ecology**, v. 17, n. 2, p. 648–655, 2016.

YAGOUB, H.; BELBACHIR, A. H.; BENABADJI, N. Detection and mapping vegetation cover based on the Spectral Angle Mapper algorithm using NOAA AVHRR data. **Advances in Space Research**, v. 53, n. 12, p. 1686–1693, 2014.

ZAKIA, M.J., L. F. G. P. **Guia para a aplicação da nova lei florestal em propriedades rurais**. [s.l.] IPEF, Imaflora, 2013.

ZHANG, X.; LI, P. Lithological mapping from hyperspectral data by improved use of spectral angle mapper. **International Journal of Applied Earth Observation and Geoinformation**, v. 31, p. 95–109, 2014.