

**UNIVERSIDADE FEDERAL DE UBERLÂNDIA - CAMPUS MONTE CARMELO**  
**ENGENHARIA DE AGRIMENSURA E CARTOGRÁFICA**

**ARTHUR HENRIQUE DE ARAÚJO E SILVA**

**CLASSIFICAÇÃO SUPERVISIONADA DE IMAGENS DE SATÉLITE PELO  
MÉTODO DA MÁXIMA VEROSSIMILHANÇA PARA DISCRIMINAÇÃO DO  
CULTIVO DE CAFÉ (*Coffea spp.*) NO MUNICÍPIO DE MONTE CARMELO - MG**

**MONTE CARMELO**

**2022**

**ARTHUR HENRIQUE DE ARAÚJO E SILVA**

**CLASSIFICAÇÃO SUPERVISIONADA DE IMAGENS DE SATÉLITE PELO  
MÉTODO DA MÁXIMA VEROSSIMILHANÇA PARA DISCRIMINAÇÃO DO  
CULTIVO DE CAFÉ (*Coffea spp.*) NO MUNICÍPIO DE MONTE CARMELO – MG**

Trabalho apresentado como requisito para a obtenção de aprovação na disciplina de Trabalho de Conclusão de Curso II do curso de Engenharia de Agrimensura e Cartográfica da Universidade Federal de Uberlândia.

Orientador: Prof. Dr. Rodrigo Bezerra de Araújo Gallis

**MONTE CARMELO**

**2022**

## LISTA DE FIGURAS

<b>Figura 1</b>	Área plantada de café em território brasileiro.	<b>11</b>
<b>Figura 2</b>	Representação gráfica de um comprimento de onda.	<b>13</b>
<b>Figura 3</b>	Espectro eletromagnético.	<b>14</b>
<b>Figura 4</b>	Assinatura espectral da vegetação seca, vegetação verde e solo em diferentes regiões do EE.	<b>15</b>
<b>Figura 5</b>	Exemplo do processo de aquisição de imagem digital.	<b>17</b>
<b>Figura 6</b>	Representação de uma imagem digital bidimensional.	<b>17</b>
<b>Figura 7</b>	Imagens de diferentes sensores e resoluções espaciais.	<b>19</b>
<b>Figura 8</b>	Diferença de resolução radiométrica em área urbana.	<b>21</b>
<b>Figura 9</b>	Fluxograma de organização das atividades.	<b>27</b>
<b>Figura 10</b>	Mapa de localização da área de estudo (Monte Carmelo - MG).	<b>28</b>
<b>Figura 11</b>	<i>Template</i> gerado para pré-visualização do mosaico.	<b>30</b>
<b>Figura 12</b>	Mosaico de imagens recobrando o município de Monte Carmelo – MG.	<b>31</b>
<b>Figura 13</b>	Mosaico de imagens recortado para o município de Monte Carmelo – MG.	<b>32</b>
<b>Figura 14</b>	Processo de amostragem concluído.	<b>33</b>
<b>Figura 15</b>	Resultado parcial do controle de qualidade da classificação.	<b>34</b>
<b>Figura 16</b>	Mapa resultante da classificação de imagens do município de Monte Carmelo – MG.	<b>35</b>

<b>Figura 17</b>	Área ampliada da área urbana do município de Monte Carmelo – MG e seu entorno.	<b>36</b>
<b>Figura 18</b>	Resultado da classificação na área da Figura 17.	<b>37</b>
<b>Figura 19</b>	Áreas cafeeiras dentro do município de Monte Carmelo – MG.	<b>38</b>
<b>Figura 20</b>	Mapeamento cafeeiro do município de Monte Carmelo – MG segundo dados da CONAB (2017).	<b>39</b>
<b>Figura 21</b>	Resultado da classificação de 2020 das áreas dos polígonos identificados como café pela CONAB em 2017.	<b>40</b>

## LISTA DE TABELAS

<b>Tabela 1</b>	Matriz de Confusão da Classificação com a unidade em pixels.	<b>41</b>
<b>Tabela 2</b>	Matriz de Confusão da Classificação em porcentagem.	<b>42</b>

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	6
<b>2 JUSTIFICATIVA</b> .....	8
<b>3 OBJETIVOS</b> .....	9
<b>3.1 Objetivo geral</b> .....	9
<b>3.2 Objetivos específicos</b> .....	9
<b>4 REVISÃO BIBLIOGRÁFICA</b> .....	10
<b>4.1 O café (<i>Coffea spp.</i>)</b> .....	10
<b>4.2 Sensoriamento Remoto Aplicado a Vegetação</b> .....	12
<b>4.2.1 Sensores orbitais</b> .....	16
<b>4.2.2 Resolução das Imagens</b> .....	18
4.2.2.1 Resolução Espacial.....	18
4.2.2.2 Resolução Espectral.....	19
4.2.2.3 Resolução Radiométrica.....	20
4.2.2.4 Resolução Temporal.....	21
<b>4.3 Processamento Digital de Imagens</b> .....	22
<b>4.3.1 Calibração Radiométrica</b> .....	23
<b>4.3.2 Classificação de Imagens</b> .....	24
4.3.2.1 Classificação Pixel a Pixel.....	25
<b>5 MATERIAL E MÉTODOS</b> .....	26
<b>5.1 Área de estudo</b> .....	28
<b>5.2 Material</b> .....	29
<b>5.2.1 Satélite PlanetScope</b> .....	29
<b>5.3 Metodologia</b> .....	30
<b>5.3.1 Aquisição das imagens</b> .....	30
<b>5.3.2 Mosaicagem</b> .....	30

<i>5.3.3 Classificação das imagens</i> .....	32
<i>5.3.4 Controle de qualidade</i> .....	34
<b>6 RESULTADOS OBTIDOS</b> .....	35
<b>7 CONCLUSÃO</b> .....	43
<b>REFERÊNCIAS</b> .....	45

## 1 INTRODUÇÃO

Atualmente, o Brasil é um dos maiores produtores de café, sendo responsável por aproximadamente um terço da produção mundial e possuindo área plantada estimada de 1,88 milhão de hectares (CONAB, 2020). O estado de Minas Gerais é responsável por 53% da produção nacional, correspondente a cerca de 16% da produção mundial (EMBRAPA, 2018). O café exerce uma grande influência econômica e social no estado, gerando emprego e renda a milhares de pessoas que estão, de alguma forma, ligadas à produção ou comercialização do produto. Esta importância do café para o setor econômico gera uma alta demanda de informações acerca do setor produtivo, como a estimativa de safra e o monitoramento de lavouras, tornando mapeamento de áreas cafeeiras extremamente necessário.

As inovações tecnológicas no campo do sensoriamento remoto têm contribuído significativamente para o monitoramento cafeeiro, porém, a obtenção de algumas informações sobre o sistema de produção como extensão, distribuição espacial e ambiente de cultivo ainda se tornam necessárias para complementar e aperfeiçoar os resultados de estudos sobre a produção (MOREIRA *et al.*, 2004).

Moreira *et al.* (2004) afirmaram também que o padrão espectral das lavouras de café no Brasil apresenta inconsistência devido à falta de parâmetros padronizados de manejo e tamanho de lavouras, pois as áreas cafeeiras são implantadas nos mais variados tipos de relevo, em áreas de extensões heterogêneas, com diferentes espaçamentos entre as lavouras e tratos culturais. Assim, diversos estudos são realizados buscando relacionar as variações espectrais da cultura com características físicas da planta, procurando entender quais são as variáveis que influenciam na resposta espectral apresentada.

Outra dificuldade encontrada no mapeamento cafeeiro é a sobreposição espectral, que prejudica o bom desempenho de algoritmos que realizam a interpretação automática de imagens. Esta sobreposição estimula o aprimoramento de metodologias que visam o mapeamento de áreas cafeeiras em escala regional (CARVALHO, 2001). Mesmo com diversos métodos conhecidos para classificação de uso e cobertura da terra em grandes áreas geográficas (como estados), existe uma crescente demanda por estimativas precisas de pequenas áreas, como em âmbito municipal (FLORES; MARTÍNEZ, 2000).

Enquanto não existem contribuições científicas que indiquem uma metodologia de classificação de imagens ideal para a discriminação de lavouras cafeeiras, pesquisas são



realizadas para testar diferentes algoritmos classificadores e verificar sua capacidade de discriminar corretamente o café de outros alvos. Sabendo que a cultura cafeeira é facilmente confundida com outros tipos de uso e cobertura da terra por classificadores automáticos, o setor de pesquisas associado ao mapeamento de áreas cafeeiras sempre será incentivado a realizar testes e buscar por inovações.

Este trabalho utilizou imagens do satélite PlanetScope de resolução espacial de 3 metros, em associação com a metodologia de classificação supervisionada de imagens de satélite pelo método da Máxima Verossimilhança, para a obtenção de dados geoespaciais e elaboração de mapas de uso e cobertura da terra com foco em áreas ocupadas pela cafeicultura.

## 2 JUSTIFICATIVA

A cultura cafeeira possui uma grande relevância econômica e cultural no Brasil, assim, faz-se necessário a realização de um monitoramento constante da produção no país para que sejam obtidas estimativas de safra precisas. Para que isso ocorra utilizando técnicas de classificação de imagens de satélite, é imprescindível que sejam estudadas metodologias que apresentem os melhores resultados quando aplicadas à cultura do café. Isto porque o alvo é frequentemente confundido por classificadores automáticos e classificado como outros tipos de vegetação, ocasionando em uma classificação de imagens imprecisa. Deste modo, torna-se necessário o desenvolvimento de aplicações e métodos alternativos que utilizem técnicas computacionais como forma de aperfeiçoar os levantamentos de produção cafeeira, em prol tanto do progresso de pesquisas científicas, quanto da previsão de safra para o setor produtivo (PRADO *et al.*, 2013).

Carvalho (2001) reconhece a necessidade de uma metodologia de classificação bem-sucedida para o café que: a) seja apta a discriminar áreas cafeeiras de outras classes de uso e cobertura que se sobrepõe espectralmente; b) consiga considerar o máximo de informações sobre a área de interesse; e c) necessite da menor interferência humana possível, caso haja necessidade de uma estimativa precisa de ocupação por café em áreas extensivas.

Moreira *et al.* (2004) destacaram que é importante aperfeiçoar os métodos atuais de estimativa de produção a partir da inserção de novas tecnologias, como imagens de satélite e os Sistemas de Informação Geográfica (SIGs). As metodologias de classificação utilizadas em estudos de outras culturas como soja, cana-de-açúcar, ou trigo, não são apropriadas para o café devido à falta de um padrão característico de manejo da cultura. Isto implica na necessidade de se determinar uma abordagem metodológica específica para aplicação em áreas cafeeiras (INPE, 2019).

Este trabalho motiva-se em buscar uma solução para a confusão de vários classificadores ao tentar discriminar cafeicultura de vegetações com características espectrais similares, e também na falta de um padrão de assinatura espectral de lavouras de café, que faz com que a cultura seja constantemente confundida com outros tipos de vegetação, problematizando a discriminação dos alvos e prejudicando as classificações de imagens em áreas cafeeiras. Tais problemáticas incentivam pesquisas em busca de uma metodologia de classificação precisa e que se mostre vantajosa para aplicação na cultura do café.

### 3 OBJETIVOS

#### 3.1 Objetivo geral

De maneira geral, esta pesquisa tem o intuito de contribuir para o desenvolvimento de uma metodologia de classificação de imagens de satélite, com alta resolução espacial, que permita melhor discriminar áreas de cultivo de café (*Coffea spp.*) de outras áreas cultivadas, bem como de outros tipos de uso e cobertura da terra.

#### 3.2 Objetivos específicos

Este trabalho tem os seguintes objetivos específicos:

- Realizar a classificação das imagens que recobrem o município de Monte Carmelo - MG utilizando o algoritmo de classificação supervisionada pelo algoritmo da Máxima Verossimilhança;
- Comparar os resultados obtidos com o mapa de referência, elaborar índices avaliadores da classificação e gerar a Matriz de Confusão;
- Gerar um mapa temático com os resultados da classificação de uso e cobertura da terra do município de Monte Carmelo - MG e um mapa de áreas cafeeiras do município de Monte Carmelo – MG;
- Avaliar os resultados afim de determinar se o método utilizado se mostrou bem-sucedido na discriminação de áreas de cultivo de café de outros tipos de uso e cobertura da terra.

## 4 REVISÃO BILIOGRÁFICA

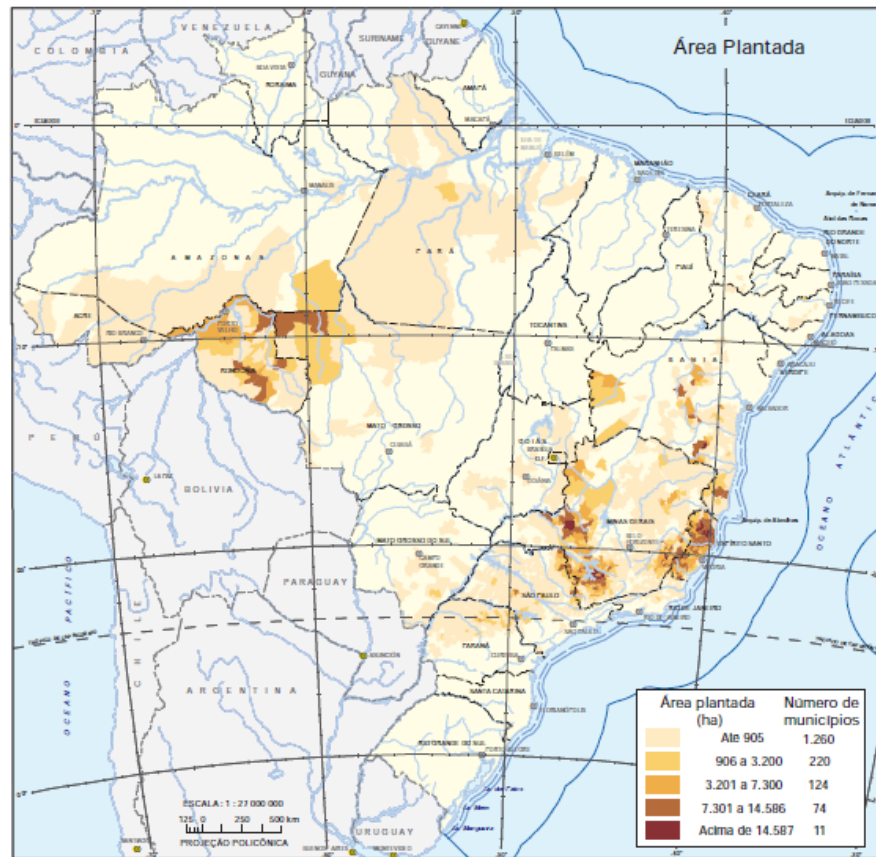
### 4.1 O café (*Coffea spp.*)

A planta do café (*Coffea spp.*) tem origem na África (GRANER; GODOYJUNIOR, 1967). Em 1615 o café ingressou na Europa, e os holandeses foram os responsáveis por disseminar o café ao redor do mundo. Em 1727, Francisco de Melo Palheta cultivou a primeira muda de café no Brasil, no estado do Pará. Com o passar do tempo, a cultura cafeeira se expandiu por todo o território nacional e fez do café o principal produto de exportação da economia brasileira durante o século XIX e o início do século XX, sendo até hoje um dos principais produtos cultivados e consumidos em todo o país (SANTOS, 2018).

As particularidades do cultivo do café ainda são fortemente dependentes do serviço braçal, o que conseqüentemente o atribui uma importante função social, responsável por gerar empregos diretamente no setor rural (MELLO, 2001). É estimado que a cafeicultura está presente em 1700 municípios brasileiros, totalizando 300 mil propriedades que contribuem para a geração de empregos e renda (CONAB, 2005). Estudos da Embrapa Café (2006, *apud* ROSA, 2007) afirmam que o setor cafeeiro é responsável por gerar cerca de sete milhões de empregos diretos e indiretos no país, movimentando uma quantia anual de 10 bilhões de reais.

A Figura 1 apresenta a espacialização da área plantada de café no Brasil no ano de 2016 segundo o IBGE. Nota-se a grande concentração de lavouras cafeeiras no sudeste do país, principalmente no estado de Minas Gerais, que retém mais da metade da produção nacional.

Figura 1 - Área plantada de café em território brasileiro



Fonte: IBGE (2016).

Zambolim (2001) afirma que o sucesso da cafeicultura ocorre por diversos fatores, entre eles destacam-se a redução dos custos de produtividade, o aumento da produtividade, a preservação do meio ambiente, a constante busca de qualidade, o avanço de novos mercados consumidores e a determinação de políticas agrícolas destinadas ao setor cafeeiro. Apontada como uma das bebidas mais populares do mundo, o café possui uma imensa relevância mundial devido à quantia financeira que é movimentada em sua comercialização (TEIXEIRA; MILHOMEN, 2001).

A considerável importância do café na economia brasileira ocorre devido à sua relevante participação na balança comercial, tornando o seu monitoramento de grande interesse para os setores público e privado (ROSA, 2007). Assim, informações objetivas e confiáveis sobre a produção do café se tornam essenciais para o direcionamento de planejamentos governamentais quanto a financiamentos de produção, abastecimento do mercado interno, importações e exportações, bolsa de mercadorias, entre outros (ROSA, 2007).

Em 2005 ocorre o surgimento do projeto CAFESAT, com o objetivo de mapear a cafeicultura brasileira nas regiões que mais produzem no país, utilizando dados orbitais de média resolução espacial (Landsat, SPOT, CBERS, entre outros), além de possibilitar a disponibilização destas informações na internet. O projeto teve apoio financeiro da Companhia Nacional de Abastecimento (CONAB) e do Consórcio Brasileiro de Pesquisas e Desenvolvimento do Café - CBP&D/Café (INPE, 2019).

A CONAB é responsável por realizar o acompanhamento da safra de café no Brasil desde 2001, contando com parcerias estaduais de órgãos do governo dos principais estados produtores, e a partir deste trabalho conjunto, produz quadrimestralmente o Boletim de Acompanhamento da Safra de Café, que estima a safra com base nas informações obtidas até o momento de sua publicação (CONAB, 2019).

Segundo o Boletim de Acompanhamento da Safra de Café emitido em janeiro de 2019, resultado de levantamentos realizados nos meses de novembro e dezembro de 2018, a área total cultivada no país com café (arábica e conilon) totaliza 2,16 milhões de hectares, sendo que 316,6 mil hectares (14,7%) estão em formação e 1,84 milhão de hectares (85,3%) em produção. A área plantada referente apenas ao *Coffea-arábica* no país soma 1,74 milhão de hectares, correspondente a 80,7% da área total de lavouras de café. O estado de Minas Gerais retém a maior área com a espécie, totalizando 1,21 milhão de hectares, que correspondem a 69,6% da área ocupada com *Coffea-arábica* em todo o país (CONAB, 2019).


## **4.2 Sensoriamento Remoto Aplicado à Vegetação**

De acordo com Colwell (1983) o sensoriamento remoto consiste na obtenção de informação de algum objeto, propriedade ou fenômeno, através de um dispositivo que não esteja em contato físico com o objeto de estudo. Esta definição foi formalmente aceita pela *American Society for Photogrammetry and Remote Sensing* (ASPRS). Florenzano (2002) definiu o sensoriamento remoto como o campo de conhecimento que permite a identificação de informações sobre alvos ou superfície terrestre, através da captação e do registro da energia eletromagnética refletida ou emitida pela superfície, com a utilização de sensores situados em plataformas terrestres, orbitais ou aéreas.

As aplicações do sensoriamento remoto têm se expandido pelos mais variados campos de conhecimento em consequência da grande disponibilidade de acesso aos dados de sensores remotos e à necessidade de entendimento dos diversos sistemas que compõe a Terra. O principal fundamento do sensoriamento remoto é a necessidade de uma fonte de energia irradiada para o objeto, com exceção apenas dos objetos que emitem sua própria energia. Batista e Dias (2005) declararam que esta energia é denominada radiação eletromagnética (REM), e é através da quantidade de REM que é refletida pelo alvo que as informações sobre o mesmo são registradas. Benvenuti (2005) afirmou que todo e qualquer material situado na superfície terrestre que possua temperatura maior que o zero absoluto ( $0^{\circ}\text{K}$ ) tem a capacidade de emitir, refletir, transmitir ou absorver parte da Radiação Eletromagnética (REM). Porém, a reflectância, quantidade de energia refletida pelo alvo, é o fenômeno físico mais estudado no uso do sensoriamento remoto aplicado à vegetação (PONZONI, 2001).

Gonzalez (2010) considerou que ondas eletromagnéticas podem ser entendidas como ondas de comportamento senoidal, de variados comprimentos, que se propagam, ou como um fluxo de partículas de massa inexistente, se conduzindo em padrão ondulatório e deslocando na velocidade da luz. A exemplificação de um comprimento de onda ( $\lambda$ ) pode ser visualizada na Figura 2.

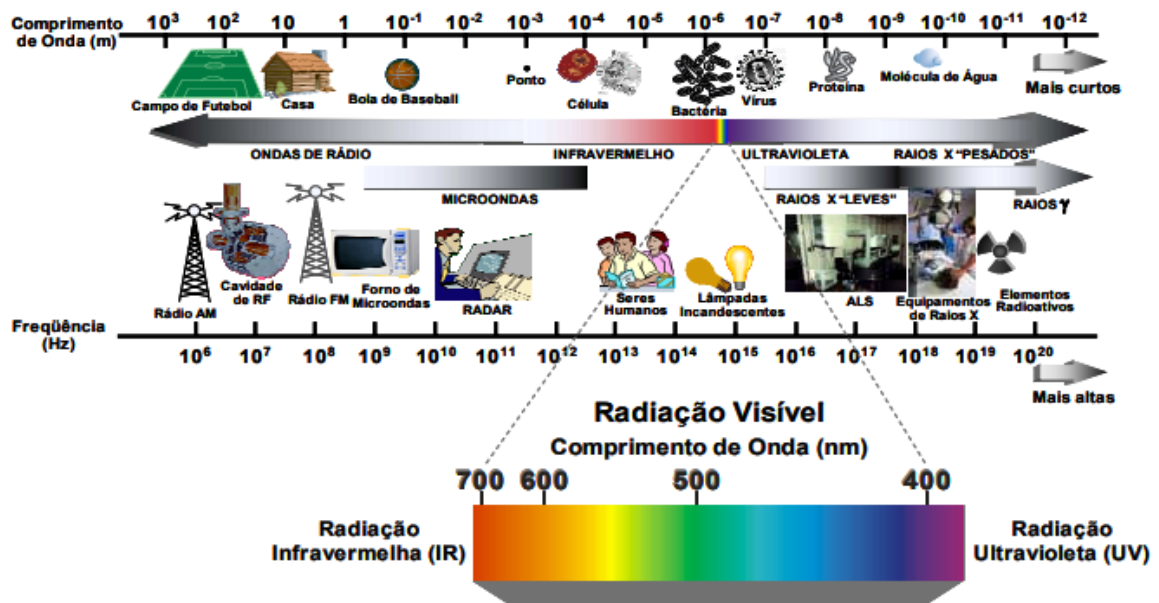
Figura 2 - Representação gráfica de um comprimento de onda.



Fonte: Gonzalez (2010).

A Figura 3 apresenta o espectro eletromagnético, relacionando as bandas espectrais de acordo com seu comprimento de onda e frequência. Para melhor entendimento, os comprimentos de onda foram relacionados com coisas que têm aproximadamente o mesmo tamanho, e foram exemplificadas utilidades e aplicações de diversos comprimentos de onda que compõe o espectro eletromagnético.

Figura 3 - Espectro eletromagnético.



Fonte: Queiroz e Gomes (2001).

De acordo com Gonzalez (2010), o espectro eletromagnético pode ser representado em termos de comprimento de onda, frequência ou energia. A frequência ( $\nu$ ) e o comprimento de onda ( $\lambda$ ) se relacionam através da equação (1), onde  $c$  é a velocidade da luz ( $2,998 \times 10^8$  m/s).

$$\lambda = \frac{c}{\nu} \quad (1)$$

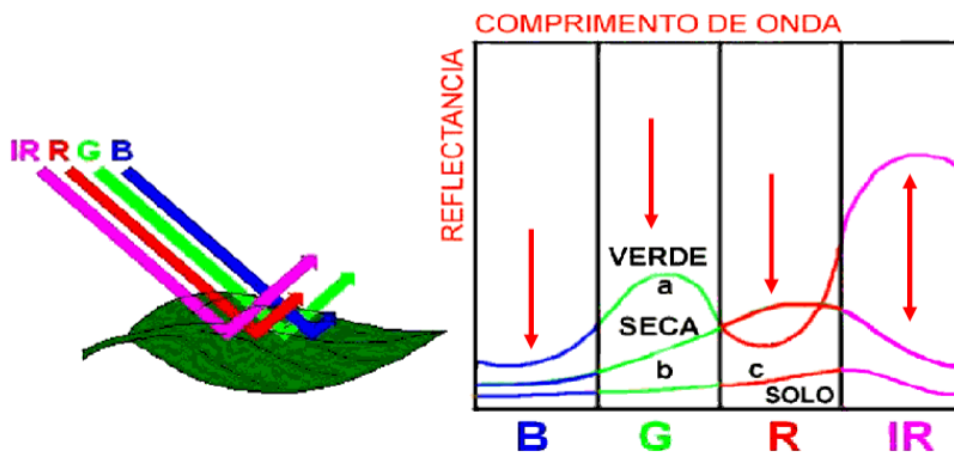
Segundo Ippotili-Ramilo (1998, *apud* BARROS, 2006), a utilização de dados obtidos por sensoriamento remoto é um método objetivo no levantamento de dados de uso e cobertura do solo e apresenta resultados precisos. Por este motivo, a aplicação de estudos com dados de SR em estimativas de área plantada e de rendimento vem se tornando comum ao redor do mundo.

Frações espectrais de radiação incidente na vegetação são refletidas, absorvidas e transmitidas, conforme suas características físico-químicas (JENSEN, 2009). O estudo da vegetação através do sensoriamento remoto está relacionado a fatores como a região em que se localizam as plantas, às condições de iluminação, à época do ano, à disponibilidade de recursos hídricos existentes e aos tipos e parâmetros das imagens analisadas (NOVO, 2010).



Novo e Ponzoni (2001) afirmam que as propriedades espectrais de uma folha são definidas em função de fatores ambientais e patogênicos, como sua composição, estrutura interna e morfologia. Deste modo, é comum que grupos geneticamente distintos apresentem diferença em seu comportamento espectral, pois alterações na pigmentação das plantas causam possíveis modificações nos valores de sua reflectância (PONZONI; SHIMABUKURO; KUPLICH, 2012). A Figura 4 apresenta de maneira ilustrativa as curvas de reflectância de três alvos nos comprimentos de onda referentes às regiões do espectro eletromagnético (EE) do azul (B), verde (G), vermelho (R), e infravermelho próximo (IR). Estes alvos são: vegetação verde (curva superior), vegetação seca (curva do meio) e solo (curva inferior). Destaca-se a alta reflectância da vegetação nas faixas espectrais do infravermelho (IR) e do verde (G).

Figura 4 - Assinatura espectral da vegetação seca, vegetação verde e solo em diferentes regiões do EE.



Fonte: Bosquilia (2012).

A cultura do café começou a ser estudada por técnicas de classificação de imagens obtidas por sensoriamento remoto desde o lançamento do primeiro satélite da série Landsat, em 1972 (MOREIRA *et al.*, 2004). Contudo, os primeiros resultados de estudos realizados com imagens do sensor MSS (*Multispectral Scanner Subsystem*) dos satélites Landsat 1, 2 e 3, que buscavam identificar e estimar áreas com café, não geraram bons resultados devido à dificuldade de discriminar os cafezais de seus alvos vizinhos (VELLOSO, 1974; VELLOSO; SOUZA, 1976; VELLOSO; SOUZA, 1978). Em estudos futuros, Tardin *et al.* (1992) comprovaram que ao utilizar imagens do sensor Landsat-5, no qual foi introduzida a banda infravermelho médio, o mapeamento da cultura do café começou a apresentar resultados promissores quando comparados a estudos anteriores.


Fatores pertinentes ao meio físico, como o relevo, que interfere no sombreamento e a geometria da reflexão da radiação, juntamente com padrões irregulares de tamanho, forma e estratificação de talhões, impossibilitam a determinação de regras estatísticas bem definidas que permitam a identificação de intervalos de nível de cinza em imagens de áreas cafeeiras com precisão razoável (VIEIRA *et al.*, 2006). Por este motivo, Moreira *et al.* (2004) concluíram que o analista deve obter informações complementares sobre a cultura da área de estudo e interferir nos resultados da classificação para se obter um resultado de precisão considerável.

#### **4.2.1 Sensores orbitais**

As informações adquiridas por sensoriamento remoto normalmente são obtidas por sensores, os quais captam a energia eletromagnética emitida ou refletida pelo objeto ou área de estudo. Estas medições de energia eletromagnética necessitam ser convertidas em informação utilizando técnicas de processamento digital de imagens (GONZALEZ, 2010). Para que um sensor esteja apto a obter e armazenar a quantidade de energia emitida ou refletida por um objeto ou superfície, é necessário que ele esteja afixado em uma plataforma estável a certa distância que permita uma contemplação de toda a região de interesse. Tais plataformas podem estar localizadas no solo, em aeronaves (tripuladas ou não), balões, ou orbitando a Terra (BATISTA; DIAS, 2005).

Os sensores podem ser de natureza ativa ou passiva, sendo esta característica definida em função da fonte de energia eletromagnética. Enquanto os sensores ativos utilizam a REM artificialmente emitida por radares, os sensores passivos captam a REM natural emitida ou refletida a partir da superfície terrestre, método de interação que consegue obter informações detalhadas sobre as propriedades químicas e físicas dos alvos de interesse (FIGUEIREDO, 2005). A Figura 5 exemplifica o processo de aquisição de uma imagem digital através de um sensor, definido pelas seguintes etapas: (a) Fonte de energia (iluminação); (b) Escolha de um elemento da cena; (c) Sistema de aquisição de imagens; (d) Projeção da cena no plano da imagem; (e) Imagem digitalizada.


Figura 5 - Exemplo do processo de aquisição de imagem digital.



Fonte: Gonzalez (2010).

O pixel é o elemento básico de uma imagem digital, normalmente apresentado em forma de um quadrado. A Figura 6 demonstra uma representação de uma imagem digital bidimensional, em que os valores digitais são apresentados em forma de matriz, "m" linhas por "n" colunas, e cada pixel possui atribuído a si um valor de tom de cinza.

Figura 6 - Representação de uma imagem digital bidimensional.



Fonte: Queiroz e Gomes (2001).

## ***4.2.2 Resolução das Imagens***

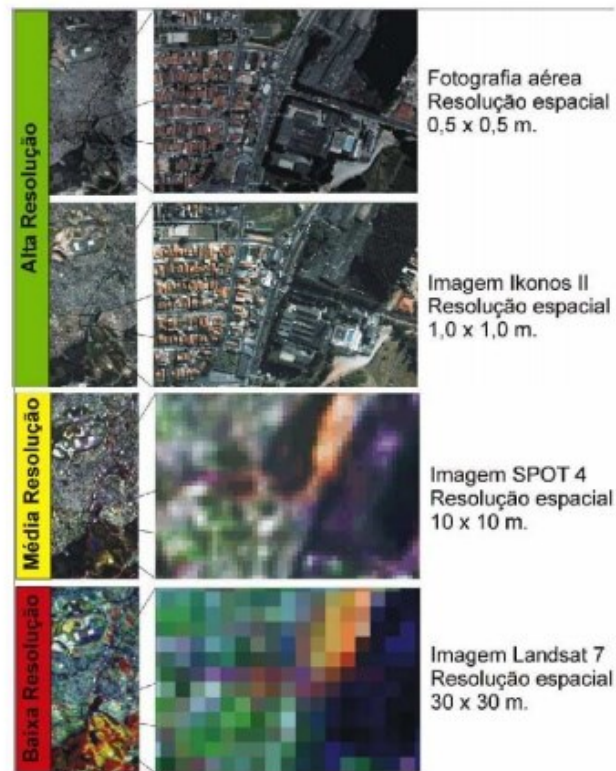
A potencialidade de um sensor está diretamente relacionada com a capacidade de captar informações detalhadas de REM refletida pelo alvo, e este detalhamento é definido através dos tipos de resoluções de cada sensor. Coelho e Brito (2007) definiram que toda imagem possui quatro tipos de resoluções, que são parâmetros fundamentais para análise de suas potencialidades de obtenção de dados. Estas resoluções são intituladas: resolução espacial, resolução radiométrica, resolução espectral e resolução temporal.

### **4.2.2.1 Resolução Espacial**

"A resolução espacial é uma medida do menor detalhe discernível em uma imagem". (GONZALEZ, 2010, p. 38). Moraes (2002) afirmou que a resolução espacial estipula o tamanho do menor alvo que pode ser distinguido em uma imagem. Para cada sensor pode ser definido o seu tamanho do pixel, correspondente à menor parcela imageada, e o fato do mesmo ser indivisível faz com que seja impossível identificar qualquer alvo dentro de um pixel, visto que seu valor é estabelecido pela reflectância da área total do solo referente ao mesmo (FIGUEIREDO, 2005).

Coelho e Brito (2007) relacionaram a resolução espacial com a eficiência do sensor para se captar informações de objetos pequenos. O nível de detalhamento das informações adquiridas (tamanho do pixel) e o tamanho total da área imageada dependem diretamente da distância entre o alvo ou superfície de interesse e a plataforma em que se encontra o sensor. Assim, Batista e Dias (2005) declararam que os sensores que se encontram situados a longas distâncias dos alvos, conseguem captar informações de uma área maior, porém, com um nível de detalhamento limitado. A Figura 7 traz uma demonstração de variadas resoluções espaciais, pertencentes a diferentes sensores.

Figura 7 - Imagens de diferentes sensores e resoluções espaciais.



Fonte: Melo (2002).

#### 4.2.2.2 Resolução Espectral

Sartori *et al.* (2009) afirmaram que uma imagem multispectral é formada por um agrupamento de cenas tomadas sincronicamente de uma determinada área, capturadas por um sensor capaz de registrar a REM em variados intervalos espectrais. Novo (2010) apontou que a resolução espectral é uma medida que mensura as dimensões da faixa espectral em que o sensor tem maior sensibilidade, e ressaltou também que quanto maior for o número de bandas em regiões diferentes do espectro eletromagnético e com larguras pequenas de comprimento de onda, melhor é a resolução espectral do sensor.

Meneses e Almeida (2012) definiram que os elementos fundamentais para que um sensor obtenha uma boa resposta espectral são: a quantidade de bandas que o sensor possui, a dimensão do comprimento de onda das bandas e as posições em que as bandas se situam no espectro eletromagnético. Os objetos situados na superfície terrestre podem responder espectralmente de formas diferentes, de acordo com a faixa do espectro eletromagnético,

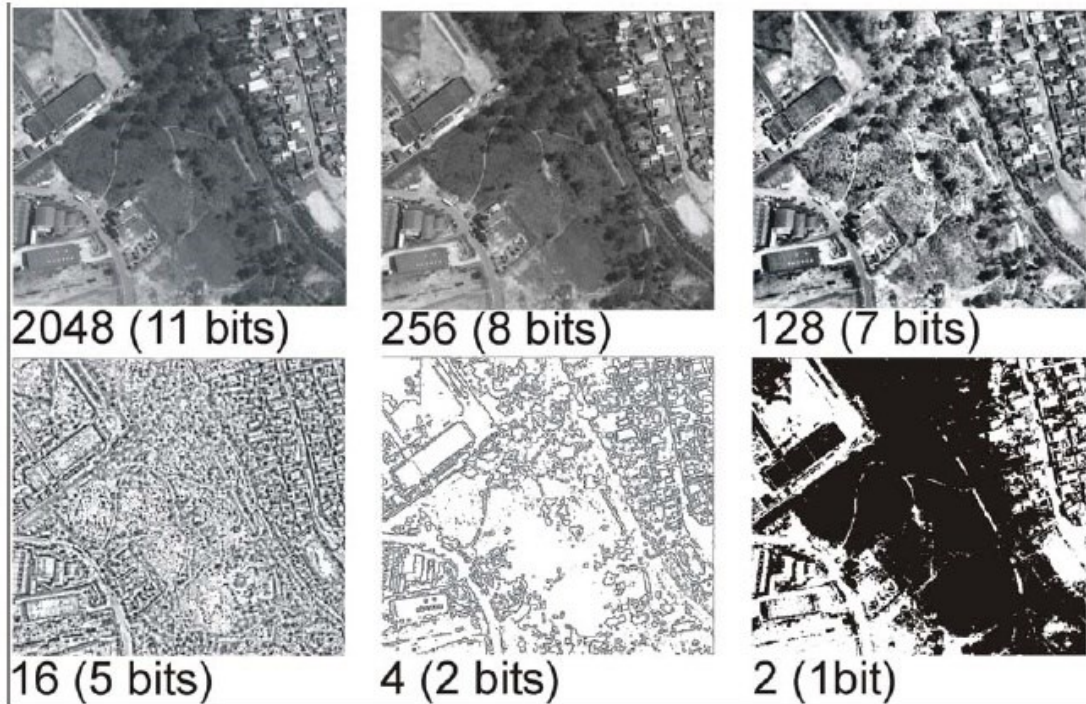
resultando em diferentes aplicações para cada banda dos sensores (NAIME *et al.*, 2014).

#### 4.2.2.3 Resolução Radiométrica

Moraes (2002) estabeleceu a resolução radiométrica como a capacidade que o sensor tem em identificar as maiores ou menores diferenças de energia emitida ou refletida pelos alvos, e afirmou que quanto maior a amplitude total dos valores de brilho, melhor é a resolução. Para Coelho e Brito (2007), a resolução radiométrica é um fator que está diretamente relacionado com a capacidade de um sensor de identificar grandes quantidades de tons de cinza dentro de apenas uma banda do espectro eletromagnético, sendo possível quantificar este fator com facilidade em imagens digitais, pois as mesmas devem possuir uma determinada quantidade de tons. Figueiredo (2005) declarou que o valor da radiação radiométrica caracteriza a intensidade de radiação que é emitida na área de interesse, intitulado "nível de cinza".

Ao se tratar de imagens digitais, a quantidade de tons que o sensor consegue armazenar está ligada a uma potência de 2. Tendo como exemplo, uma imagem que apresente 8 bits (*binary digits*) tem como quantidade de tons  $2^8$ , ou seja, 256 tons. A Figura 8 ilustra a diferença de resolução radiométrica em 6 imagens da mesma área urbana, em diferentes resoluções radiométricas.

Figura 8 - Diferença de resolução radiométrica em área urbana.



Fonte: Melo (2002).

#### 4.2.2.4 Resolução Temporal

Meneses e Almeida (2012) definiram a resolução temporal como o período de intervalo de tempo entre duas aquisições de imagens do mesmo objeto ou local. A resolução temporal possui relação com a observação repetida da mesma área utilizando imagens de um mesmo sensor, podendo ser resumida como o intervalo de tempo entre as aquisições de imagens (FERNANDES, 2009).

De acordo com Batista e Dias (2005), a resolução temporal é um dos elementos fundamentais na aplicação do monitoramento de mudanças que ocorrem na superfície terrestre, sejam estas mudanças causadas por ações naturais ou antrópicas. No estudo da agricultura, uma boa resolução temporal é essencial para um monitoramento primoroso de culturas agrícolas.

### 4.3 Processamento Digital de Imagens

O avanço da era digital proporcionou a criação de diversas técnicas de processamento de imagens, procedimentos que podem ser realizados afim de modificar imagens digitais para aperfeiçoar sua visualização e interpretação, de acordo com o objetivo desejado. Estas técnicas têm se expandido significativamente entre diversas aplicações em áreas como a medicina, geografia, biologia, astronomia, e o sensoriamento remoto, principalmente (GONZÁLEZ; RUIZ; ACOSTA, 2013).

Uma das maiores vantagens da utilização de imagens digitais é que as mesmas são passíveis de processamentos que permitem o realce ou a extração de informações específicas para interpretação subsequente (NOVO, 2010). Batista e Dias (2005) caracterizaram o Processamento Digital de Imagens (PDI) como o campo de conhecimento que lida com a modelagem matemática, análise, projeto e implementação em software e em hardware de sistemas digitais destinados à manipulação de informação em pixel, com o intuito de deixar a imagem mais propícia à interpretação, seja por seres humanos ou por máquinas, obtendo assim maior efetividade de armazenamento e transmissão.

Vários erros recorrentes nas imagens digitais são ocasionados devido a defeitos apresentados pelos sensores ou problemas na estabilidade da plataforma em que ele está contido. Há também a ocorrência de erros causados por outros fatores, como mau funcionamento do sensor, distorções nas imagens, deformações de escala, perda de contraste, registro incorreto de valores digitais, entre outros (MENESES; ALMEIDA, 2012). Estes erros presentes nas imagens precisam ser corrigidos ou amenizados por meio de processamentos digitais, gerando assim cenas mais limpas e livres de ruídos.



### 4.3.1 Calibração Radiométrica

O processo de captura de imagens digitais possui erros que constantemente geram degradações radiométricas, estes erros são ocasionados por falhas na calibração dos sensores e erros apresentados na transmissão dos dados (FIGUEIREDO, 2005). A calibração radiométrica é um procedimento essencial para gerar imagens multiespectrais e hiperespectrais com boa qualidade radiométrica e que apresentem informações coerentes com o referencial radiométrico conhecido (MORIYA, 2011).

Em uma imagem de sensores orbitais, os valores digitais apresentados são usados por conveniência no processamento de dados, e não representam os valores reais de reflectância dos alvos. Cenas diferentes possuem uma grande variação em sua energia registrada, que pode ser reduzida por meio da conversão da radiância espectral no sensor para a reflectância estratosférica no topo da atmosfera. (PEREIRA *et al.*, 1996). Deste modo, a conversão dos valores da imagem para reflectância se torna necessária quando será utilizada mais de uma imagem para análise, quando se deseja correlacionar dados biofísicos, ou na realização de mosaicos e séries temporais (ROBINOVE, 1982, *apud* GOERGEN, 2014

Asrar (1989, *apud* CHEN; HERZ, 1996) definiu a calibração radiométrica absoluta do sensor como a relação entre as radiâncias incidentes ao sensor e suas respostas. Slater (1985, *apud* CHEN; HERZ, 1996) determinou três categorias para os procedimentos utilizados com maior frequência na calibração radiométrica absoluta de sistemas de sensoriamento remoto: (1) calibração de pré-lançamento - método utilizado pelo DGI - INPE (Departamento de Geração de Imagens - Instituto Nacional de Pesquisas Espaciais); (2) calibração em órbita através de uma fonte de calibração a bordo do sensor (como é o caso do satélite Landsat-5, que possui um calibrador interno) - método utilizado pela EOSAT (*Earth Observation Satellite*) dos EUA; e (3) calibração em órbita com medidas recolhidas em um campo de referência na superfície terrestre.

### 4.3.2 Classificação de Imagens

O maior objetivo nos estudos do sensoriamento remoto com imagens de satélite é conseguir identificar os diferentes tipos de uso e cobertura da terra, como padrões de solo, tipos de vegetação, área urbana, água, rochas, entre outros. Para este fim, a classificação automática de imagens multiespectrais destina-se a relacionar cada pixel da imagem a uma classe de interesse, com base em suas propriedades espectrais (NOVO, 2010). Os pixels representados pela mesma classe apresentam padrões de textura, cor e tonalidade similares (FIGUEIREDO, 2005).

A classificação é de natureza não supervisionada quando não há nenhum conhecimento antecipado sobre as classes abordadas, fazendo com que o algoritmo do *software* utilizado defina de maneira automática as classes de cada pixel. Por outro lado, a classificação supervisionada possibilita que o analista interfira no processo atribuindo amostras para cada classe espectral, com base em seu conhecimento prévio (NOVO, 2010).

Ao tentar extrair informações sobre o uso e cobertura da terra através de dados obtidos por sensoriamento remoto, os cientistas especificam previamente se a classificação será de natureza rígida, com classes discretas e mutuamente exclusivas, ou de natureza nebulosa (*fuzzy*), onde há graus de pertinência dos pixels para cada classe (SEONG; USERY, 2001, *apud* JENSEN, 2009). Também é necessário definir se a classificação a ser realizada será baseada em pixels individuais (classificação pixel) ou se será utilizado algum algoritmo de segmentação de imagens para, posteriormente, proceder-se à análise de imagens orientada a objetos, que leva em consideração as características espectrais dos conjuntos de pixels contidos nas regiões individualizadas pela segmentação. Estes algoritmos atribuem relevância à informação espectral e espacial (HEROLD *et al.*, 2003; HODGSON *et al.*, 2003; TULLIS; JENSEN, 2003, *apud* JENSEN, 2009).

Após realizada a classificação, é preciso avaliar a qualidade da mesma afim de determinar a precisão dos pontos classificados em relação com a realidade. Este processo é realizado comparando o mapa gerado pela classificação com um mapa de referência sobre a área, gerando uma matriz de confusão, que representa a confiabilidade do processo através da correlação das informações sobre os mapas comparados. Feita a matriz de confusão, é possível gerar o coeficiente kappa, que representa o grau de concordância entre as informações e quantifica a precisão do resultado em um valor que varia de 0 a 1, em que 1 representa total

concordância dos dados classificados, e 0 ou valores negativos indicam a inexistência de concordância (PRINA; TRENTIN, 2015). Pode também ser calculado o índice de exatidão global, responsável por expressar a precisão da classificação calculando a razão entre os pontos classificados corretamente e o número total de pontos de referência.

#### 4.3.2.1 Classificação Pixel a Pixel

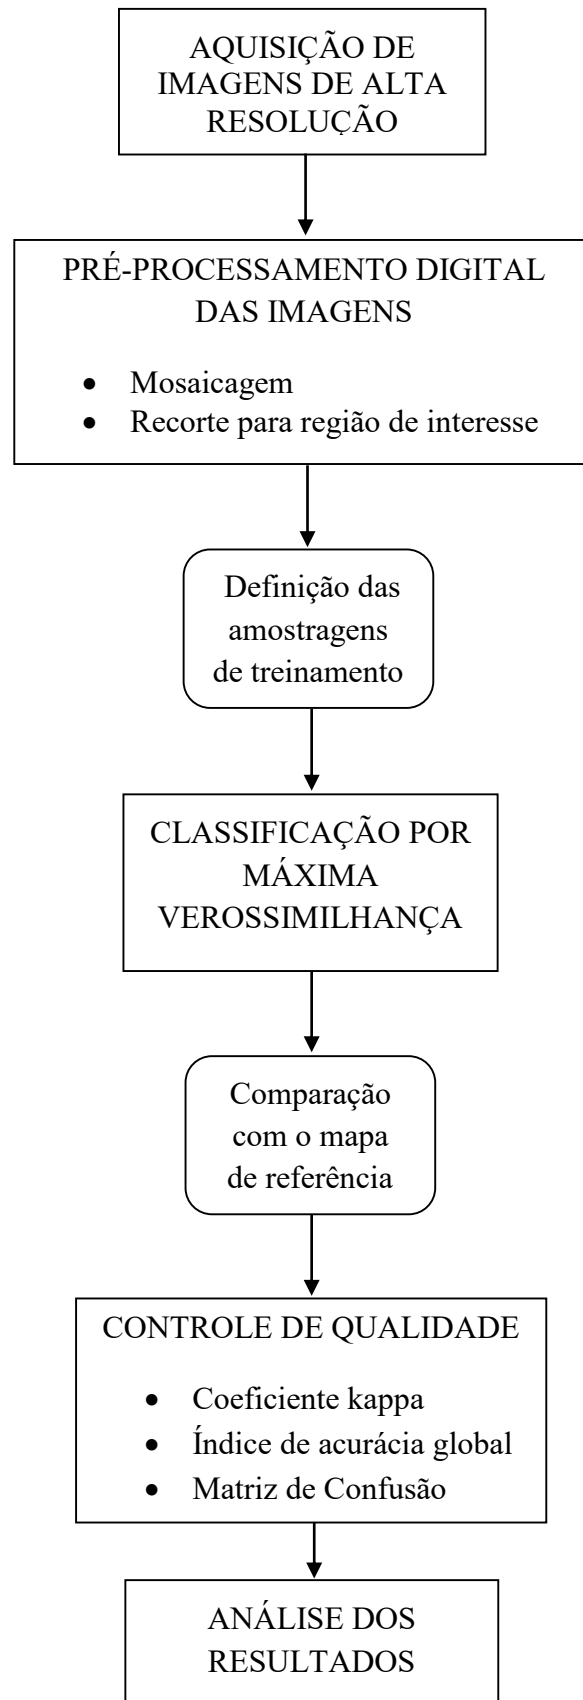
A classificação por Máxima Verossimilhança é a técnica de classificação pixel a pixel mais utilizada. De natureza supervisionada, o método realiza a classificação dos pixels baseando-se em estatísticas básicas dos dados da imagem como média, variância, e matrizes de covariância (JENSEN, 2009). Este método leva em consideração a ponderação das distâncias entre as médias dos níveis digitais das classes, com a utilização de parâmetros estatísticos. Em seguida, supõe que todas as bandas têm distribuição normal e verifica a probabilidade que cada pixel tem de pertencer à determinada classe (INPE, 2008).

O resultado final de uma classificação de imagens pelo método da Máxima Verossimilhança é um mapa temático que descreve a distribuição espacial das classes selecionadas (ZHANG; FOODY, 2001, *apud* PRADO; GALO, 2002). Meneses e Almeida (2002) afirmaram que, devido às premissas estatísticas do classificador, as áreas de treinamento precisam ser definidas com bastante representatividade, caso contrário, a imagem classificada apresentará imprecisões.

## **5 MATERIAL E MÉTODOS**

Este tópico apresenta os materiais que foram utilizados neste trabalho e a metodologia que foi empregada em sua execução. A realização das atividades foi organizada de acordo com o fluxograma apresentado a seguir (Figura 9).

Figura 9 - Fluxograma de organização das atividades.

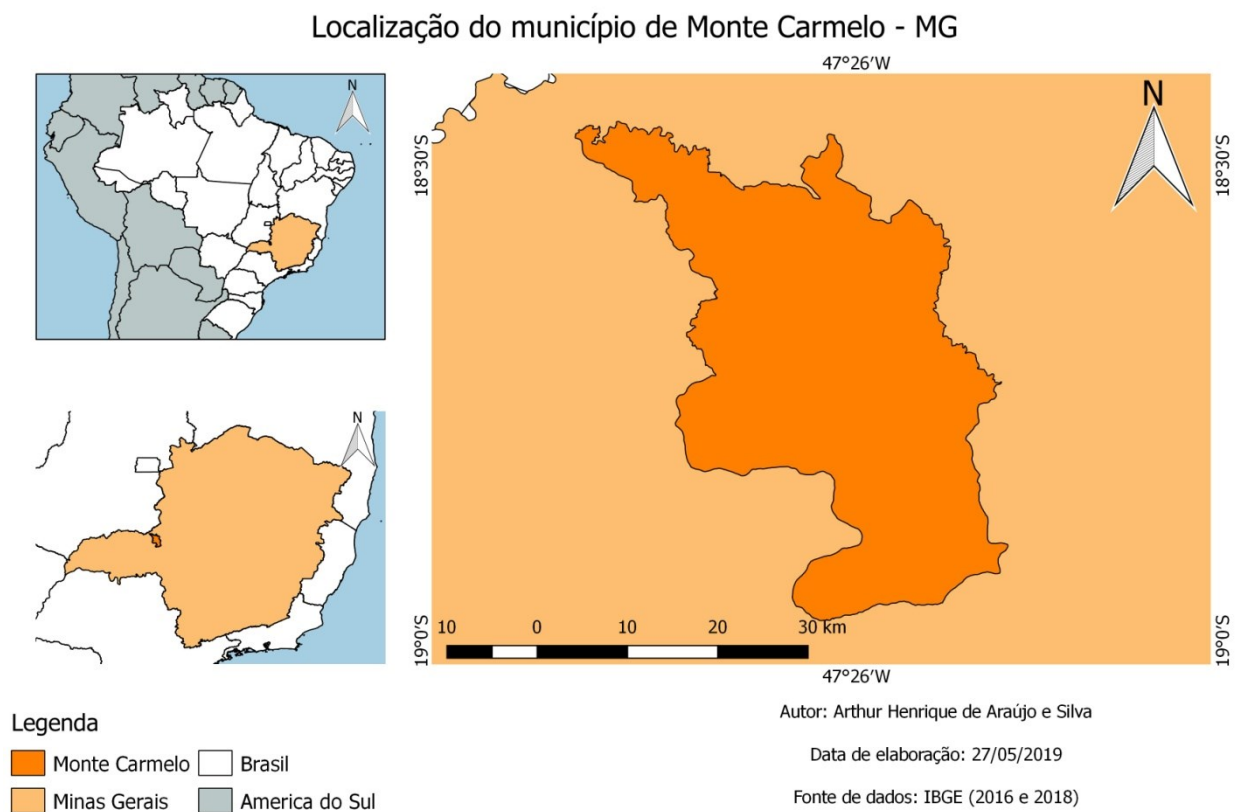


Elaboração: O autor.

## 5.1 Área de estudo

Para a escolha da área de estudo, foi necessário definir uma área com a existência de várias lavouras de café extensivas e bem distribuídas espacialmente, e com dados disponíveis sobre o mapeamento cafeeiro da região, para servir de verdade de campo e permitir a realização de um controle de qualidade pós classificação. Assim, a área de estudo definida foi o município de Monte Carmelo - MG, situado na mesorregião do Triângulo Mineiro e Alto Paranaíba, pois há um vasto conhecimento sobre as características da região e seu parque cafeeiro foi mapeado recentemente com dados disponibilizados online de forma gratuita. Seu relevo possui trechos aplainados e ondulados, o solo predominante é o latossolo vermelho e o clima é tropical e tropical de altitude. A Figura 10 apresenta um mapa de localização do município.

Figura 10 - Mapa de localização da área de estudo (Monte Carmelo - MG).



Elaboração: O autor.

## 5.2 Material

Os materiais que foram utilizados na realização deste trabalho são:

- Imagens do satélite PlanetScope que recobrem o município de Monte Carmelo - MG;
- Arquivos KML do mapeamento cafeeiro da CONAB (verdade de campo), referentes ao município de Monte Carmelo - MG;
- Dados de mapeamento e área plantada fornecidos pelo Geoportal do Café;
- Notebook Dell Inspiron 14R para fins de processamento de dados;
- *Software* ENVI Classic 5.1 para pré-processamentos;
- *Software* Qgis para confecção de mapas;
- *Software* Microsoft Office Excel 2007 destinado a realização de operações e geração de gráficos;
- *Software* Microsoft Office Word 2007 destinado a elaboração da parte escrita do trabalho.

### 5.2.1 *Satélite PlanetScope*

A constelação de satélites PlanetScope constitui a maior constelação de satélites de sensoriamento remoto, formada por aproximadamente 120 satélites capazes de adquirir imagens com 3,125 metros de resolução espacial e 12 bits de resolução radiométrica. Possui uma banda pancromática e quatro bandas multiespectrais: azul (455nm a 515 nm), verde (500 nm a 590 nm), vermelho (590 nm a 670 nm) e infravermelho próximo (780 nm a 860 nm). As imagens são processadas (ortorretificadas, realçadas, mosaicadas e equalizadas) e depois entregues para o usuário final. Possui boa resolução temporal, visto que a revisita é diária e as imagens são disponibilizadas para venda diariamente em uma plataforma digital online.

## 5.3 Metodologia


### 5.3.1 Aquisição das imagens

As imagens foram adquiridas no site da Planet Labs, Inc., empresa americana que comercializa imagens da superfície terrestre do satélite PlanetScope. Foram escolhidas imagens que recobrem todo o município de Monte Carmelo - MG priorizando dias em que o céu se encontrava livre de nuvens para se obter imagens limpas e com erros minimizados. Sendo assim, foram baixadas imagens do dia 05/05/2020 pois as mesmas apresentavam boa visibilidade e tempo limpo. Foram necessárias 14 imagens para recobrir toda a região de interesse (Monte Carmelo – MG).

### 5.3.2 Mosaicagem

O processo de mosaicagem foi realizado no *software* ENVI Classic 5.1 através do método georreferenciado, que funciona localizando regiões com as mesmas coordenadas nas imagens e unindo-as, até que sejam transformadas em uma imagem só. Na aba de ferramentas *Basic Tools > Mosaicking > Georeferenced* foram selecionadas as 14 imagens, e assim foi gerado o *Template*, que é similar a uma pré-visualização do mosaico antes do mesmo ser processado.

Figura 11 – *Template* gerado para pré-visualização do mosaico.





Fonte: O autor.

Após analisar o *Template* para confirmar que o mosaico a ser gerado estava correto, a etapa seguinte foi a definição dos parâmetros de mosaicagem de acordo com as particularidades das imagens. O tamanho do píxel de saída não foi alterado e foi mantido o mesmo dos arquivos de entrada (3 metros). O modelo de reamostragem escolhido foi o modelo matemático conhecido como Vizinho Mais Próximo, e assim, na aba *File > Apply* foi possível gerar o mosaico com sucesso.


Figura 12 – Mosaico de imagens recobrindo o município de Monte Carmelo – MG.



Fonte: O autor.

Em seguida, o mosaico foi importado para o *software* Qgis para recorte e definição da região de interesse. Através da ferramenta *Raster > Extrair > Recorte* foi possível delimitar a região do mosaico que será trabalhada através do recorte de uma camada vetorial (*shapefile* do limite municipal de Monte Carmelo – MG). Assim, a imagem foi recortada e a área de interesse foi definida como mostra a Figura 13 abaixo.

Figura 13 – Mosaico de imagens recortado para o município de Monte Carmelo – MG.

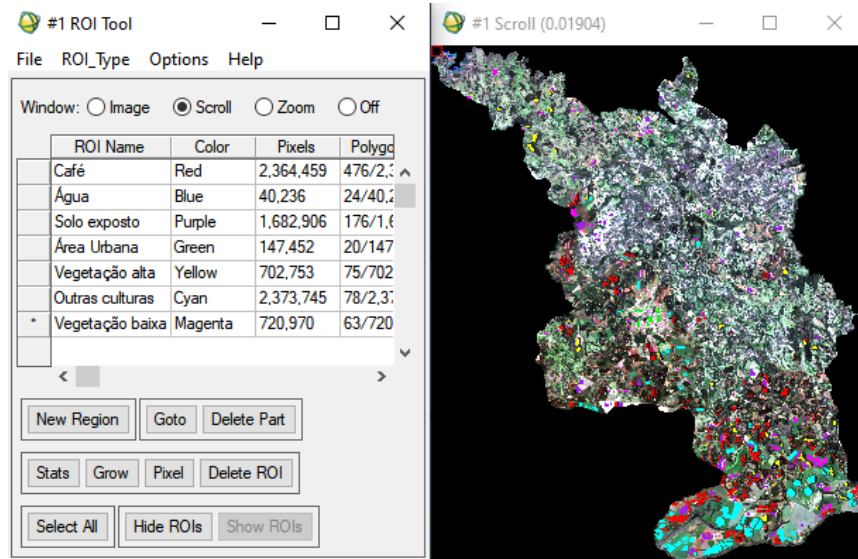


Fonte: O autor.

### 5.3.3 Classificação das imagens

A classificação pixel a pixel foi realizada no *software* ENVI Classic 5.1. Na classificação supervisionada por Máxima Verossimilhança, torna-se necessário a realização de uma boa amostragem das regiões de interesse para que o classificador relacione o pixel a uma classe com maior propriedade. Ao atribuir a cada classe de interesse uma assinatura espectral bem definida, o resultado gerado pela classificação é mais acurado. Na aba de ferramentas *Basic Tools > Region Of Interest > ROI Tool* é possível iniciar o processo de amostragem definindo amostras na imagem para cada classe de uso e cobertura do solo que é desejada na classificação. Foram escolhidas as seguintes classes: Café, Água, Solo exposto, Área Urbana, Vegetação Alta, Outras Culturas e Vegetação Baixa. Na Figura 14 pode-se observar quantos pixels foram coletados para a amostra de cada classe e como ficou distribuído espacialmente nossas amostras na região do município.

Figura 14 – Processo de amostragem concluído.



Fonte: O autor.

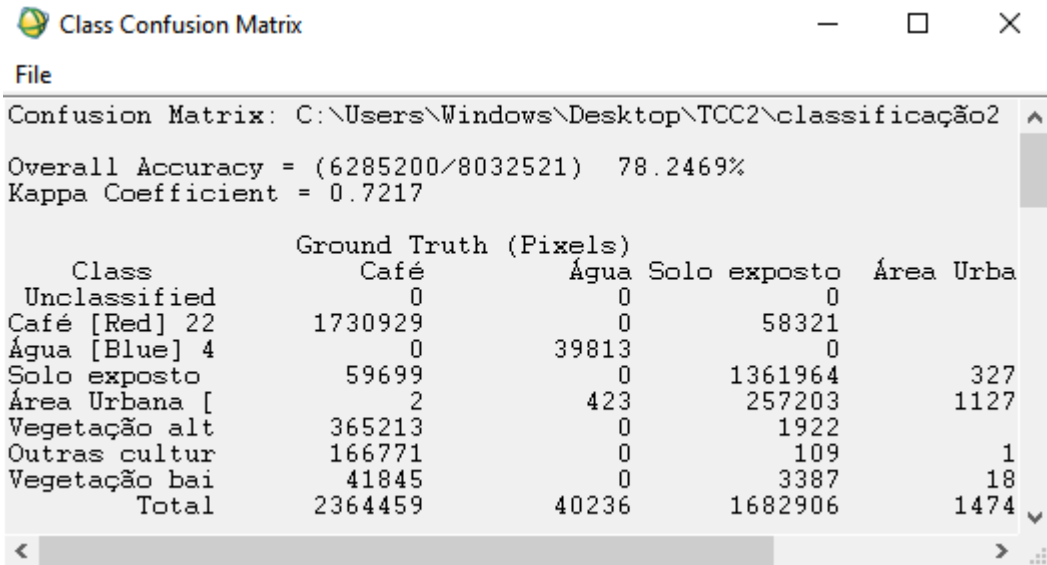
Todo a amostragem foi realizada comparando regiões da imagem referentes à amostra coletada com o mapa do Geoportal do Café. Este projeto de mapeamento do parque cafeeiro de Minas Gerais foi realizado pelo governo em parceria com a Emater-MG, Embrapa, CONAB, entre outras, e realizou o levantamento da área plantada com o uso de imagens de satélite e com validação dos dados em campo por extensionistas da Emater-MG. Portanto, suas informações são precisas e foram essenciais para uma amostragem confiável das regiões em que se encontra a cultura do café. Após o processo ser concluído, iniciou-se a classificação supervisionada pelo método da Máxima Verossimilhança através da ferramenta *Classification > Supervised > Maximum Likelihood*.

Após gerado o resultado, foi aplicado um filtro Kernel de matriz 5x5 de correção majoritária para obter polígonos mais contínuos, corrigindo pixels de outras classes classificados de forma errada dentro da classe correta. A ferramenta é acessada pela aba *Classification > Post Classification > Majority/Minority Analysis*. Este filtro fez com pixels em pequenas quantidades que estavam situados dentro de um alto número de pixels de outra classe fossem corrigidos para a classe em maioria, reduzindo erros como pixels classificados como vegetação alta dentro de um agrupamento majoritário de pixels de café, ou vice-versa. A classificação foi gerada com sucesso e o arquivo foi importado para o *software* Qgis para confecção de mapas e produtos finais.

### 5.3.4 Controle de qualidade

O controle de qualidade da classificação das imagens foi realizado no *software* ENVI Classic 5.1 através da ferramenta *Classification > Post Classification > Confusion Matrix > Using Ground Truth ROIs*. Este comando possibilita a avaliação da classificação através da geração da Matriz Confusão, do Coeficiente Kappa e do Índice de Acurácia Global utilizando as amostras de solo obtidas no processo de amostragem como verdade de campo. A Matrix Confusão permitiu estimar quantos pixels foram classificados erroneamente e o Coeficiente Kappa definiu o grau de concordância da classificação digital com a verdade de campo, avaliando o resultado com um valor de 0 a 1. Com a ferramenta *Classification > Post Classification > Class Statistics* foi possível saber qual foi a área total classificada como café, e assim comparou-se este valor com o total de área plantada em hectares segundo o mapeamento do Geoportal do Café. O fato de o café ser uma cultura perene permite que mapeamentos de anos anteriores sejam tomados como referência, pois há grande probabilidade de que as áreas plantadas com café não tenham tido seu cultivo alterado.

Figura 15 – Resultado parcial do controle de qualidade da classificação.



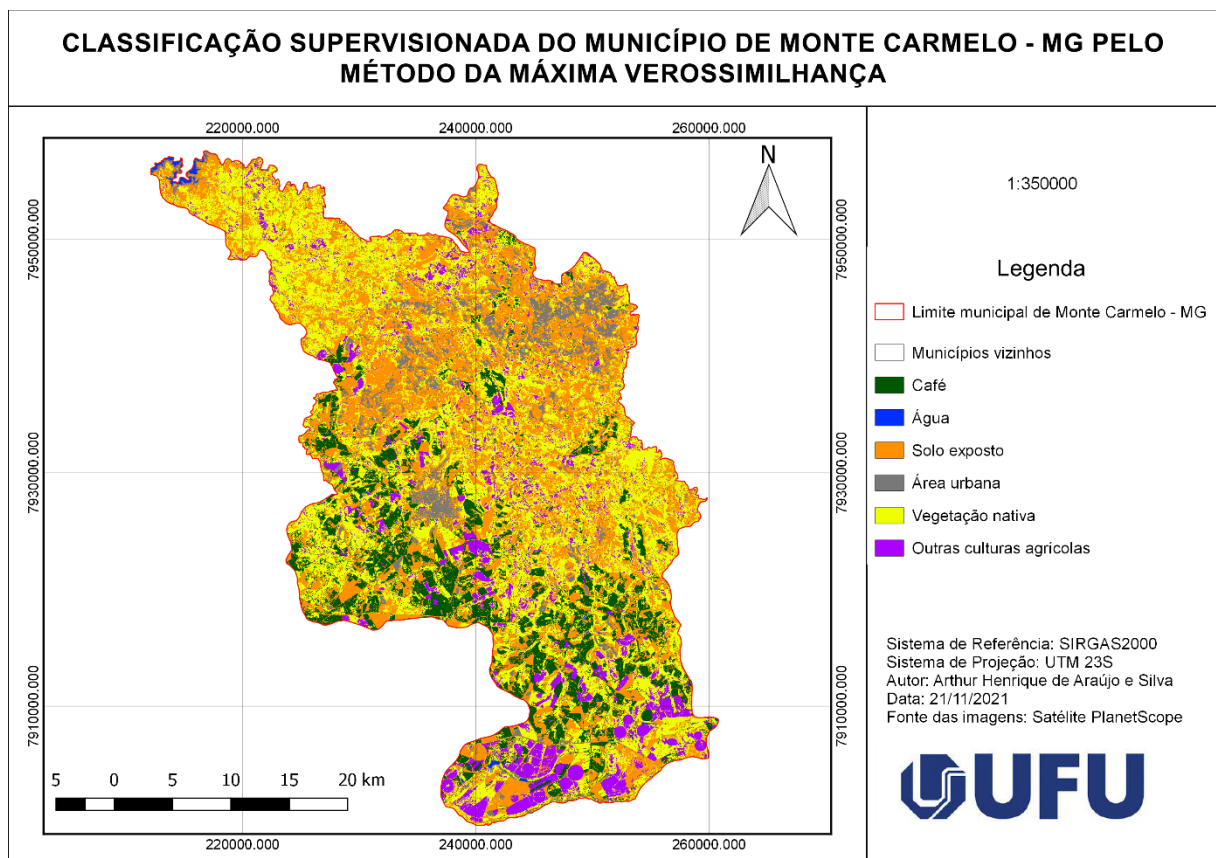
Class	Ground Truth (Pixels)			
	Café	Água	Solo exposto	Área Urba
Unclassified	0	0	0	
Café [Red] 22	1730929	0	58321	
Água [Blue] 4	0	39813	0	
Solo exposto	59699	0	1361964	327
Área Urbana [Vegetação alt]	2	423	257203	1127
Outras cultur	365213	0	1922	
Vegetação bai	166771	0	109	1
Vegetação bai	41845	0	3387	18
Total	2364459	40236	1682906	1474

Fonte: O autor.

## 6 RESULTADOS OBTIDOS

A Figura 16 apresenta um mapa com o resultado da classificação supervisionada pelo método da Máxima Verossimilhança no município de Monte Carmelo – MG utilizando imagens do satélite PlanetScope de resolução espacial de 3m. Para melhor visualização, as classes Vegetação Alta e Vegetação Baixa foram unidas e transformadas em Vegetação Nativa, pois separadas estavam poluindo visualmente o mapa e deixando-o confuso com informações sobrecarregadas. Já com as classes unificadas, a visualização melhorou consideravelmente.


Figura 16 – Mapa resultante da classificação de imagens do município de Monte Carmelo – MG.



Fonte: O autor.

A Figura 17 apresenta uma imagem de satélite de dentro do município de Monte Carmelo que recobre a área urbana e seu entorno.


Figura 17 – Área ampliada da área urbana do município de Monte Carmelo – MG e seu entorno.



Fonte: O autor.

Já a Figura 18 mostra como ficou o resultado da classificação na região da Figura 17. Observa-se que esta é uma área em que quase todas as classes de uso e cobertura da terra da classificação estão representadas, com exceção apenas da classe Água, que se encontra apenas em pequenos reservatórios ao longo do município e em um corpo d'água na extremidade norte.

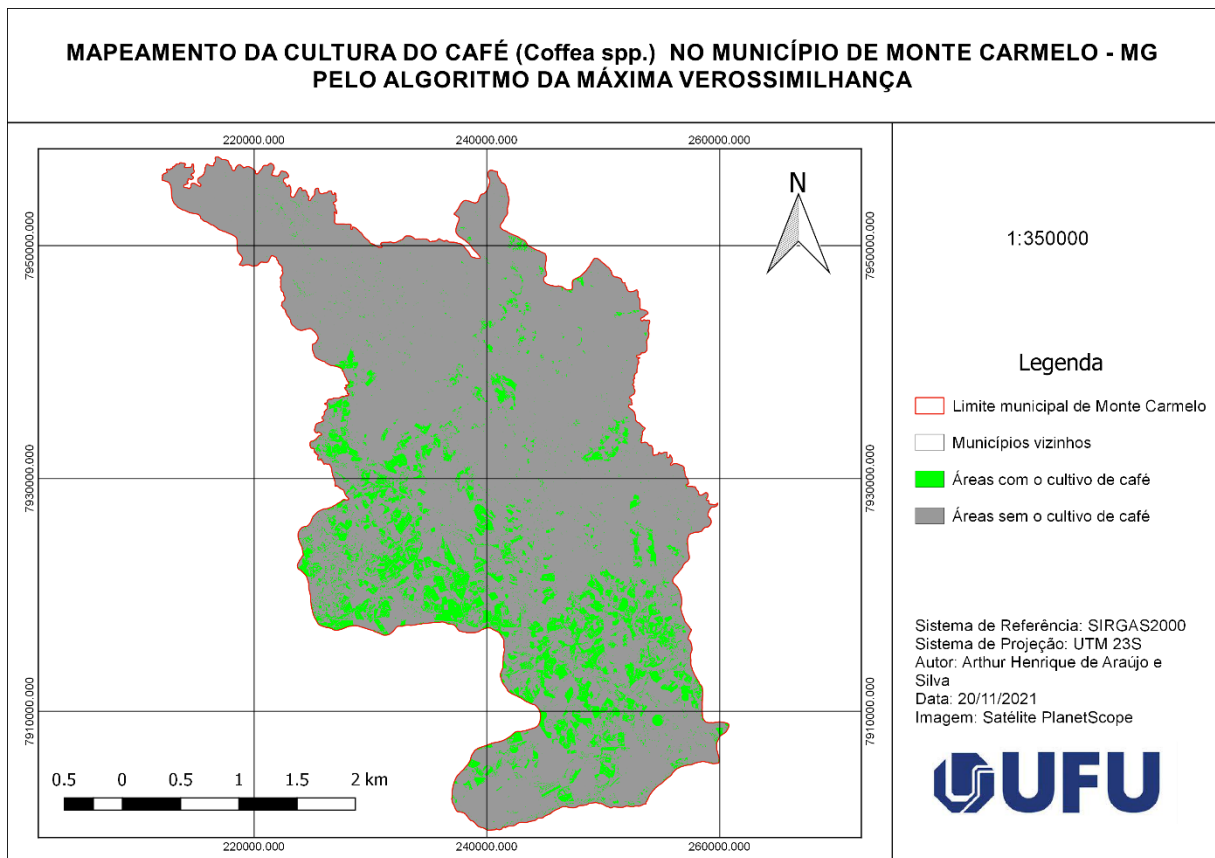
Figura 18 – Resultado da classificação na área da Figura 17.



Fonte: O autor.

Já o mapa abaixo apresentado na Figura 19 busca exibir de forma mais objetiva o mapeamento da cultura cafeeira do município de Monte Carmelo - MG, minimizando a quantidade de classes de forma que a área de interesse seja melhor visualizada. Assim, pode-se observar com clareza as regiões do município que apresentam cultivo de café, e as regiões que não apresentam.

Figura 19 – Áreas cafeeiras dentro do município de Monte Carmelo – MG.

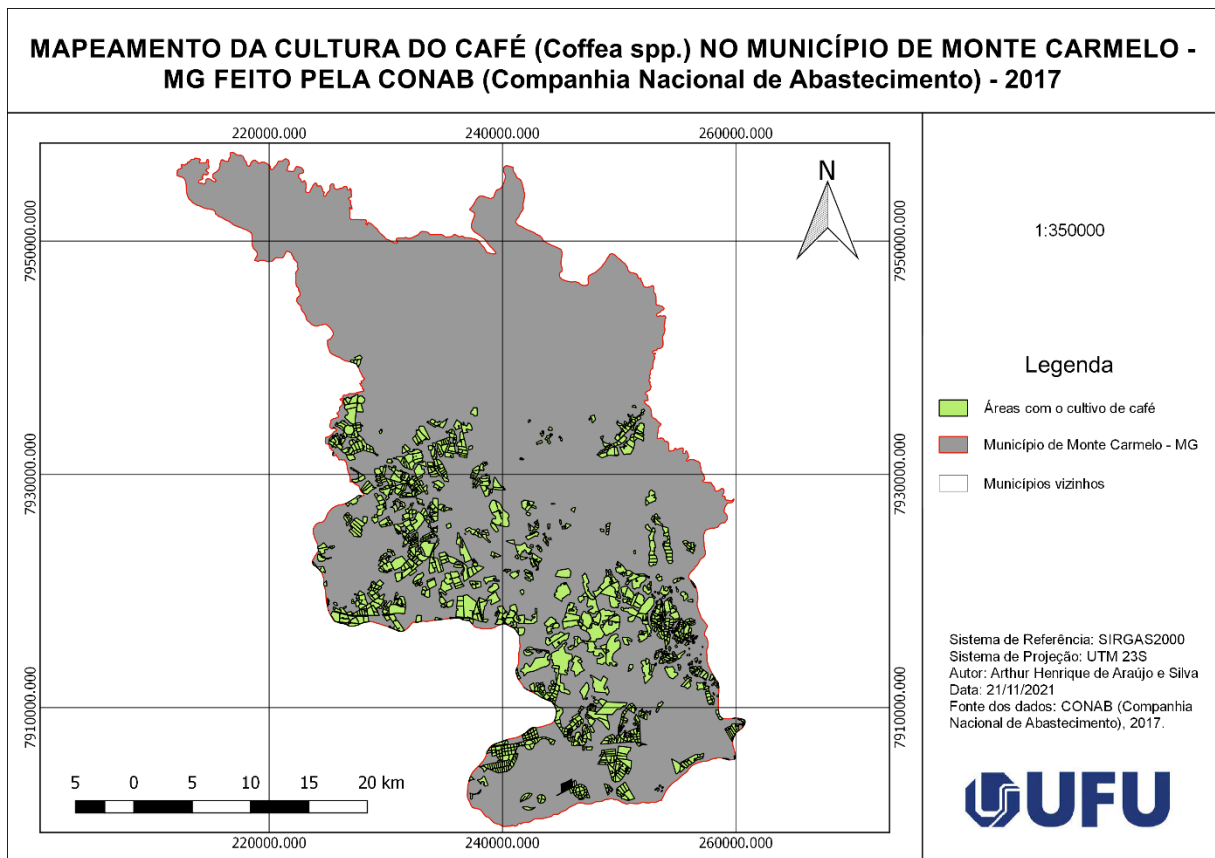


Fonte: O autor.

A Figura 20 mostra um mapeamento da cultura do café em Monte Carmelo – MG realizado pela CONAB em 2017 e é considerado um mapa de referência. Ao realizar uma comparação visual dos mapas, percebe-se que grande parte das regiões identificadas como plantação de café pela CONAB em 2017 continuam com a prática da cultura ainda em 2020. As regiões sul e centro-oeste do município são os lugares em que estão mais concentradas as áreas cafeeiras em ambos os mapeamentos, enquanto a região norte se mostra quase isenta da prática cafeeira, apresentando poucas culturas agrícolas, muito solo exposto e vegetação nativa.



Figura 20 – Mapeamento cafeeiro do município de Monte Carmelo – MG segundo dados da CONAB (2017).

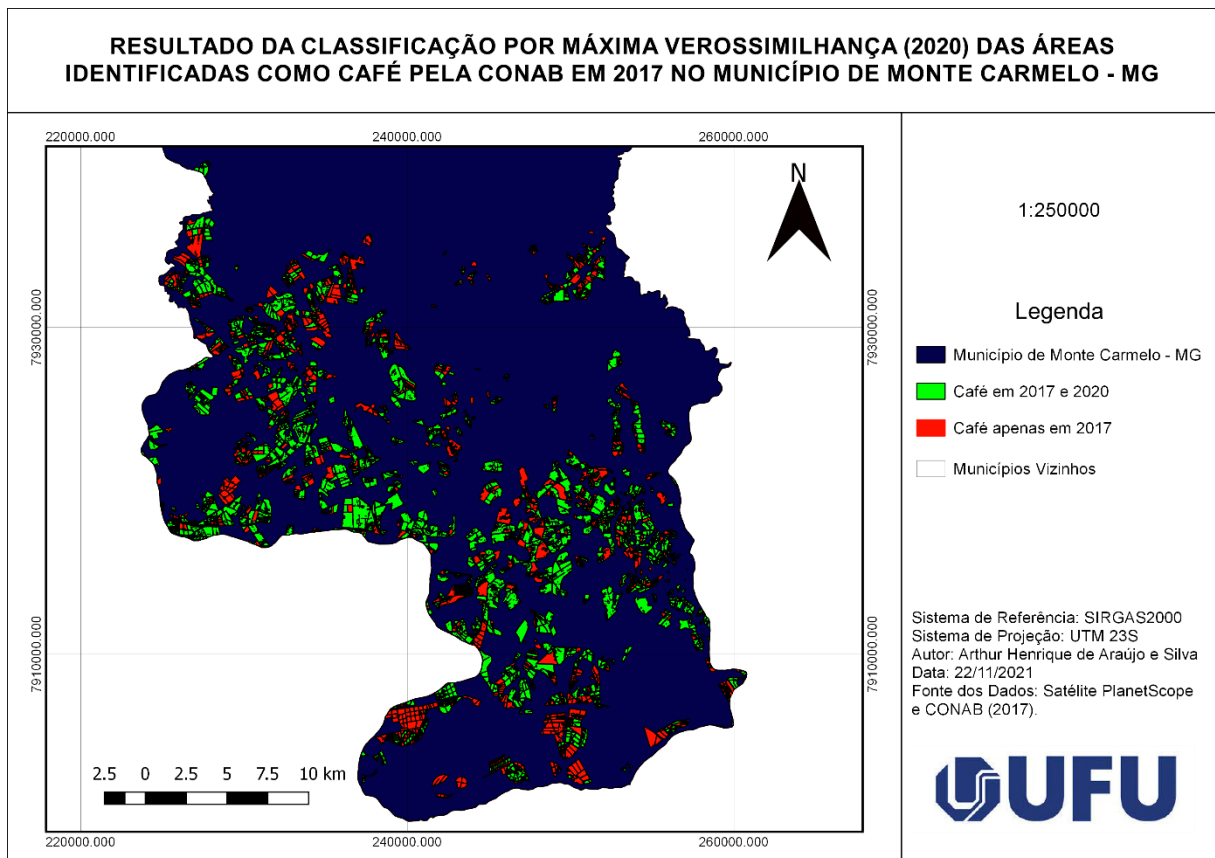


Fonte: O autor.

Foi criada uma camada de pontos com um ponto no centroide de cada polígono do mapeamento da CONAB em 2017. Como são 1498 polígonos, distribuiu-se 1498 pontos. Através da ferramenta “Contar pontos em polígonos” do software Qgis, contou-se quantos destes pontos se situaram dentro dos polígonos de café da classificação de 2020. No total, 914 pontos foram classificados novamente como café. Ou seja, 61,01% dos pontos que estavam dentro dos polígonos classificados como café pela CONAB em 2017 também se situaram dentro dos polígonos classificados como café na classificação supervisionada pelo método da Máxima Verossimilhança no ano 2020.

Para fins de comparação da classificação realizada no trabalho com o mapeamento da CONAB em 2017, foi elaborado o mapa apresentado abaixo na Figura 21. O mapa não engloba toda a região de Monte Carmelo pois tem como objetivo realizar uma comparação apenas dos polígonos referentes às áreas identificadas como café pela CONAB em 2017, e não há nenhum deles na região norte do município. Todos os polígonos do mapa são glebas de café segundo o mapeamento da CONAB de 2017. Os polígonos em cor verde foram as áreas que também foram classificadas como café na classificação por Máxima Verossimilhança de 2020, enquanto os polígonos em vermelho representam áreas que foram identificadas como outro tipo de classe.

Figura 21 – Resultado da classificação de 2020 das áreas dos polígonos identificados como café pela CONAB em 2017.



Fonte: O autor.

A área total de café em 2017 no município de Monte Carmelo - MG segundo dados extraídos dos polígonos do mapeamento da CONAB é de 190.744.000 m<sup>2</sup> ou 19.074,4 hectares. Em 2018 segundo o Geoportal do café, o município possuía 185.490.000 m<sup>2</sup> ou 18.549 hectares de área plantada de lavouras cafeeiras. Já em 2020 a área total de café do município, baseada

nas informações da classificação supervisionada pelo método da Máxima Verossimilhança realizada neste trabalho, apresenta 175.265.649 m<sup>2</sup> ou 17.526,56 hectares. Observamos que ao longo do período de tempo observado (2017 a 2020), a área total ocupada por lavouras de café no município sofreu reduções, sendo que os dados de 2017 e 2018 são precisos e confiáveis, enquanto os resultados do ano de 2020 foram gerados através da classificação deste trabalho e possuem maior margem de erro.

Segundo o processamento de controle de qualidade do software Envi que utiliza as amostras obtidas durante o processo de amostragem como verdade de campo, o Índice de Acurácia Global da classificação foi de 78,25% e o Coeficiente Kappa foi de 0,7217. A Tabela 01 apresenta a Matrix de Confusão com a unidade de pixels e a Tabela 02 apresenta a Matriz de Confusão em porcentagem.

Tabela 01 – Matriz de Confusão da Classificação com a unidade em pixels.

<b>VERDADE DE CAMPO</b> <b>CLASSES</b>	<b>Café</b>	<b>Água</b>	<b>Solo Exposto</b>	<b>Área Urbana</b>	<b>Veg. Alta</b>	<b>Outras Culturas</b>	<b>Veg. Baixa</b>	<b>Total</b>
<b>Café</b>	1730929	0	58321	4	41260	86875	9887	1927276
<b>Água</b>	0	39813	0	0	0	0	0	39813
<b>Solo Exposto</b>	59699	0	1361964	32750	3891	23365	9038	1490707
<b>Área Urbana</b>	2	423	257203	112745	232	10	142	370757
<b>Veg. Alta</b>	365213	0	1922	1	654165	7	152	1021460
<b>Outras Culturas</b>	166771	0	109	146	1478	1952887	269054	2390445
<b>Veg. Baixa</b>	41845	0	3387	1806	1727	310601	432697	792063
<b>Total</b>	2364459	40236	1682906	147452	702753	2373745	720970	8032521

Elaboração: O autor.

Tabela 02 – Matriz de Confusão da Classificação em porcentagem.

<b>VERDADE DE CAMPO</b> <b>CLASSES</b>	<b>Café</b>	<b>Água</b>	<b>Solo Exposto</b>	<b>Área Urbana</b>	<b>Veg. Alta</b>	<b>Outras Culturas</b>	<b>Veg. Baixa</b>	<b>Total</b>
<b>Café</b>	73,21	0	3,47	0	5,87	3,66	1,37	23,99
<b>Água</b>	0	98,95	0	0	0	0	0	0,5
<b>Solo Exposto</b>	2,52	0	80,93	22,21	0,55	0,98	1,25	18,55
<b>Área Urbana</b>	0	1,05	15,28	76,46	0,03	0	0,02	4,62
<b>Veg. Alta</b>	15,45	0	0,11	0	93,09	0	0,02	12,72
<b>Outras Culturas</b>	7,05	0	0,01	0,1	0,21	82,27	37,32	29,76
<b>Veg. Baixa</b>	1,77	0	0,20	1,22	0,25	13,08	60,02	9,86
<b>Total</b>	100	100	100	100	100	100	100	100

Elaboração: O autor.

A Matriz de Confusão evidencia e comprova em números que as classes que são confundidas frequentemente pelo algoritmo classificador são: Café e Vegetação Alta, Solo Exposto e Área Urbana, Outras Culturas e Vegetação Baixa. Isto ocorre pois estas classes apresentam resposta espectral muito semelhante uma da outra. O Índice de Acurácia Global e o Coeficiente Kappa apresentaram resultados satisfatórios, visto que o IAG foi próximo a 80% e o Coeficiente Kappa usualmente define uma boa classificação quando seu valor é acima de 0,7.

## 7 CONCLUSÃO

Através da análise dos resultados obtidos neste trabalho, é possível concluir que o algoritmo classificador da Máxima Verossimilhança do software Envi aliado ao uso de imagens de satélite de alta resolução espacial, consegue discriminar bem o café de outros tipos de alvos, com exceção da classe Vegetação Alta, pela qual o café foi consideravelmente confundido na classificação. Ambos os tipos de uso e cobertura do solo são bem parecidos quando observados por uma imagem de satélite, principalmente quando se trata de lavouras densas com cafezais altos e volumosos. As classes Área Urbana e Solo Exposto também foram frequentemente confundidas pois em muitos casos ambas apresentam resposta espectral idêntica, com áreas completamente brancas quando vistas na composição RGB de cores reais. As classes Vegetação Baixa e Outras Culturas também ocasionaram confusão na classificação pois muitas destas culturas agrícolas são culturas de baixa altura e coloração verde clara, muito similar a áreas de vegetação baixa.

Os índices numéricos apresentados no controle de qualidade da classificação também mostram que a classificação obteve um resultado satisfatório. Com o mapa apresentado na Figura 20, é possível concluir que a classificação obteve um resultado de alta acurácia, mas pouca precisão. A alta acurácia é baseada no fato de que o valor total de área plantada de café no município de Monte Carmelo calculada no trabalho, apresentou um valor próximo aos valores da CONAB de 2017 e do Geoportal do Café de 2018. Porém, muitas das glebas de café identificadas pela CONAB em 2017 não foram identificadas novamente como café em 2020 (vide Figura 20). Então, apesar de a classificação ter identificado a grande maioria de lavouras de café nas mesmas regiões do município que os outros mapeamentos identificaram (sul e centro-oeste) e com um valor próximo de área total comparado a anos anteriores, a localização exata de algumas glebas de café não coincidiram, o que tornou a classificação um pouco imprecisa.

Transformando os dados do resultado da classificação de raster para vetor, é possível identificar o tamanho de cada gleba de café do município utilizando ferramentas do software Qgis. Recomenda-se para trabalhos futuros de classificação supervisionada de imagens de satélite de alta resolução espacial para discriminação de café, a acrescentar o procedimento de segmentação de imagens durante o processo de amostragem. Tal procedimento pode auxiliar significativamente a reduzir a confusão do algoritmo em diferenciar as classes Café e Vegetação Alta, pois apesar da resposta espectral similar, o formato e tamanho destes tipos de uso e

cobertura da terra são bem distintos entre si, e podem ser facilmente diferenciados por uma segmentação para uma classificação mais precisa.

## REFERÊNCIAS

- ABIC - **Associação Brasileira da Indústria de Café**. Disponível em: . Acesso em: 12 abr. 2017.
- BAATZ, M.; BENZ, U.; DEHGHANI, S.; HEYNEN, M.; HÖLTJE, A.; HOFMANN, P.; LINGENFELDER, I.; MIMLER, M.; SOHLBACH, M.; WEBER, M.; WILLHAUCK, G. **e-Cognition Professional User Guide 4**. München, Germany: Definiens Imaging GmbH, 2004. 486 p.
- BARROS, M. A. **Geotecnologias como contribuição ao estudo do agroecossistema cafeeiro de minas gerais em nível municipal**. 2006. 157 f. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006.
- BATISTA, T. G; DIAS, W. N. **Introdução ao Sensoriamento Remoto e Processamento de Imagens**. Instituto de Pesquisas Espaciais (INPE), 2005.
- BENVENUTI, Fernando Aparecido et al. **Relação de índices espectrais de vegetação com a produtividade da cana-de-açúcar e atributos edáficos**. 2005.
- BOSQUILIA, R. W. D. **Comportamento espectral de alvos: vegetação**. Universidade Federal do Paraná - UFPR. Curitiba. 2012.
- CARVALHO, L. M. T. **Mapping and monitoring forest remnants: a multiscale analysis of spatio-temporal data**. 2001, 150f. Tese (Doutorado em Sensoriamento Remoto) - Wageningen University, Wageningen, 2001.
- CHEN, S. C.; HERZ, R. **Estudos Quantitativos e Calibração Radiométrica de Dados Digitais do Landsat-5**. INPE. In: VIII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO - SBSR, Salvador, Brasil. 1996. Anais[...] Disponível em: <http://mar.tecnico.unicamp.br/col/sid.inpe.br/deise/1999/01.29.11.31/doc/T24.pdf> Acesso em: 10 abr. 2019.
- COELHO, L.; BRITO, J. N. **Fotogrametria digital**. Rio de Janeiro: Editora da Universidade do Estado do Rio de Janeiro, 2007. 196 p.
- COLWELL, R. **Manual of Remote Sensing. Vol. 1 and 2. American Society of Photogrammetry and Remote Sensing**, Falls Church, 1983.
- CONAB. **Companhia Nacional de Abastecimento**. 2005. Disponível em <https://www.embrapa.br/cafe> Acesso em 01 abr. 2019.
- DUVEILLER, G.; DEFOURNY, P.; DESCLÉE, B.; MAYAUX, P. **Deforestation in Central Africa: estimates at regional, national and landscape levels by advanced processing of systematically-distributed Landsat extracts**. *Remote Sensing of Environment*, v.112, p.1969-1981, 2008.
- EMBRAPA. **Empresa Brasileira de Pesquisa Agropecuária**. 2018. Disponível em <https://www.embrapa.br/cafe> Acesso em: 27 mar. 2019.

ESPINDOLA, G. M.; CÂMARA, G. **Ajuste de parâmetros no algoritmo de segmentação de imagens do software eCognition**. INPE. In: XIV SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO - SBSR, Florianópolis - SC, Brasil. Anais[...] Disponível em: <http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.15.22.12/doc/5739-5744.pdf>  
Acesso em: 12 maio 2019.

FERNANDES, J. L. *et al.*. **Monitoramento da cultura de cana-de-açúcar no Estado de São Paulo por meio de imagens SPOT Vegetation e dados meteorológicos**. 2009.

FERNANDES, P. J. F. **Dados SRTM e derivados no mapeamento geomorfológico regional**. 2013. 93 f. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013.

FIGUEREDO, D. **Conceitos Básicos de Sensoriamento Remoto**. Companhia Nacional do Abastecimento. Brasil, 2005.

FLORENZANO, T. G. **Imagens de satélites para estudos ambientais**. São Paulo: Oficina de Textos, 2002.

FLORES, L. A.; MARTÍNEZ, L. I. Land cover estimation in small areas using ground survey and remote sensing. **Remote Sensing of Environment**, v. 74, n. 2, p. 240-248, 2000.

GOERGEN, L. C. G. **Uso da reflectância de imagens landsat 5 TM na identificação de plantios de *eucalyptus dunnii* e *eucalyptus urograndis* e sua correlação com o volume de madeira**. 99 f. Dissertação (Mestrado em Engenharia Florestal), Centro de Ciências Rurais, Universidade Federal de Santa Maria - UFSM. Santa Maria - RS. 2014.

GONZÁLEZ, F. E.; RUIZ, M. J.; ACOSTA, F. M. **Tutorial do Sensoriamento Remoto**. Universidad de las Palmas de Gran Canaria. 2013.

GONZALEZ, R.C.; WOODS, R. E.; EDDINS, S. L. **Digital image processing using MATLAB**. New Jersey: Prentice Hall, 609p, 2004.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de Imagens Digitais**. 3ª ed. São Paulo: Edgard Blücher, 2010. Traduzido por Cristina Yamagani e Leonardo Piamonte.

GRANER, E. A.; GODOY-JUNIOR, C. **Manual do cafeicultor**. São Paulo: Universidade de São Paulo, 1967.

IBGE. **A geografia do café**. Dinâmica Territorial da Produção Agropecuária. 136 p. Rio de Janeiro. 2016.

INPE. Instituto Nacional de Pesquisas Espaciais. **Manuais: tutorial de geoprocessamento do SPRING**. São José dos Campos: INPE, 2008.

INPE. **CAFESAT**. Disponível em: <http://www.dsr.inpe.br/laf/cafesat/informacoes.html>  
Acesso em: 10 maio 2019.



JENSEN, J. R. **Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres**. 2 ed. Tradução de J. C. N. Epiphânio. São José dos Campos, SP. 2009. Tradução de: Remote Sensing of the environment: an Earth resource perspective.

LEONARDI, F.; ALMEIDA, C. M.; FONSECA, L. M. G.; CAMARGO, F. F. **Avaliação Comparativa entre Classificação Supervisionada por Regiões e Orientada a Objeto para Imagens de Alta Resolução Espacial: Cbers 2B-HRC e QuickBird**. INPE. In: XIV SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO - SBSR, Natal - RS, Brasil. Anais[...] Disponível em: <http://mar.tecnico.unicamp.br/col/dpi.inpe.br/sbsr@80/2008/11.16.12.54/doc/981-988.pdf> Acesso em: 02 abr. 2019.

LUZ, N. B. **Integração de análise orientada a objetos e árvores de decisão para classificação de sub-tipologias de floresta ombrófila mista**. 157 f. Tese (Doutorado em Ciências Geodésicas), Departamento de Ciências Geodésicas, Universidade Federal do Paraná - UFPR. Curitiba. 2011.

MELO, D. H. C. T. B. **Uso de dados Ikonos II na análise urbana: testes operacionais na zona leste de São Paulo**. São José dos Campos: INPE, 2002. 146 p.

MELLO, E.V. **Tecnologias de produção de café com qualidade**. Cafeicultura no Brasil. In: ZAMBOLIM, L. Viçosa: 2001.

MENESES, R. P.; ALMEIDA, T. **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília. 2012.

MORAES, C. E. **Fundamentos do Sensoriamento Remoto**. Instituto Nacional De Pesquisas Espaciais (INPE), São José dos Campos, 2002.

MOREIRA, M. A.; ADAMI, M.; RUDORFF, B. F. T. **Análise espectral e temporal da cultura do café em imagens Landsat**. Pesquisa Agropecuária Brasileira, Brasília, v. 39, n. 3, 2004.

MORIYA, E. A. S. **Identificação de bandas espectrais para detecção de cultura de cana-de-açúcar sadia e doente utilizando câmara hiperespectral embarcada em vant**. Tese (doutorado). Presidente Prudente – SP, p. 147, 2011.

NAIME, J. M. *et al.* **Agricultura de Precisão**. São Carlos: Cubo, 2014. 73 p.

NOVO, E. M. L. de M. **Sensoriamento Remoto: Princípios e Aplicações**. 4. ed. São Paulo: Edgard Blücher, 2010.

NOVO, E. M. L.; PONZONI, F. J. **Introdução ao Sensoriamento Remoto**. São José dos Campos - SP. 2001.

PEREIRA, J. L. G. *et al.* **Reflectância de Coberturas Vegetais na Amazônia**. In: VII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO - SBSR, 1996, Salvador. Anais[...] São José dos Campos, SP: INPE, 1996. p. 551-556.

PINHO, C.M.D.; RENNÓ, C.D. ; KUX, H. **Avaliação de técnicas de fusão aplicadas à imagem QuickBird**. Simpósio Brasileiro de Sensoriamento Remoto. 12, 2005, Goiânia. Anais... São José dos Campos: INPE, 2005. p. 4225 – 4232.

PLANET. **Planet imagery product specification: PlanetScope & RapidEye**. 2016. Disponível em: [https://www.planet.com/products/satellite-imagery/files/1610.06\\_Spec%20Sheet\\_Combined\\_Imagery\\_Product\\_Letter\\_ENGv1.pdf](https://www.planet.com/products/satellite-imagery/files/1610.06_Spec%20Sheet_Combined_Imagery_Product_Letter_ENGv1.pdf) Acesso em: 02 maio 2019.

PONZONI, F. J. **Comportamento Espectral da Vegetação. In. Sensoriamento Remoto – Reflectância dos alvos naturais**. Editora UnB, Embrapa, Brasília (DF), p. 157-199, 2001.

PONZONI, Flávio Jorge; SHIMABUKURO, YosioEdemir; KUPLICH, Tatiana Mora. **Sensoriamento Remoto da Vegetação**. 2. ed. São Paulo: Oficina de Textos, 2012.

PRADO, F. A.; GALO, M. L. B. T. Classificação de imagens multiespectrais Baseada em abordagem *fuzzy*. **Revista Brasileira de Cartografia**. Universidade Estadual Paulista - UNESP, Departamento de Cartografia. 2009. p. 233 - 244.

PRADO, D. F. C.; MORATO, R. G., HAYAKAWA, E. G.; KAWAKUBO, F. S. **Mapeamento do cultivo de café no sul de Minas Gerais utilizando imagens Landsat-5 TM**. INPE. In: XVI SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO - SBSR, Foz do Iguaçu - PR, Brasil. 2013. Anais[...] Disponível em: <http://www.revistas.usp.br/rdg/article/view/103040/115436> Acesso em 20 abr. 2019.

PRINA, Z. B; TRENTIN, R. **GMC: Geração de Matriz de Confusão a partir de uma classificação digital de imagem do ArcGIS**. INPE. In: XVII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO - SBSR, João Pessoa-PB, Brasil, 2015. Anais[...] Disponível em <http://www.dsr.inpe.br/sbsr2015/files/p0031.pdf> Acesso em 25 abr. 2019.

QUEIROZ, R. B. ; RODRIGUES, A. G. ; GÓMEZ, A. T. . **Estudo Comparativo entre as Técnicas Máxima Verossimilhança Gaussiana e Redes Neurais na Classificação de Imagens IR-MSS CBERS 1**. In. 2004, Palhoça, SC, Brasil. Anais[...] Disponível em: [http://www.ufrgs.br/niee/eventos/CBCOMP/2004/pdf/Workshop\\_Ambiente/Inteligencia\\_Artificial/t170100151\\_3.pdf](http://www.ufrgs.br/niee/eventos/CBCOMP/2004/pdf/Workshop_Ambiente/Inteligencia_Artificial/t170100151_3.pdf) Acesso em: 05 abr. 2019.

QUEIROZ, J. E. R.; GOMES, H. M. **Introdução ao Processamento Digital de Imagens**. 2001.

ROSA, V. G. C. **Modelo agrometeorológico-espectral para monitoramento e estimativa da produtividade do café na região sul/sudoeste do estado de Minas Gerais**. 145 f. Dissertação (Mestrado em Sensoriamento Remoto), Instituto Nacional de Pesquisas Espaciais - INPE. São José dos Campos. 2007.

SANCHEZ, E. C. M. **Controle por Aprendizado Acelerado e Neuro-Fuzzy de Sistemas Servo - Hidráulicos de Alta Frequência**. Dissertação (Mestrado em Engenharia Mecânica). Pontifícia Universidade Católica do Rio de Janeiro - PUCRIO. Rio de Janeiro. 2009.

SANTOS, T. **Raízes do café no Brasil**. 2018. Disponível em: <https://brasilecola.uol.com.br/historia/o-cafe-no-brasil-suas-origens.htm> Acesso em: 03 abr. 2019.

- SARAIVA, D. F. **Classificação orientada a objeto para mapeamento da vegetação sobre canga couraçada**. 42 f. Monografia (Especialista em geoprocessamento), Departamento de Cartografia, Universidade Federal de Minas Gerais - UFMG. Belo horizonte. 2013.
- SARTORI, A. A. C.; BARBOSA, A. P.; PISANI, R. J.; OLIVEIRA, F. O.; ZIMBACK, C. R. L. **Mapeamento de conflitos de solo em áreas de preservação permanente na Bacia Experimental do Rio Pardo - São Paulo – Brasil**. INPE. In: XIV XVI SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO - SBSR, Natal, Brasil. 2009. Anais[...] Disponível em:  
<http://mar.te.sid.inpe.br/col/dpi.inpe.br/sbsr%4080/2008/11.14.22.03/doc/6197-6202.pdf>  
 Acesso em: 24 abr. 2019.
- SILVA, R. R. **Aplicação de imagens orbitais de alta resolução espacial no cadastro técnico rural Multifinalitário**. Porto Alegre: UFRGS, 2007.
- SOUZA, O. N. **Introdução à Teoria dos Conjuntos Fuzzy**. Departamento de Matemática, Universidade Estadual de Londrina - UEL. 2010.
- STROSKI, P. N. **O que é lógica fuzzy?**. 2017. Disponível em:  
<http://www.electricalibrary.com/2017/11/13/o-que-e-logica-fuzzy/>  
 Acesso em: 22 maio 2019.
- TARDIN, A.T.; ASSUNÇÃO, G.V.; SOARES, J.V. **Análise preliminar de imagens TM visando a discriminação de café, citrus e cana-de-açúcar na região de Furnas-MG**. Pesquisa Agropecuária Brasileira, 1992.
- TEIXEIRA, S. M.; MILHOMEM, A. V. **A competitividade e custos da cafeicultura brasileira**. In: Zambolim, L. (Ed.) Tecnologias de produção de café com qualidade. Viçosa: UFV, Departamento de Fitopatologia, 2001. p. 25 - 64.
- VELOSO, M. H. **Coffe inventory through orbital imagery**. Rio de Janeiro: Instituto Brasileiro do Café, 1974.
- VELOSO, M. H.; Souza, D. D. **Sistema automático de inventário cafeeiro**. Rio de Janeiro: Instituto Nacional do Café, 1976.
- VELOSO, M. H.; Souza, D. D. **Trabalho experimental de inventariação automática de cafezais utilizando imagens orbitais e o equipamento image-100**. Rio de Janeiro: Instituto Brasileiro do Café, 1978.
- VIEIRA, T. G. C.; ALVES, H. M. R.; LACERDA M. P. C.; VEIGA R. D.; EPIPHANIO J. C. N. **Crop parameters and spectral response of coffe (*Coffea arabica L.*) areas within the state of Minas Gerais, Brazil**. Coffee Science. 2006.
- WAGNER, A. **Extração de Conhecimento a partir de Redes Neurais aplicada ao problema da Cinemática Inversa na Robótica**. Universidade do Vale do Rio dos Sinos - UNISINOS, 2003.
- ZAMBOLIM, L. **Tecnologias de produção de café com qualidade**. Viçosa: UFV, 2001. 648