

---

**UNIVERSIDADE FEDERAL DE PERNAMBUCO**  
**CENTRO DE TECNOLOGIA E GEOCIÊNCIAS**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS GEODÉSICAS E**  
**TECNOLOGIAS DA GEOINFORMAÇÃO**

---



**João Antonio dos Santos Pereira**

**IMPACTO DA CHUVA NO COMPORTAMENTO DOS ÍNDICES FÍSICOS PARA  
CLASSIFICAÇÃO DO USO DA TERRA NO SUBMÉDIO DO SÃO FRANCISCO**

Recife  
2017

---

João Antonio dos Santos Pereira

**IMPACTO DA CHUVA NO COMPORTAMENTO DOS ÍNDICES FÍSICOS PARA  
CLASSIFICAÇÃO DO USO DA TERRA NO SUBMÉDIO DO SÃO FRANCISCO**

Dissertação apresentada à Universidade Federal de Pernambuco como parte dos requisitos para obtenção do título de mestre em Ciências Geodésicas e Tecnologias da Geoinformação.

**Área de concentração:** Cartografia e Sistemas de Geoinformação

**Orientador:** Prof. Dr. João Rodrigues Tavares Junior

Recife  
2017

---

Catálogo na fonte  
Bibliotecária Margareth Malta, CRB-4 / 1198

P436i Pereira, João Antonio dos Santos.  
Impacto da chuva no comportamento dos índices físicos para classificação do uso da terra no submédio do São Francisco microrregião de Itaparica-PE / João Antonio dos Santos Pereira. – 2017.  
105 folhas, il., gráfs., tabs.

Orientador: Prof. Dr. João Rodrigues Tavares Junior.  
Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG.  
Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação, 2017.

Inclui Referências.

1. Engenharia Cartográfica. 2. Classificações supervisionadas. 3. Índices físicos. 4. Uso do solo. I. Tavares Junior, João Rodrigues. (Orientador). II. Título.

UFPE

526.1 CDD (22. ed.)

BCTG/2017-138

João Antonio dos Santos Pereira

**IMPACTO DA CHUVA NO COMPORTAMENTO DOS ÍNDICES FÍSICOS PARA  
CLASSIFICAÇÃO DO USO DA TERRA NO SUBMÉDIO DO SÃO FRANCISCO**

Dissertação apresentada à Universidade Federal de Pernambuco como parte dos requisitos para obtenção do título de mestre em Ciências Geodésicas e Tecnologias da Geoinformação.

Aprovado em: 01/02/2017.

**Banca Examinadora**

---

Prof. Dr. João Rodrigues Tavares Junior (Orientador)  
Universidade Federal de Pernambuco

---

Profa. Dra. Ana Lúcia Bezerra Candeias (Examinador Interno)  
Universidade Federal de Pernambuco

---

Profa. Dra. Rafaella Chrystiane de Moura Matos (Examinador Externo)  
Faculdade Joaquim Nabuco

---

*À Deus, meus familiares e amigos,  
Por me iluminarem e incentivarem à trilhar os melhores caminhos durante esta etapa.*

*Dedico.*

---

## AGRADECIMENTOS

Primeiramente gostaria de agradecer à Deus pelo dom da vida e por tudo que tem me proporcionado ao longo de minha existência, nunca me deixando faltar nada, e servindo como um referencial para direcionamento da minha vida.

Aos meus pais João e Maria, pelo amor, zelo, carinho, esforço, compreensão, estímulo e diversas demonstrações de como ser um modelo de pais, nunca me deixando desanimar frente às adversidades encontradas.

Aos meus irmãos Izabela e João Paulo, por se manterem sempre ao meu lado me apoiando durante esta caminhada, e por toda amizade e companheirismo dispendido à mim, sendo irmãos inseparáveis e com quem sempre pude contar.

À todos os meus familiares e amigos de infância, onde sempre encontrei palavras de apoio e incentivo para seguir essa caminhada.

À minha namorada Pollyne Amorim, pelo amor, amizade e companheirismo nesses últimos anos, me inspirando a buscar ser uma pessoa melhor, e a batalhar com mais garra por meus objetivos.

Ao professor João Rodrigues, pela orientação, amizade, paciência e sabedoria na condução deste trabalho ao longo desses dois anos. Às professoras Ana Lúcia Candeias, Leidjane Oliveira e Rafaella Matos, pelas importantíssimas considerações e contribuições ao trabalho.

Ao Programa de Ciências Geodésicas e Tecnologias da Geoinformação, especialmente na pessoa da professora Andrea Carneiro, onde pude usufruir de grande crescimento pessoal e profissional. E à CAPES pela concessão da bolsa fundamental ao desenvolvimento deste trabalho.

À Elisabeth Galdino, pela solicitude e gentileza com que sempre trata à todos na secretaria da Pós-graduação.

Aos meus colegas de turma, com quem sempre pude contar nos momentos de dúvidas, e onde encontrei acima de tudo, bons amigos. Em especial à Franciele Araújo, Rafael Anjos, João Alberto, Ermerson Vasconcelos, Heithor Queiroz e Tarso Luconi.

E à todos aqueles que participaram da minha caminhada até aqui, desculpem-me àqueles que esqueci, mas sempre que pensar nesses anos, a imagem de vocês me virá na memória com carinho e saudade das experiências vividas.

---

## RESUMO

A associação de variados métodos e usos das imagens de satélite trazem a possibilidade de enxergar o ambiente de maneira ampla. Entre os usos mais comuns desses dados estão as classificações supervisionadas e os índices físicos. A necessidade dessa aplicação aumenta em ambientes onde os cenários de degradação dos recursos ambientais está se acentuando com o passar do tempo, como é o caso do bioma Caatinga. Sendo assim, a pesquisa propõe a utilização de classificações supervisionadas e índices físicos para analisar a região ao entorno do reservatório de Itaparica. Esta região é estratégica para o estado pois comporta além da represa, importantes áreas de cultivos irrigados, e é objeto de estudo do projeto INNOVATE (Interplay Among Multiple Uses of Water Reservoirs via Innovative Coupling Substance Cycles in Aquatic and Terrestrial Ecosystems), que tem como principal interesse entender as relações entre as mudanças climáticas e as formas de uso da terra e dos recursos hídricos em ambiente semiárido. Nesta pesquisa, foram utilizadas imagens do sensor OLI/TIRS do landsat 8 e dados de chuva, e realizadas classificações supervisionadas pelos métodos da máxima verossimilhança e distância euclidiana para observar a distribuição das classes de uso do solo. Essas classificações foram avaliadas a partir dos índices estatísticos Kappa e TAU, com base na matriz de confusão gerada a partir das amostras da classificação. Além disso, foram utilizados os índices físicos albedo de superfície, NDVI (Normalized Difference Vegetation Index), temperatura de superfície e saldo de radiação, segundo metodologia proposta no algoritmo SEBAL (Surface Energy Balance Algorithms for Land), para analisar o comportamento de cada classes e relacioná-los com os resultados obtidos com as classificações. Nos resultados foram observadas que nas classificações supervisionadas houve confusão entre as classes de solo exposto e área urbana, assim como nas classes de agricultura irrigada e vegetação arbórea. Essa confusão é explicada pela similaridade espectral que esses alvos possuem. Exatamente nesse sentido, os índices físicos aparecem como forma de obter separação entre as classes que se assemelham. O saldo de radiação e o albedo conseguiram gerar discrepâncias maiores entre os alvos na imagem de janeiro, porém obtiveram péssimo desempenho nessa função para a imagem de junho, pois a ocorrência de um evento chuvoso no dia da passagem do

---

sensor impactou totalmente esses índices. Dessa forma, o NDVI se mostrou mais eficiente, pois suas alterações necessitam mais tempo para serem consideráveis.

**Palavras-chave:** Classificações supervisionadas. Índices físicos. Uso do solo.

---



## ABSTRACT

The association of various methods and uses of satellite images bring the possibility to see the environment widely. Among the most common uses of this data are supervised classifications and the physical indexes. The need for this application increases in environments where the scenarios of degradation of environmental resources is increasing over time, as is the case of the Caatinga. Thus, the research proposes the use of supervised classifications and physical indexes to analyze the region surrounding the Itaparica reservoir. This region is strategic for the State because it acts beyond the dam, important areas of irrigated crops, and is the subject of study of the project INNOVATE (Interplay Among Multiple Use of Water Reservoirs via Innovative Coupling Substance Cycles in Aquatic and Terrestrial Ecosystems), whose main interest to understand the relationship between climate change and ways of use of land and water resources in semi-arid environment. In this research, it was used images from the landsat sensor OLI/TIR 8 and rain data, and performed supervised classifications by methods of maximum likelihood and Euclidean distance to observe the distribution of land use classes. These classifications were evaluated from the statistical indexes Kappa and TAU, based on the array of confusion from the samples of the classification. In addition, physical indexes used were surface albedo, NDVI (Normalized Difference Vegetation Index), surface temperature and radiation balance, according to the methodology proposed in the algorithm SEBAL (Surface Energy Balance Algorithms for Land), to analyze the behavior of each classes and relate them with the results obtained with the ratings. The results were observed in supervised classifications there was confusion between the classes of soil exposed and urban area, as well as irrigated agriculture classes and arboreal vegetation. This confusion is explained by spectral similarity to those targets. Exactly in this sense, the physical indexes appear as way to get separation between classes that resemble. The radiation balance and albedo were able to generate larger discrepancies between the targets in January, but image obtained bad performance in this function to the image of June, because the occurrence of a rain event on the day of passing the sensor fully impacted them. In this way, the NDVI has proved to be more efficient, because their changes require more time to be considerable.

**Keywords:** Supervised classifications. Physical indexes. Land use.

---

## LISTA DE ILUSTRAÇÕES

Figura 1: Assinatura espectral de diferentes alvos de superfície.....	21
Figura 2: Radiância espectral do corpo negro para algumas temperaturas.....	25
Quadro 1: Faixas espectrais do Landsat OLI/TIRS.....	33
Quadro 2: Escala de qualidade da classificação.....	36
Figura 3: Mapa de Localização.....	38
Figura 4: Fluxograma dos procedimentos metodológicos.....	39
Figura 5: Precipitação observada entre os dias 26/12/2013 à 29/12/2013.....	41
Figura 6: Precipitação observada entre os dias 30/12/2013 à 02/01/2014.....	42
Figura 7: Precipitação observada entre os dias 04/06/2013 à 07/06/2014.....	43
Figura 8: Precipitação observada entre os dias 08/06/2014 à 11/06/2014.....	44
Figura 9: Modelo de elevação digital.....	45
Figura 10: Pontos amostrais para as classes de uso do solo para as duas datas....	46
Figura 11: Processo inicial para classificação supervisionada de imagens.....	47
Figura 12: Processo de criação de contexto para classificação de imagens.....	47
Figura 13: Processo de equalização das bandas espectrais.....	48
Figura 14: Processo de criação das classes da classificação de imagens.....	48
Figura 15: Processo de obtenção de amostras para classificação de imagens.....	59
Figura 16: Processo de escolha do método de classificação de imagens.....	49
Figura 17: Produto final da classificação de imagens.....	50
Figura 18: Classificação por Máxima Verossimilhança (02/01/2014).....	57
Figura 19: Classificação por Máxima Verossimilhança (11/06/2014).....	61
Figura 20: Classificação por Distância Euclidiana (02/01/2014).....	64
Figura 21: Classificação por Distância Euclidiana (11/06/2014).....	68
Figura 22: Carta-imagem do Albedo de Superfície (02/01/2014).....	72
Figura 23: Carta-imagem do Albedo de Superfície (11/06/2014).....	74
Figura 24: Carta-imagem do NDVI (02/01/2014).....	76
Figura 25: Carta-imagem do NDVI (11/06/2014).....	77
Figura 26: Carta-imagem da Temperatura de Superfície (02/01/2014).....	79
Figura 27: Carta-imagem da Temperatura de Superfície (11/06/2014).....	81
Figura 28: Carta-imagem do Saldo de Radiação (02/01/2014).....	82
Figura 29: Carta-imagem do Saldo de Radiação (11/06/2014).....	84

---

## LISTA DE TABELAS

Tabela 1: Estatísticas gerais da classificação por Máxima Verossimilhança (02/01/2016).....	58
Tabela 2: Matriz de Confusão da classificação por Máxima Verossimilhança (02/01/2014).....	58
Tabela 3: Exatidão do produtor e usuário da classificação por Máxima Verossimilhança (02/01/2016).....	59
Tabela 4: Estatísticas gerais da classificação para os pontos por Máxima Verossimilhança (02/01/2016).....	60
Tabela 5: Matriz de Confusão da Classificação por Máxima Verossimilhança obtida pelos pontos amostrais (02/01/2014).....	60
Tabela 6: Exatidão do produtor e usuário da classificação por Máxima Verossimilhança obtida pelos pontos amostrais (02/01/2014).....	60
Tabela 7: Estatísticas gerais da classificação por Máxima Verossimilhança (11/06/2016).....	61
Tabela 8: Matriz de Confusão da Classificação por Máxima Verossimilhança (11/06/2016).....	62
Tabela 9: Exatidão do produtor e usuário da classificação por Máxima Verossimilhança (11/06/2016).....	62
Tabela 10: Estatísticas gerais da classificação por Máxima Verossimilhança (11/06/2016).....	63
Tabela 11: Matriz de Confusão da Classificação por Máxima Verossimilhança obtida pelos pontos amostrais (11/06/2014).....	63
Tabela 12: Exatidão do produtor e usuário da classificação por Máxima Verossimilhança obtida pelos pontos amostrais (11/06/2014).....	64
Tabela 13: Estatísticas gerais da classificação por Distância Euclidiana (02/01/2014).....	65
Tabela 14: Matriz de Confusão da Classificação por Distância Euclidiana (02/01/2014).....	65
Tabela 15: Exatidão do produtor e usuário da classificação por Distância Euclidiana (02/01/2014).....	65

---

Tabela 16: Estatísticas gerais da classificação por Distância Euclidiana obtida pelos pontos amostrais (02/01/2014).....	67
Tabela 17: Matriz de Confusão da classificação por Distância Euclidiana obtida pelos pontos amostrais (02/01/2014).....	67
Tabela 18: Exatidão do produtor e usuário da classificação por Distância Euclidiana obtida pelos pontos amostrais (02/01/2014).....	67
Tabela 19: Estatísticas gerais da classificação por Distância Euclidiana (11/06/2014).....	68
Tabela 20: Matriz de Confusão da Classificação por Distância Euclidiana (11/06/2014).....	69
Tabela 21: Exatidão do produtor e usuário classificação por Distância Euclidiana (11/06/2014).....	60
Tabela 22: Estatísticas gerais da classificação por Distância Euclidiana obtida pelos pontos amostrais (11/06/2014).....	70
Tabela 23: Matriz de Confusão da Classificação por Distância Euclidiana obtida pelos pontos amostrais (11/06/2014).....	71
Tabela 24: Exatidão do produtor e usuário da classificação por Distância Euclidiana (11/06/2014).....	71

---

## LISTA DE GRÁFICOS

Gráfico 1: Dados de precipitação.....	40
Gráfico 2: Variação do Albedo de Superfície entre as classes (02/01/2014).....	73
Gráfico 3: Variação do Albedo de Superfície entre as classes (11/06/2014).....	75
Gráfico 4: Variação do NDVI entre as classes (02/01/2014).....	77
Gráfico 5: Variação do NDVI entre as classes (11/06/2014).....	78
Gráfico 6: Variação da Temperatura de Superfície entre as classes (02/01/2014)...	80
Gráfico 7: Variação da Temperatura de Superfície entre as classes (11/06/2014)...	82
Gráfico 8: Variação do Saldo de Radiação entre as classes (02/01/2014).....	84
Gráfico 9: Variação do Saldo de Radiação entre as classes (11/06/2014).....	85
Gráfico 10: Relação entre o albedo de superfície e o NDVI (02/01/2014).....	86
Gráfico 11: Relação entre o Albedo de superfície e a temperatura de superfície (02/01/2014).....	87
Gráfico 12: Relação entre o albedo de superfície e o saldo de radiação (02/01/2014).....	88
Gráfico 13: Relação entre o NDVI e a temperatura de superfície (02/01/2014).....	89
Gráfico 14: Relação entre o NDVI e o saldo de radiação (02/01/2014).....	89
Gráfico 15: Relação entre a temperatura de superfície e o saldo de radiação (02/01/2014).....	90
Gráfico 16: Relação entre o albedo de superfície e o NDVI (11/06/2014).....	91
Gráfico 17: Relação entre o albedo de superfície e temperatura de superfície (11/06/2014).....	92
Gráfico 18: Relação entre o albedo de superfície e saldo de radiação (11/06/2014).....	92
Gráfico 19: Relação entre NDVI e temperatura de superfície (11/06/2014).....	93
Gráfico 20: Relação entre NDVI e saldo de radiação (11/06/2014).....	93
Gráfico 21: Relação entre temperatura de superfície e saldo de radiação (11/06/2014).....	94

---

## LISTA DE ABREVIATURAS E SIGLAS

**ALI** - Advanced Land Imager

**ASTER** - Advanced Spaceborne Thermal Emission and Reflection Radiometer

**CODEVASF** - Companhia de Desenvolvimento dos Vales do São Francisco e do Parnaíba

**CPTEC** - Centro de Previsão de Tempo e Estudos Climáticos

**DSA** – Dia Sequencial do Ano

**EMBRAPA** - Empresa Brasileira de Pesquisa Agropecuária

**EO 1** - Earth Observing

**EOS AM1** - Earth Observing System

**ERTS -1** - Earth Resources Technology Satellites

**IBGE** – Instituto Brasileiro de Geografia e Estatística

**INMET** – Instituto Nacional de Meteorologia

**INNOVATE** - Interplay among multiple uses of water reservoirs via innovate coupling aquatic and terrestrial ecosystems

**INPE** – Instituto Nacional de Pesquisas Espaciais

**IOCCG** - International Ocean-Colour Coordinating Group

**LAI** – Leaf Area Index

**LandSat** - Land Remote Sensing Satellite

**MaxVer** – Máxima Verossimilhança

**MMS** - Multispectral Scanner System

**ND** – Número Digital

**NDVI** - Normalized Difference Vegetation Index

**OLI** – Operational Land Imager

**RMSE** - Root Mean Squared Error

**SAVI** - Soil-Adjusted Vegetation Index

**SEBAL** – Surface Energy Algorithm for Land

**TIR** – Thermal Infrared

**TIRS** – Thermal Infrared Sensor

**TM** - Thematic Mapper

**USGS** – United States Geological Survey

---

## LISTA DE SÍMBOLOS

**F<sub>e</sub>** – Ferro

**μm** – Micrometro

**mm** – Milímetro

**σ** – Constante de Stefan-Boltsman

**π** - Pi

**nm** – Nanômetro

**L<sub>λ</sub>** – Radiância espectral no topo da atmosfera

**ρ<sub>λ</sub>** – Reflectância planetária no topo da atmosfera

**Z** – Altitude

**K** – KAPPA

**T** – TAU

**α<sub>TOA</sub>** – Albedo no topo da atmosfera

**T<sub>sw</sub>** – Transmissividade atmosférica

**α** – Albedo de superfície

**ρ<sub>iv</sub>** – Banda do infravermelho próximo

**ρ<sub>v</sub>** – Banda do vermelho

**ε<sub>nb</sub>** – Emissividade na banda termal

**ε<sub>0</sub>** – Emissividade da superfície

**T<sub>sup</sub>** – Temperatura de Superfície

**°C** – Graus Celsius

**R<sub>OC\_INC</sub>** – Radiação de onda curta incidente

**R<sub>OL\_INC</sub>** – Radiação de onda longa incidente

**ε<sub>a</sub>** – Emissividade atmosférica

**T<sub>ar</sub>** – Temperatura do ar

**R<sub>OL\_EMI</sub>** – Radiação de onda longa emitida

**R<sub>n</sub>** – Saldo de radiação

---

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>17</b>
1.1	OBJETIVO GERAL.....	19
1.2	OBJETIVOS ESPECÍFICOS.....	19
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA .....</b>	<b>20</b>
2.1	SENSORIAMENTO REMOTO E INTERAÇÃO DA RADIAÇÃO ELETROMAGNÉTICA COM A SUPERFÍCIE TERRESTRE.....	20
2.1.1	<b>Sensoriamento remoto em alvos terrestres e sazonalidade.....</b>	<b>21</b>
2.1.2	<b>Sensoriamento remoto em ambientes aquáticos.....</b>	<b>23</b>
2.2	PRINCÍPIOS FÍSICOS QUE REGEM O COMPORTAMENTO TÉRMICO.....	24
2.2.1	<b>Teoria do Corpo Negro.....</b>	<b>24</b>
2.2.2	<b>Equação de Stefan-Boltzmann.....</b>	<b>25</b>
2.2.3	<b>Teoria de Planck.....</b>	<b>26</b>
2.2.4	<b>Emissividades.....</b>	<b>26</b>
2.2.5	<b>Lei de Wien.....</b>	<b>27</b>
2.2.6	<b>Inércia Térmica.....</b>	<b>27</b>
2.3	ANÁLISE ESPACIAL A PARTIR DO SEBAL ( <i>SURFACE ENERGY BALANCE ALGORITHMS FOR LAND</i> ).....	28
2.4	CLASSIFICAÇÕES DE IMAGENS A PARTIR DO SOFTWARE SPRING.....	31
2.5	CARACTERÍSTICAS DO SENSOR OLI/TIRS.....	32
2.5.1	<b>Sensores Landsat.....</b>	<b>32</b>
2.6	MÉTODOS ESTATÍSTICOS.....	33
2.6.1	<b>Índice Kappa.....</b>	<b>34</b>
2.6.2	<b>Índice TAU.....</b>	<b>34</b>
2.6.3	<b>Matriz de Confusão/erros.....</b>	<b>35</b>
2.7	ESTADO DA ARTE.....	36
<b>3</b>	<b>CARACTERIZAÇÃO DA ÁREA DE ESTUDO..</b>	<b>38</b>
<b>4</b>	<b>MATERIAIS E MÉTODOS .....</b>	<b>39</b>
4.1	FLUXOGRAMA DOS PROCEDIMENTOS METODOLÓGICOS .....	39
4.2	MATERIAIS UTILIZADOS .....	39
4.2.1	<b>Escolha e aquisição das imagens.....</b>	<b>39</b>
4.2.2	<b>Dados meteorológicos.....</b>	<b>40</b>
4.2.3	<b>Modelo de elevação digital.....</b>	<b>44</b>
4.2.4	<b>Pontos amostrais.....</b>	<b>45</b>
4.3	CLASSIFICAÇÃO SUPERVISIONADA.....	46
4.4	PROCESSAMENTO DAS IMAGENS OLI/TIRS.....	50
4.4.1	<b>Conversão dos números digitais para radiância no topo da atmosfera.....</b>	<b>51</b>
4.4.2	<b>Conversão dos números digitais para Refletância no Topo da Atmosfera.....</b>	<b>51</b>
4.4.3	<b>Albedo Planetário (<math>\alpha_{toa}</math>).....</b>	<b>51</b>
4.4.4	<b>Transmissividade Atmosférica (<math>\tau_{sw}</math>).....</b>	<b>52</b>
4.4.5	<b>Albedo de Superfície (<math>\alpha</math>).....</b>	<b>52</b>
4.4.6	<b>Normalized Difference Vegetation Index (NDVI).....</b>	<b>52</b>
4.4.7	<b>Soil Adjusted Vegetation Index (SAVI).....</b>	<b>53</b>

---



4.4.8	LAI (Leaf área index).....	53
4.4.9	Emissividades.....	54
4.4.10	Temperatura de Superfície ( $T_{sup}$ ).....	54
4.4.11	Radiação de Onda Curta Incidente ( $R_{OC\_INC}$ ).....	54
4.4.12	Radiação de Onda Longa Incidente ( $R_{OL\_INC}$ ).....	55
4.4.13	Radiação de Onda Longa Emitida ( $R_{OL\_EMI}$ ).....	55
4.4.14	Saldo de Radiação à Superfície ( $R_n$ ).....	56
5	<b>RESULTADOS E DISCUSSÃO</b> .....	57
5.1	CLASSIFICAÇÃO PELO SOFTWARE SPRING .....	57
5.1.1	<b>Classificação pelo método da Máxima Verossimilhança</b> .....	57
5.1.1.1	Imagem de 02/01/2014.....	57
5.1.1.1.1	<i>Estatística para os pontos coletados</i> .....	59
5.1.1.2	Imagem de 11/06/2014.....	61
5.1.1.2.1	<i>Estatística para os pontos coletados</i> .....	62
5.1.2	<b>Classificação pelo método da Distância Euclidiana</b> .....	64
5.1.2.1	Imagem de 02/01/2014.....	64
5.1.2.1.1	<i>Estatística para os pontos coletados</i> .....	66
5.1.2.2	Imagem de 11/06/2014.....	68
5.1.2.2.1	<i>Estatística para os pontos coletados</i> .....	70
5.2.	ÍNDICES FÍSICOS.....	71
5.2.1	<b>Albedo de Superfície (<math>\alpha</math>)</b> .....	71
5.2.1.1	Imagem de 02/01/2014.....	71
5.2.1.2	Imagem de 11/06/2014.....	73
5.2.2	<b>NDVI</b> .....	75
5.2.2.1	Imagem de 02/01/2014.....	75
5.2.2.2	Imagem de 11/06/2014.....	77
5.2.3	<b>Temperatura de Superfície</b> .....	79
5.2.3.1	Imagem de 02/01/2014.....	79
5.2.3.2	Imagem de 11/06/2016.....	80
5.2.4	<b>Saldo de Radiação (<math>R_n</math>)</b> .....	82
5.2.4.1	Imagem de 02/01/2014.....	82
5.2.4.2	Imagem de 11/06/2014.....	84
5.2.5	<b>Relação entre os índices</b> .....	85
5.2.5.1	Índices obtidos nas imagens de 02/01/2014 .....	85
5.2.5.2	Índices obtidos nas imagens de 11/06/2014 .....	90
6	<b>CONCLUSÕES</b> .....	95
7	<b>RECOMENDAÇÕES FUTURAS</b> .....	97
	<b>REFERÊNCIAS</b> .....	98

---

## 1 INTRODUÇÃO

Segundo Novo (1999), sensoriamento remoto pode ser definido como a aquisição de informação sobre um objeto a partir de medidas feitas por um sensor que não se encontra em contato físico direto com ele. O sensoriamento remoto por satélite é portanto baseado na detecção da energia que os alvos de superfície refletem ao interagir com a radiação eletromagnética proveniente do sol, ou mesmo, a energia que estes emitem, apresentando inúmeras aplicações.

É uma eficiente ferramenta de análise espacial e em estudos acerca dos alvos de superfície, o emprego de dados coletados por sistemas sensores orbitais tem se mostrado uma ferramenta muito valiosa para auxiliar o homem a obter informações do uso e ocupação do solo em grandes áreas na superfície terrestre (Dainese, 2001).

Determinar a evolução dos alvos de superfície é de interesse de toda a sociedade. Estudos sobre a vegetação como os de Shimabukuro et al (1998), Bastiaanssen (2000), Huete (1988), apontam a importância da mesma no estudo do uso de solo. Da mesma forma como afirma Sakamoto et al (2005), o sensoriamento remoto da superfície terrestre tem sido usado com sucesso, por exemplo, na detecção da dinâmica da vegetação por ser capaz de indicar as mudanças gradativas ocorridas durante seu desenvolvimento.

Os corpos hídricos, áreas urbanas e solo exposto tem sido objeto de estudo em várias partes do mundo, como pode ser observado em artigos de Handcock et al (2012), Staenz e Itten (1982), Stoner e Baumgardner (1981).

Com a evolução da tecnologia computacional, o desenvolvimento de metodologias para interpretação de imagens proporcionou a obtenção de algoritmos classificadores para que se pudesse extrair o máximo da informação espectral das imagens.

Entre estas metodologias estão incluídas as classificações de imagens de forma automática e assistida. Além de índices físicos, como o NDVI (Normalized Difference Vegetation Index), albedo de superfície, temperatura de superfície e saldo de radiação, que apresentam características peculiares de cada classe de uso de solo pode ser aplicada em sua observação.

Em trabalhos como os de Allen (2002), Bhattarai et al (2012), Ding e Elmore (2015), Erogov (2015), foram utilizados índices físicos, ou classificações, ou ambos,

para o estudo das feições espaciais. Intrinsecamente, a classificação é considerada um processo fundamental usado para relacionar os valores de pixels com a cobertura da terra ou, às vezes, com classes de uso da terra que estão presentes no local correspondente na superfície da Terra, (Mather, 2004)

As imagens de satélite ao serem processadas geram representações que serão tão precisas quanto for a combinação entre o tipo de dado utilizado, metodologia aplicada e até mesmo habilidade do operador. Estas classificações podem ser avaliadas por testes estatísticos específicos desenvolvidos para averiguar sua precisão. Churches et al (2014), Reyes et al (2017), se utilizaram do índice Kappa para avaliar a precisão das classificações pelo método da máxima verossimilhança e orientadas ao objeto. Índice que é vastamente utilizado pela comunidade que opera com imagens de sensoriamento remoto. Ele detalha a acurácia do mapeamento a partir de dados de referência, e assim denota-se a potencialidade da aplicabilidade do método proposto nos dados utilizados.

Esses métodos podem ainda ser aplicados obedecendo uma escala de tempo com intuito de observar a variação das feições superficiais e verificar se o desempenho dos classificadores sofre influência de fatores como a sazonalidade de culturas e estações climáticas diferentes.

Frente à preocupação com as variações do clima, e a escassez de recursos ambientais em áreas susceptíveis, o uso das técnicas expostas acima se fazem necessários. Tendo em vista que estudos de avaliação dos impactos das mudanças climáticas sobre a estabilidade dos biomas predominantes no Brasil indicam que o bioma caatinga está entre os mais vulneráveis num cenário de aumento das temperaturas globais, o que coloca a região Nordeste do Brasil em estado especial de alerta (Nobre, 2011).

Dessa forma, espera-se que esse trabalho contribua para o entendimento de como a associação entre as classificações de imagens, podem ser utilizadas em conjunto com índices físicos, para gerar mapeamentos mais fidedignos. Essa atualização temática visa ainda observar a influência da sazonalidade e dos eventos chuvosos no potencial de distinção dos alvos a partir de técnicas de processamento de imagens, em um ambiente que reage de forma acentuada em seus aspectos físicos às condições climáticas em curto espaço de tempo.

---

A partir deste preceito, estes processos foram aplicados para observar a dinâmica espacial entre o reservatório de Itaparica e seu entorno, situados no município de Petrolândia, localizado da mesorregião do sertão do São Francisco de Pernambuco, área de interesse do projeto INNOVATE (Interplay among multiple uses of water reservoirs via innovative coupling substance cycles in aquatic and terrestrial ecosystems). Projeto esse realizado em cooperação científica entre o Brasil e a Alemanha, que tem por interesse principal entender as relações entre mudanças climáticas e formas de uso da terra e da água na região do Reservatório de Itaparica.

### 1.1 OBJETIVO GERAL

Analisar a dinâmica sazonal dos alvos de superfície sob o ponto de vista das classificações supervisionadas e índices físicos no entorno do reservatório de Itaparica.

### 1.2 OBJETIVOS ESPECÍFICOS

1. Analisar as classificações supervisionadas pelos métodos da máxima verossimilhança e da distância euclidiana utilizando índices estatísticos para avaliação temática;
  2. Analisar o comportamento espectral e espacial do albedo de superfície, NDVI, temperatura de superfície e saldo do radiação a partir do sensor OLI/TIRS na área teste das margens do reservatório de Itaparica;
  3. Analisar os efeitos da sazonalidade e dos eventos meteorológicos pontuais nas diferentes feições de superfície e como isto interfere na discriminação dos alvos;
  4. Avaliar as causas que resultaram em confusão entre as classificações.
-

## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 SENSORIAMENTO REMOTO E INTERAÇÃO DA RADIAÇÃO ELETROMAGNÉTICA COM A SUPERFÍCIE TERRESTRE

Segundo Florenzano (2002), o sensoriamento remoto é a tecnologia que nos permite obter imagens da superfície terrestre, através da captação e/ou registro da energia refletida ou emitida pelos objetos que constituem a paisagem.

A resposta que o sensor capta, ao passar em determinada região é a radiação eletromagnética refletida ou emitida pelos objetos de superfície. Segundo Rianza et al (1993), a interação entre a energia eletromagnética e a matéria se reflete em uma resposta diversificada que está sujeita às propriedades espectrais desta matéria.


A reflectância espectral é um elemento do comportamento espectral de cada feição da superfície. Os fatores que influenciam a determinação da reflectância e, conseqüentemente, as características espectrais, são a geometria de aquisição dos dados, os parâmetros relativos ao alvo e os parâmetros atmosféricos tais como: umidade atmosférica, concentração e tipo de aerossóis, cobertura de nuvens, etc. (Bokwer et al., 1989).

Segundo Moraes (2002) o comportamento espectral de um objeto pode ser definido como sendo o conjunto dos valores sucessivos da reflectância do objeto ao longo do espectro eletromagnético, também conhecido como a assinatura espectral do objeto. Ao observar esse aspecto ao longo do tempo, se torna possível o monitoramento das variações periódicas das classes de uso do solo. Essa periodicidade é de fundamental importância para a gestão dos recursos naturais.

Sendo assim o estudo do padrão reflexivo de cada um dos objetos terrestres (solo, vegetação, corpos hídricos, áreas construídas), se trata da porção da radiação eletromagnética refletida por estes, após sua interação com as substâncias componentes da superfície terrestre e que é detectada pelo sensor. Esta radiação se relaciona distintamente com cada tipo de alvo, de acordo com sua estrutura atômica e molecular, e como essa energia irá atuar nos átomos dos componentes de cada material. Dessa forma a diferença de resposta espectral é determinada principalmente pelas composições físico-químicas de cada objeto ou feição terrestre. Estes fatores fazem com que cada alvo terrestre apresente sua própria assinatura

---

espectral, (Figura 1). No entanto, a assinatura espectral não se dá apenas em função da reflexão do alvo, pois esta também é influenciada pela emissão de energia que o objeto apresenta.



Fonte: D'ARCO, 2016.

Após esta interação, a energia que é refletida, ou emitida, por cada alvo, sofre influência dos componentes atmosféricos em seu percurso até o sensor, onde os efeitos da nebulosidade e do espalhamento e absorção da luz, limita a detecção de algumas áreas em determinado momento. A combinação destes efeitos é conhecida por atenuação atmosférica. A absorção atmosférica é um fenômeno termodinâmico que resulta na perda de energia para os constituintes atmosféricos em comprimentos de onda específicos. Entre os elementos que absorvem em maior quantidade a radiação solar estão as nuvens, os aerossóis, o vapor de água, o dióxido de carbono e o ozônio (Richards e Jia, 2006).

### 2.1.1 Sensoriamento remoto em alvos terrestres e sazonalidade

Cada tipo de alvo apresenta uma assinatura espectral diferente. É através desse padrão que cada um deles pode ser determinado. Segundo Stoner & Baumgardner (1981), a reflectância do solo é uma propriedade cumulativa derivada do comportamento espectral inerente da combinação heterogênea de seus

componentes, como tamanho de partícula, estrutura do solo, rugosidade superficial, umidade, teor de matéria orgânica, teor de minerais carbonatados, presença ou não de quartzo e dos óxidos de Fe.

O estudo da assinatura espectral dos alvos em áreas urbanas é dificultado pela heterogeneidade dos elementos que compõe os objetos presentes na superfície. Isto é acentuado em imagens de média resolução espacial, tendo em vista que a maioria dos alvos é menor que a área do pixel da imagem. Desta forma, é importante saber como se comportam os tipos de componentes das edificações e áreas pavimentadas. Segundo Staenz e Itten (1982), a reflectância do concreto e do asfalto se dá nas seguintes proporções: Na região do visível, de 9 – 35 % para o concreto, contra 5 – 11% do asfalto, no infravermelho próximo variaram de 12 – 40% e 6 – 13%, respectivamente.

A vegetação apresenta comportamento diferente de acordo com seu aspecto e vigor. Uma vegetação saudável, por exemplo, apresenta grande absorção da faixa do vermelho, em decorrência da forte presença da clorofila, xantofila e carotenos, que são responsáveis pela coloração esverdeada da folha, sendo assim, têm alta reflexão da banda verde. Ao mesmo momento em que esta apresenta uma alta reflexão nos comprimentos de onda do infravermelho, decorrente da interação da radiação com a estrutura celular superficial da folha, e está relacionada com os aspectos fisiológicos da folha e varia com o seu conteúdo de água na estrutura celular superficial. Portanto, o comportamento espectral das folhas depende da sua composição química e de sua estrutura interna. A variação da reflectância da cobertura vegetal em diferentes bandas de sensores remotos depende, principalmente, da quantidade de folhas e da arquitetura do dossel (Shimabukuro, 1998). Influenciam nessa resposta espectral as condições atmosféricas, características das parcelas de solo, índice de área foliar, estado de desenvolvimento da planta, biomassa, e geometria de iluminação solar.

Um dos objetos deste estudo, a vegetação de caatinga, é caracterizada por uma enorme mudança em seus aspectos sazonalmente. Esses ciclos onde ela, em épocas úmidas apresenta um aspecto mais vigoroso, e em períodos mais secos, perde quase que totalmente suas folhas, trazem efeitos na quantidade de biomassa, e conseqüentemente, influencia fortemente em sua resposta espectral. Segundo Trovão et al (2007), as plantas da Caatinga apresentam diversas adaptações

---

fisiológicas às condições estressantes, sendo o estudo desses parâmetros de vital importância para o entendimento dos ecossistemas do semiárido.

É de se ressaltar que este bioma possui um alto poder de resiliência, refletido quando da ocorrência de chuvas, que mesmo em baixas intensidades, produzem uma rápida resposta na vegetação nativa, que, de seca, se revigora em questões de dias. Isso ocorre em virtude de adaptações evolutivas que essas espécies vegetais passaram ao longo do tempo para sobreviver em um ambiente com condições tão estressantes (Silva et al, 2011).

### **2.1.2 Sensoriamento remoto em ambientes aquáticos**

Com relação à corpos hídricos, sua assinatura espectral é condicionada à sua pureza. A água limpa absorve mais energia que a água suja, devido à presença, nesta última, de matéria orgânica e material particulado. Os principais responsáveis pelo espalhamento da radiação na água são as partículas suspensas como bactérias, células dos fitoplânctons e os detritos orgânicos e inorgânicos, enquanto os principais absorvedores da radiação são os pigmentos fotossintéticos, os detritos orgânicos e a matéria orgânica (Ferreira e Pereira, 2009).

Desse modo, analisar os ambientes aquáticos sempre foi um desafio, pois, a água apresenta características singulares de interação com a radiação eletromagnética. E dentro desses estudos, a investigação da temperatura da água por sensoriamento remoto se apresenta como uma importante ferramenta de análise para conhecimento dos recursos naturais.

Segundo Sentlinger et al (2008), geralmente, determinar a temperatura em corpos hídricos de água doce é mais difícil que determinar o mesmo parâmetro no oceano, devido aos materiais que se misturam à água e causam interferência espectral no pixel. Esses compostos interferem na emissividade da água e alteram a resposta espectral, assim como, alguns deles podem reter mais calor, criando manchas mais quentes na água.

Segundo Handcock (2012), a medição da temperatura na superfície da água utilizando o infravermelho termal (TIR) obtido por sensoriamento remoto é uma alternativa para análise de corpos hídricos de forma especializada, sendo que as observações da TIR são fortemente afetadas pela radiação absorvida e emitida por vapor de água, sendo por isso que o foco das aplicações do TIR, se situam na

---



região do espectro eletromagnético compreendida entre 8 – 14 $\mu$ m, onde interferência atmosférica e a contaminação por radiação solar (na região 3 – 5 $\mu$ m) é minimizada.

O uso do sensoriamento remoto para estimar a temperatura da superfície da terra emprega a função de Planck. As medidas de temperatura da água por sensoriamento remoto são realizadas com sensores que detectam radiação termal (3-5 e 8-14 $\mu$ m) emitida pela camada milimétrica (0.1mm) da superfície da água (Xavier, 2014).

Na maioria das circunstâncias, mais de 90% da luz atingindo um satélite sobre um alvo aquático deriva da atmosfera (IOCCG, 2010). Portanto, a maior fonte potencial de erro e incerteza de medição do espaço é o erro residual na correção atmosférica (Mouw et al, 2015). E os erros decorridos da atmosfera são ainda mais importantes para estudos com corpos hídricos. Para minimizar esses erros, nas bandas do infravermelho próximo e de ondas curtas, que apresentam maior coeficiente de absorção da água, devem ser aplicadas correções para minimizar a interferência de fatores como o vento, vapor de água entre outros que interferem na emissividade dos corpos hídricos.

## 2.2 PRINCÍPIOS FÍSICOS QUE REGEM O COMPORTAMENTO TÉRMICO

Sendo de grande relevância para a distinção de alvos de superfície, o sensoriamento remoto termal é regido por algumas leis da física como a teoria do corpo negro, a equação de Stefan-Boltzmann, Teoria de Planck, teoria das emissividades, lei de Wien e de inércia térmica, que determinam o comportamento dos materiais quanto à sua emissão de radiação.

### 2.2.1 Teoria do Corpo Negro


Para entender como se comporta essa emissão de energia térmica em cada corpo, é de fundamental importância o modelo teórico do corpo negro. Conceitualmente, o corpo negro é aquele que absorve toda a radiação eletromagnética que nele incide, (Varejão-Silva, 2006). Como teoricamente nada reflete, é atribuído à ele a cor negra e daí vem o seu nome. Assim como é um absorvedor perfeito, um corpo negro é também um emissor perfeito. Esses corpos, que apesar de não existirem na natureza, servem como referencial para a emissão

---

de radiação, fundamento básico para a mensuração da temperatura de um determinado objeto.

Um corpo negro a uma determinada temperatura emite radiação por unidade de comprimento de onda, em todos os comprimentos desde zero ao infinito, mas não na mesma quantidade de radiação em cada comprimento de onda, (Figura 2). Observe que a radiância tende a zero, tanto para frequências muito altas quanto para frequências muito baixas. Possui ainda um máximo para cada frequência, cujo valor aumenta com a temperatura, para qualquer frequência dada, e que a radiância aumenta rapidamente com a temperatura.

Figura 2: Radiância espectral do corpo negro para algumas temperaturas



Fonte: UFRGS, 2016.

Assim, a razão entre as emitâncias reais e de corpo negro é o que se denomina de emissividade do corpo real e é expressa pela equação.

$$\varepsilon_{\lambda,T} = \frac{E_{\lambda}}{E_{\lambda,b}} \quad (1)$$

Na qual  $E_{\lambda}$  é a emitância espectral do corpo real em um dado comprimento de onda e temperatura.  $E_{\lambda,b}$  é a emitância espectral do corpo negro à mesma temperatura e comprimento de onda do corpo real (Xavier, 2014).

### 2.2.2 Equação de Stefan-Boltzmann

Segundo Pereira (2011) a energia emitida por um corpo negro por unidade de área e por unidade de tempo em todos os comprimentos de onda, isto é, o fluxo da

energia total emitida, é proporcional à quarta potência da temperatura Kelvin (lei de Stefan-Boltzmann): O modelo da aproximação desta lei para a energia radiante emitida em todo o espectro, que representa a integração total da função de Planck. A equação expressa esse princípio:

$$M = \varepsilon \sigma T^4 \quad (2)$$

Onde M representa a emitância radiante total hemisférica,  $\varepsilon$  a emitância total hemisférica, T a temperatura cinética e  $\sigma$  é a constante de Stefan-Boltzmann.

O parâmetro  $\varepsilon$  representa o quanto a emitância do corpo se aproxima da do corpo negro (Varejão-Silva, 2006).

### 2.2.3 Teoria de Planck

O físico Max Planck formulou sua teoria acerca das interações entre matéria e radiação. Ela propõe que a matéria pode emitir e absorver energia em pequenas quantidades e de forma não contínua. A teoria da radiação para o corpo negro define a radiância espectral em função do comprimento de onda e da temperatura do corpo negro (Varejão-Silva, 2006).

$$E(\lambda, T) = \frac{2\pi c^2}{\lambda^5} \frac{1}{(e^{\frac{hc}{\lambda T}} - 1)} \quad (3)$$

onde T indica a temperatura da superfície emissora de radiação (corpo negro) e  $\pi = 3,14159$ . Os demais símbolos representam as seguintes constantes.

$c = 2,99793 \times 10^{10} \text{ cms}^{-2}$ , sendo a velocidade de propagação da luz no vácuo;

$h = 6,6256 \times 10^{-27} \text{ erg s}$ , é a constante de Planck, e

$k = 1,3805 \times 10^{-16} \text{ cal cm}^2 \text{ min}^{-1}$ .

Onde I é a radiância espectral,  $\nu$  é a frequência, T é a temperatura do corpo negro, h é a constante de Planck, c é a velocidade da luz, e é o número de Euler e k é a constante de Boltzmann.

### 2.2.4 Emissividades

Define-se emissividade de uma superfície a uma temperatura T como a razão entre a intensidade da radiação emitida pela superfície no comprimento de onda  $\lambda$  e a intensidade de radiação emitida por um corpo negro nos mesmos valores de T e  $\lambda$ , (Pereira, 2015).

---

Conhecer o significado da emissividade dos elementos e de fundamental importância para entender os padrões de temperatura de cada objeto. A água por exemplo, é um material de alta emissividade, e segundo comprovou em 1860 o físico Gustav Kirchhoff, a capacidade de emissão é igual à capacidade de absorção de energia de um determinado corpo. Sendo assim, a água tem um grande potencial de absorção energética, ou seja, tem uma grande inércia térmica.

A emissividade direcional, integrada na faixa espectral de 8 a 12  $\mu\text{m}$ , é obtida a partir da seguinte equação:

$$\varepsilon = \frac{T_p^4 - T_1^4}{T_p^4 - T_2^4} \quad (4)$$

Onde  $\varepsilon$  é a emissividade da amostra (integrada na faixa espectral de 8 a 12  $\mu\text{m}$ ),  $T_1$  é a temperatura de radiação da amostra quando o plano superior é emissor,  $T_2$  é a temperatura de radiação da amostra quando o plano superior é refletor, e  $T_p$  é a temperatura cinética do plano superior, (Pachêco, 1998).

### 2.2.5 Lei de Wien

A lei de Wien afirma que para cada temperatura, existe um comprimento de onda para o qual a energia emitida pelo corpo negro é máxima (Varejão-Silva, 2006). O comprimento aumenta com a diminuição da temperatura segundo a lei do deslocamento de Wien que é determinada pela equação.

$$\lambda_m = \frac{b}{T} \quad (5)$$

sendo  $b$ , a constante de deslocamento de Wien:  $b = 2,90 \times 10^{-3} \text{ mK}$ .

$T$  = a temperatura em kelvin do corpo.

Desta forma quanto maior for a temperatura de um corpo, menor será o comprimento de onda emitida por ele.

### 2.2.6 Inércia Térmica

A inércia térmica é moldada a partir da relação entre a densidade, o calor específico e a capacidade térmica de um material. Em termos mais simplistas, essa inércia é a característica que cada material apresenta de aquecimento ao ser exposto à radiação térmica.

Esse comportamento tem grande destaque em corpos hídricos, pois se relaciona com o demorado tempo de aquecimento por radiação solar em massas de

---

água. Porém, esse aquecimento não se dá de forma uniforme nesses corpos. A presença de matérias misturadas na água altera a capacidade de retenção de calor, fazendo com que a distribuição da temperatura se dê de forma disforme. Sendo assim, fundamental fator influente na análise da temperatura de grandes massas de água.

Em alvos de superfície como solos e vegetação, a inércia térmica é menor, dessa forma, os alvos aquecem e esfriam mais rapidamente.

### 2.3 ANÁLISE ESPACIAL A PARTIR DO SEBAL (*SURFACE ENERGY BALANCE ALGORITHMS FOR LAND*)

Para avaliar as condições dos elementos da superfície como vegetação, corpos hídricos, tipos de solo, entre outros, e dessa forma, também os recursos naturais, a comunidade científica desenvolveu vários métodos de análise. Dentre eles o SEBAL (*Surface Energy Balance Algorithms for Land*), desenvolvido por Bastiaanssen em 1995, que obteve grande aceitação em função dos bons resultados obtidos pelo modelo.

O modelo SEBAL de Bastiaanssen (1995) é um algoritmo voltado para o estudo de fluxo de calor e estimativa da evapotranspiração, que se destaca pelo fato de utilizar suposições empíricas básicas e por necessitar de dados de sensores orbitais complementados por poucas informações de superfície; ademais, tem sido amplamente utilizado e aceito na comunidade científica nacional e internacional (Nicácio, 2008; Paiva et al. 2011; Bhattarai et al. 2012).

O algoritmo SEBAL faz uso das radiâncias espectrais registradas nos sensores dos satélites e de um conjunto de dados meteorológicos que incluem a velocidade do vento e a temperatura do ar, possibilitando, com isso calcular o balanço de energia na superfície da Terra e, assim, obter a estimativa da evapotranspiração nas escalas horária e diária (Courault et al., 2003)

Embora este algoritmo possa ser elaborado para calcular os componentes do balanço de energia em escala regional usando um mínimo de dados de campo, a parametrização local das equações pode melhorar a precisão das equações (Duchemin et al., 2006). Essa parametrização local se dá por meio de pesquisa de campo, onde dados coletados na área de estudo servem de referencial para avaliar

---

a qualidade da estimativa gerada pelo modelo, e adaptando o algoritmo para as condições específicas da região.

O uso do SEBAL tem a grande vantagem de proporcionar o balanço de energia à superfície de maneira efetiva e econômica. Possibilita grande cobertura espacial e, dependendo do sensor orbital que o alimenta com dados dos canais reflectivos e termais, pode também ter grande resolução espacial, (Silva, 2005).

Com dados adequados, as estimativas do modelo podem ser feitas em escalas espaciais e temporais permitindo a comparações de padrões espaciais, sazonais para variações inter-anuais da atividade da vegetação a ser avaliada (Heinsch et al., 2006).

Deste método, derivam variados componentes do balanço de energia que podem fornecer informações importantes sobre as características dos alvos superficiais.

Um destes componentes é o NDVI (*Normalized Difference Vegetation Index*). Este índice é usado para identificar a presença de vegetação verde na superfície, o que permite caracterizar sua distribuição espacial, bem como a evolução do seu estado ao longo do tempo, a qual é determinada pelas variações das condições climáticas dominantes, bem como pelos ciclos fenológicos anuais (Folhes, 2007). O NDVI é o método que calcula a diferença entre os valores refletidos da banda do infravermelho próximo e da banda do vermelho, normalizada pela soma dos mesmos valores. Este índice está associado a parâmetros biofísicos da cobertura vegetal, como biomassa e índice de área foliar. (Ponzoni e Shumabukuro, 2007). A cobertura verde saudável absorve a maior parte da luz vermelha e reflete a maior parte da luz do infravermelho próximo, pois a clorofila absorve principalmente a luz azul e vermelha e o mesófilo reflete a luz do infravermelho. Essa reflexão nesse comprimento de onda é influenciada pelas propriedades dos tecidos foliares das plantas como estrutura celular e cloroplastos, responsáveis pela fotossíntese, e estas características anatômicas são afetadas por fatores ambientais como umidade e salinidade do solo, e estado nutricional da folha (Ma et al, 2001).

O albedo de superfície é definido como a proporção do fluxo de energia refletida pela superfície em relação ao fluxo de energia que incide sobre a mesma. O albedo da superfície é um parâmetro muito importante, pois o seu monitoramento global possibilita detectar possíveis mudanças de uso do solo, variação do porte da

---

vegetação, aumento de áreas urbanas, que venham a ocorrer em diversos biomas do nosso planeta, resultantes de processos naturais e/ou antropogênicos, (Silva 2010). Redução de cobertura vegetal, solos impermeabilizados e áreas de salinização são alguns exemplos de fatores que ocasionam o aumento do albedo. Por outro lado, regiões como áreas de floresta conservadas, cultivo agrícola irrigado, e corpos hídricos apresentam valores baixos de albedo. Dessa forma, é possível afirmar que o albedo serve como importante parâmetro para se observar o estado de conservação de ambiental. Segundo Gomes (2009), exercem influência no albedo, variáveis micrometeorológicas como vento e o orvalho. E a oscilação do albedo ocorre de forma mais acentuada no decorrer do tempo, também em fator da precipitação.

A temperatura de superfície é mais um parâmetro de análise para estudos ambientais, e também, classificação de imagens. Herb et al. (2008) desenvolveram um modelo para determinação da temperatura da superfície visando a identificação dos diversos usos e cobertura da superfície, o qual pode ser usado para diferenciar mudanças na superfície. Essa variável é bastante influenciada pela precipitação, sendo assim, torna-se relevante a sua associação à dados meteorológicos, como forma de obtenção de informações mais fieis acerca dos alvos da superfície.

Este parâmetro assume importante papel para a distinção dos alvos, pois cada alvo exibe comportamentos térmicos distintos, baseados em seu potencial de calor. Em termos simplistas, o potencial de calor resulta da energia sendo absorvida, transmitida e refletida, às vezes, por várias vezes. Por exemplo, a água tem uma alta inércia térmica, o que significa que ela muda a temperatura lentamente quando a energia térmica é adicionada, e tem uma baixa condutividade térmica, ou seja, o calor passa através dela lentamente, e uma alta capacidade térmica, pois tem alta capacidade de armazenamento de calor (Handcock, 2012). Já os alvos terrestres apresentam comportamentos distintos de acordo com o tipo de alvo e seus componentes predominantes.

Outro parâmetro que pode ser utilizado na análise espacial é o saldo de radiação –  $R_n$  ( $W m^{-2}$ ). Este representa a quantidade de energia na forma de ondas eletromagnéticas disponíveis para serem divididos entre os fluxos de energia necessários aos processos de evapotranspiração, aquecimento do ar, aquecimento do solo e fotossíntese (Machado et al, 2014). O saldo de radiação exerce um papel

---

fundamental nos processos de troca de calor e massa na baixa atmosfera, uma vez que se constitui no principal responsável pelo aquecimento do solo, do ar e, principalmente, pela evapotranspiração da vegetação nativa e das culturas (Silva, 2005). Os fatores que constituem este agente climático são a radiação de ondas curtas que incidem na superfície, e a proporção desta que reflete em função do albedo, juntamente com a radiação de ondas longas que incidem na superfície e a radiação de onda longa que é emitida pelos objetos de acordo com sua temperatura e conseqüente poder de emissão térmica. O conjunto destas variáveis torna possível a distinção das classes de ocupação do solo, uma vez que cada um deles apresenta diferentes constituintes, variando a resposta espectral, além do que, ocorre variação mesmo dentro de alvos semelhantes. Alterações em estado de conservação, ocorrência de eventos chuvosos que afetam o albedo e a temperatura da superfície, grau de desenvolvimento de cultivos, efeitos topográficos são alguns fatores que influenciam no saldo de radiação.

Para as estimativas realizadas com esse modelo, diversos tipos de sensores podem ser utilizados gerando vários índices que o mesmo propõe. Para isso, é necessário que o sensor colete as faixas do espectro eletromagnético correspondentes ao comprimento de onda do visível, infravermelho próximo, e termal.

#### 2.4 CLASSIFICAÇÕES DE IMAGENS A PARTIR DO SOFTWARE SPRING

A classificação de imagens tem um importante valor para estudos ambientais. Através dela é possível extrair as categorias de uso de solo, informação fundamental para sua gestão.

Existem as classificações por pixel e por segmentação. A classificação por pixel leva em consideração a informação espectral de cada pixel isoladamente nas bandas que estiverem ativas no software. A segmentação de imagem é um procedimento adotado antes da fase de classificação no qual a imagem é dividida em regiões espectralmente homogêneas, e algumas dessas áreas são utilizadas como treinamento do classificador, (Dainese, 2001)

As classificações podem ser ainda supervisionadas, quando necessita de amostras de treinamento coletadas na imagem, ou, não-supervisionada, quando as informações são geradas pelo próprio algoritmo. Ou seja, o método de classificação

---



é dito supervisionado quando existe um conhecimento prévio de algumas áreas em que se deseja trabalhar, o que permite a seleção de amostras de treinamento confiáveis (Dainese, 2001).

Neste contexto existe a classificação por Máxima Verossimilhança (MAXVER). Este método considera a ponderação das distâncias entre médias dos níveis digitais das classes, utilizando parâmetros estatísticos. A distribuição de valores de reflectância em uma área de treinamento é descrita por uma função de densidade de probabilidade, desenvolvida com base na estatística Bayseana. Este classificador avalia a probabilidade de um determinado pixel pertencer a uma categoria a qual ele tem maior probabilidade de associação (INPE, 2002).

O outro método utilizado foi o da Distância Euclidiana ou Mínima. Este atribui cada elemento desconhecido à classe cuja média é mais próxima, ou seja, a atribuição de uma classe ao elemento depende da distância em relação à classe à qual este foi atribuído, (Hodgson, 1988).

## 2.5 CARACTERÍSTICAS DO SENSOR OLI/TIRS

A seguir, será apresentada uma breve revisão acerca dos sensores que compõe a série Landsat, abordando algumas das suas características e objetivos e destacando o que foi utilizado para a realização da pesquisa.

### 2.5.1 Sensores Landsat

A série Landsat (Land Remote Sensing Satellite), iniciou em 1972 com o lançamento do satélite ERTS-1. Ela teve sequência com os Landsat 2, 3, 4 e sobretudo com o Landsat 5 e 7. O principal objetivo do sistema Landsat foi o mapeamento multiespectral em alta resolução da superfície da Terra. Eles foram amplamente utilizados em todo o mundo, tornando-se uma rica fonte de dados para a análise ambiental. Os dois principais instrumentos imageadores do Landsat 5 eram: (MSS) Multispectral Scanner e (TM) Thematic Mapper.

O sensor TM possuía 7 bandas, cada uma representando uma determinada faixa do espectro eletromagnético. As bandas 1,2,3,4,5 e 7 possuem 30 m de resolução espacial, isto é, cada pixel da imagem representa uma área de 0,09ha de terreno, enquanto a banda 6, possui resolução de 120 m, cada pixel representa 1,4ha.

---

O mais novo sensor da série Landsat, apresenta alguns melhoramentos. Segundo Roy et al (2014), o menor comprimento de ondas das faixas espectrais, beneficia a acurácia dos dados, a partir do momento que o sensor é mais sensível às variações de energia existente entre os variados elementos da superfície.

Os projetos OLI (Operational Land Imager) e TIRS (Thermal Infrared Sensor), incorporam avanços técnicos que melhoram o seu desempenho em relação aos sensores Landsat anteriores. Significativamente, como o Advanced Land Imager (ALI) na EO1, o OLI e TIRS são sensores de varredura, com planos focais e longas matrizes de detectores através de faixas de alinhamento. Isso proporciona maior fidelidade geométrica, resolução radiométrica e sensibilidade para ruídos (Irons et al, 2012) em comparação com a tecnologia de sensor de varredura usada por instrumentos Landsat anteriores. Além disso, ele conta com novas bandas (Quadro 1): uma que visa estudos costeiros e estudos dos aerossóis (banda 1), outra de detecção de nuvens cirros (banda 9) e uma banda de avaliação da qualidade, e ajusta o comprimento de onda de cada banda.

Quadro 1: Faixas espectrais do Landsat OLI/TIRS.

Banda 1: Azul (0.43 - 0.45 $\mu\text{m}$ ) 30 m
Banda 2: Azul (0.450 - 0.51 $\mu\text{m}$ ) 30 m
Banda 3: Verde (0.53 - 0.59 $\mu\text{m}$ ) 30 m
Banda 4: Vermelho (0.64 - 0.67 $\mu\text{m}$ ) 30 m
Banda 5: Infravermelho Próximo (0.85 - 0.88 $\mu\text{m}$ ) 30 m
Banda 6: Infravermelho de Ondas Curtas (1.57 - 1.65 $\mu\text{m}$ ) 30 m
Banda 7: Infravermelho de Ondas Curtas (2.11 - 2.29 $\mu\text{m}$ ) 30 m
Banda 8: Pancromática (PAN) (0.50 - 0.68 $\mu\text{m}$ ) 15 m
Banda 9: Cirrus (1.36 - 1.38 $\mu\text{m}$ ) 30 m
Banda 10: Infravermelho Térmico (10.6 - 11.19 $\mu\text{m}$ ) 100 m
Banda 11: Infravermelho Térmico (11.5 - 12.51 $\mu\text{m}$ ) 100 m

Fonte: USGS, 2016.

## 2.6 MÉTODOS ESTATÍSTICOS

A seguir, serão abordados os métodos estatísticos utilizados para avaliar as classificações supervisionadas do ponto de vista da precisão temática.

---

### 2.6.1 Índice Kappa

A avaliação da acurácia pode ser obtida por meio de coeficientes de concordância derivados da matriz de confusão, sendo que estes podem ser expressos como concordância total ou para classes individuais. Congalton (1991) relata que o uso do coeficiente Kappa (equação 6) é satisfatório na avaliação da precisão de uma classificação temática, pelo fato de levar em consideração toda a matriz de confusão no seu cálculo, inclusive os elementos de fora da diagonal principal, os quais representam as discordâncias na classificação, diferentemente da exatidão global, por exemplo, que utiliza somente os elementos diagonais (concordância real).

Cohen (1960) define Kappa como um coeficiente de concordância para escala nominais que pede a proporção de concordância depois que a concordância atribuída a casualidade é retirada de consideração. O coeficiente Kappa considera todos os elementos da matriz de erros ao invés de apenas aqueles que se situam na diagonal principal da mesma, ou seja, estima a soma da coluna e linha marginais

A equação 6 representa o cálculo do índice:

$$k = \frac{\text{Pr}(a) - \text{Pr}(e)}{1 - \text{Pr}(e)} \quad (6)$$

onde Pr (a) é a proporção de unidades que concordam e Pr (e) é a proporção de unidades que concordam por casualidade.

### 2.6.2 Índice TAU

O coeficiente de concordância Tau baseia-se na probabilidade a priori (Klecka, 1980), ou seja, a concordância esperada (Pr) pode ser obtida antes mesmo de elaborar a matriz de erros. Pr é expresso por  $1/n$ , onde n é número de categorias ou classes. Pode ser considerado, ainda, se a classificação das categorias foi efetuada com a mesma probabilidade ou não (Ma & Redmond, 1995). Sua interpretação é feita da mesma forma do que coeficiente Kappa.

O coeficiente TAU (T) (Equação 7) é superficialmente similar ao KAPPA e pode ser calculado da seguinte forma (Figueredo, 2007):

$$T = \frac{P_0 - P_r}{1 - P_r} \quad (7)$$

Onde  $P_r = \sum_{i=1}^c P_{i+}$   $P_1 = \frac{1}{n^2} \sum_{i=1}^c x_{i+} x_i$

---

Sendo  $P_r$  a concordância casual, onde  $P_i = (X_{i+} / I_n)$  a distribuição marginal dos dados de referência,  $P_i = (X_i / I_n)$  as probabilidades a priori para cada classe e  $P_0$  a concordância real.

### 2.6.3 Matriz de Confusão/erros

Para que as imagens sejam interpretadas com confiabilidade, lança-se mão de algoritmos classificadores, que consistem em equações estatísticas implementadas em programas específicos, cuja finalidade é reduzir os erros de interpretação, que são influenciados por fatores relacionados à falta de qualidade das imagens, principalmente quando há distribuição dos valores numéricos dos pixels de classes distintas, (Cruz e Ribeiro, 2008).

Uma das formas de avaliar a exatidão de um classificador é a montagem da matriz de erros ou de confusão, na qual, partindo-se da amostra de validação, os resultados da classificação são organizados em matriz quadrada de dimensão igual ao número de classes (Congalton, 1991).

Ainda segundo Congalton (1991) a matriz de confusão (Equação 8) consiste numa matriz quadrada de números definidos em linhas e colunas que expressam o número de unidades da amostra (pixels, grupos de pixels ou polígonos) atribuído a uma categoria particular relativo à categoria atual, conforme foi verificado em campo. Geralmente, as colunas representam os dados de referência, enquanto as linhas representam a classificação gerada a partir dos dados de sensoriamento remoto.

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r x_{i+} x_{+i}}{N^2 - \sum_{i=1}^r x_{i+} x_{+i}} \quad (8)$$

Onde:

$r$  = Número de classes;

$x_{ii}$  = Número de elementos classificados corretamente;

$x_{i+}$  = Total de elementos classificados para uma categoria  $i$ ;

$x_{+i}$  = Total de elementos de referência amostrados para uma categoria  $i$ ;

$N$  = Número total de amostras.

Landis e Koch (1977) propõem uma escala de avaliação da qualidade da classificação (Quadro 2).

---

Quadro 2: Escala de qualidade da classificação.

<b>Valor do Kappa</b>	<b>Qualidade da Classificação</b>
<0,00	Péssima
0,00 – 0,20	Ruim
0,20 – 0,40	Razoável
0,40 – 0,60	Boa
0,60 – 0,80	Muito Boa
0,80 – 1,00	Excelente

Fonte: adaptado de Landis e Koch (1977)

## 2.7 ESTADO DA ARTE

Buscar a realização de um trabalho que esteja em consonância com pesquisas atuais ajudam a comprovar a relevância do objeto estudado, ao mesmo tempo que demonstra a preocupação da comunidade científica em resolver os problemas que se apresentam atualmente. Dessa forma, tanto a classificação de imagens, como os índices físicos são produtos importantes de análise espacial como apontam os autores a seguir.

Egorov et al (2015) apontaram a importância das classificações supervisionadas para a observação dos elementos espaciais. Destacou as dificuldades em obter classificações onde classes semelhantes de uso do solo possam ser eficientemente separadas. Os autores propõe o uso de segmentação de imagens como forma de obter melhores resultados nessas classificações.

Churches et al (2014) utilizaram classificação supervisionada em uma série de imagens do Landsat TM para observar as mudanças no uso da terra no Haiti. Foi utilizado a classificação por máxima verossimilhança, onde os resultados apontados foi a redução das áreas de florestas ao passar do tempo na ilha. Para avaliar as classificações, foi utilizado o índice Kappa, baseado na matriz de confusão.

Ding e Elmore (2015) utilizaram imagens Landsat TM/ETM+ para estudar a temperatura da Baía de Chesapeake entre os estados de Maryland e Virgínia nos Estados Unidos. Os resultados apontam para a influência da urbanização e industrialização para o aumento da temperatura de superfície da região, assim como os efluentes da usina de energia como fator para um maior aquecimento das águas da baía.

Ke et al (2015) realizaram um estudo comparando o NDVI estimado pelos sensores OLI do landsat 8 e ETM+ do landsat 7, com o NDVI obtido por meio de imagens do sensor MODIS. Ele concluiu que os resultados obtidos através das imagens do OLI foram mais consistentes que o ETM+ no sentido de discernir os alvos, baseado na maior variação entre os valores mais representativos para cada classe de ocupação do solo. Foi verificada a concordância da estimativa do NDVI obtido pelo OLI ao ser comparado com o derivado do sensor MODIS.

Matos et al (2016) fez uso de uma série de imagens do Landsat 5-TM para observar o comportamento temporal do albedo de superfície, NDVI e saldo de radiação na área ao entorno do reservatório de Itaparica. Foi observado como as mudanças de uso do solo, associadas com os fatores climáticos exercem influência nos índices físicos.

Zhou et al (2016) utilizaram dados de temperatura do MODIS e classificação supervisionada a partir de imagens OLI para mapear campos de arroz na planície de Panjin na China. As imagens de temperatura serviram para diferenciar as estações de crescimento da cultura relacionadas aos tempos de inundação. Para avaliar a precisão da classificação foram utilizadas a precisão global e o coeficiente Kappa, onde ambos apresentaram desempenhos de 95% e 90% respectivamente.

Bonhomme et al (2015) apontam para a utilização do coeficiente Kappa a partir da matriz de confusão para a avaliação das classificações de imagens provenientes de sensoriamento remoto visando as mudanças do uso da terra.

Reyes et al (2017) utilizaram a matriz de erros e o coeficiente Kappa para avaliar algumas classificações de imagem orientadas ao objeto, numa região com grande diversidade de feições como pastagens naturais, áreas agrícolas, superfície de água, solo exposto, e áreas urbanas.

---

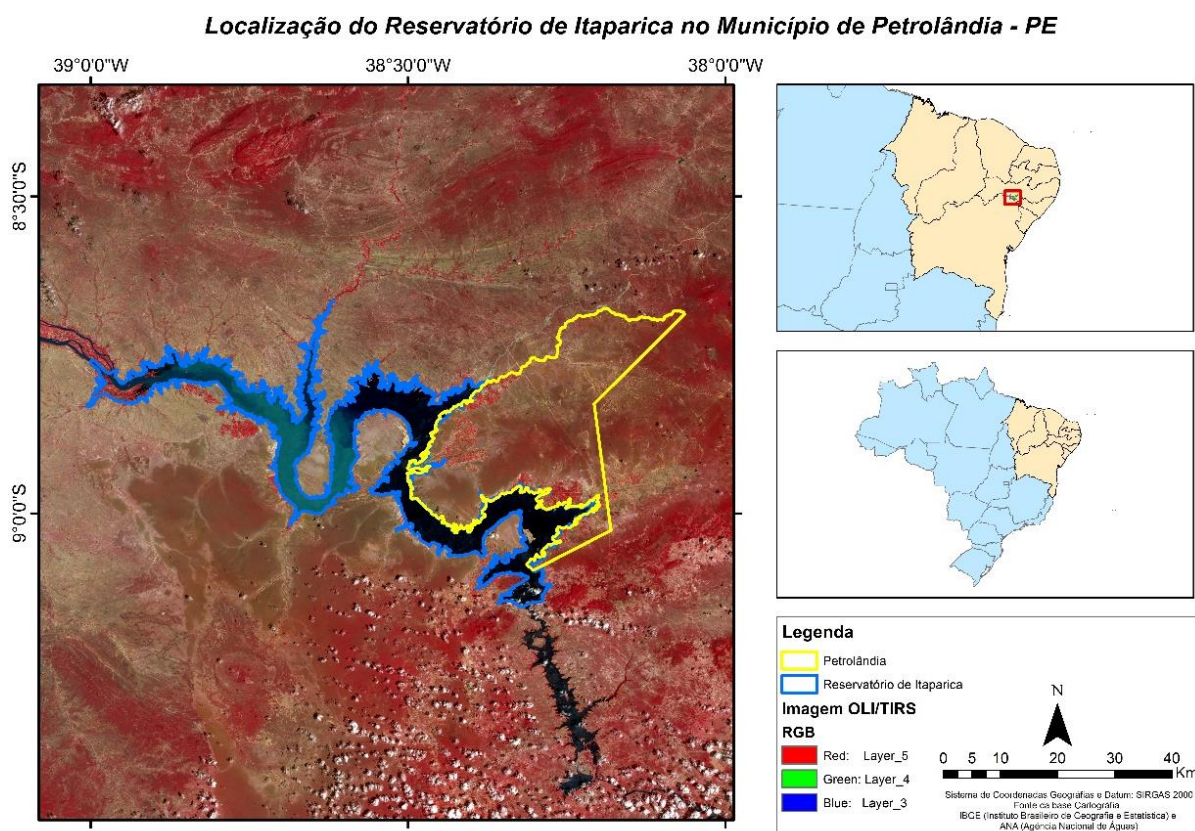
### 3 CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A área de estudo (Figura 3) é o reservatório da Hidroelétrica Luiz Gonzaga, mais conhecida como Barragem de Itaparica no município de Petrolândia em Pernambuco.

O município se localiza na mesorregião do Submédio Vale do São Francisco. Tem população estimada para 2016 de 35.731 habitantes, área de 1056,595 Km<sup>2</sup>, resultando numa densidade demográfica de 30,75 hab/km<sup>2</sup> (IBGE, 2016).

Longe da capital pernambucana, Recife, cerca de 430 km, fica a uma altitude de aproximadamente 280 metros, e tem clima semiárido do tipo BShw, segundo a classificação de Koppen (Matos et al, 2015). A vegetação é composta por caatinga hiperxerófila, e os solos predominantes são as Areias Quartzosas, Planossolos (EMBRAPA, 2001).

Figura 3: Mapa de Localização.

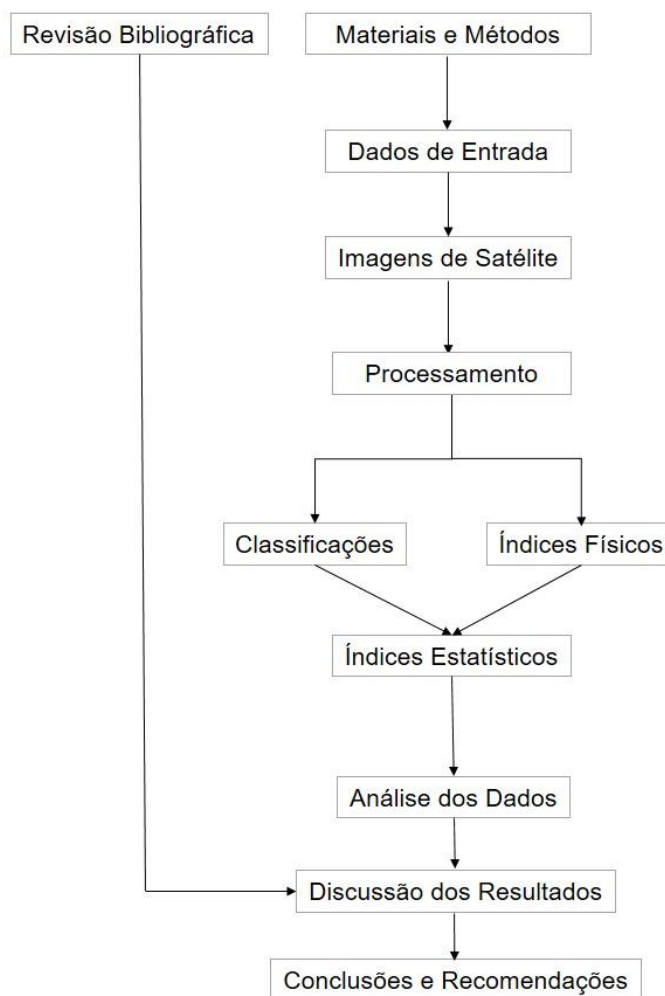


## 4 MATERIAIS E MÉTODOS

### 4.1 FLUXOGRAMA DOS PROCEDIMENTOS METODOLÓGICOS

O processo metodológico foi executado de acordo com o fluxograma.

Figura 4: Fluxograma dos procedimentos metodológicos



Fonte: Autor.

### 4.2 MATERIAIS UTILIZADOS

A seguir são listados os dados utilizados neste trabalho.

#### 4.2.1 Escolha e aquisição das imagens

A seleção das imagens buscou-se adquirir as que apresentassem menor presença de nuvens, e fossem temporalmente espaçadas a ponto de observar a

---




variação dos índices sazonalmente. Ao observar esses fatores, as imagens referentes às datas de 02/01/2014 e 11/06/2014, de órbita 216 e ponto 66, corresponderam à esses critérios, ambas de forma gratuita através da plataforma Earth Explorer sob responsabilidade da USGS (United States Geological Survey).

#### 4.2.2 Dados meteorológicos

Foram obtidos dados de precipitação pluviométrica mensais da série histórica do INMET (Instituto Nacional de Meteorologia), e foram separados os anos de 2013 e 2014 (Gráfico 1) para avaliar como a precipitação anterior à data das imagens influenciou na paisagem.

Gráfico 1: Dados de precipitação.



Fonte: INMET, 2016.

Além disso, foram obtidos no site do CPTEC (Centro de Previsão de Tempo e Estudos Climáticos), os mapas diários de precipitação para os dias imediatamente anteriores à datas das imagens de satélite utilizadas na pesquisa.

Para a semana anterior à imagem de 02/01/2014 (Figuras 5 e 6), é notável a ausência de precipitação de magnitude superior à 2mm para a região objeto do estudo.

Figura 5: Precipitação observada entre os dias 26/12/2013 à 29/12/2013.

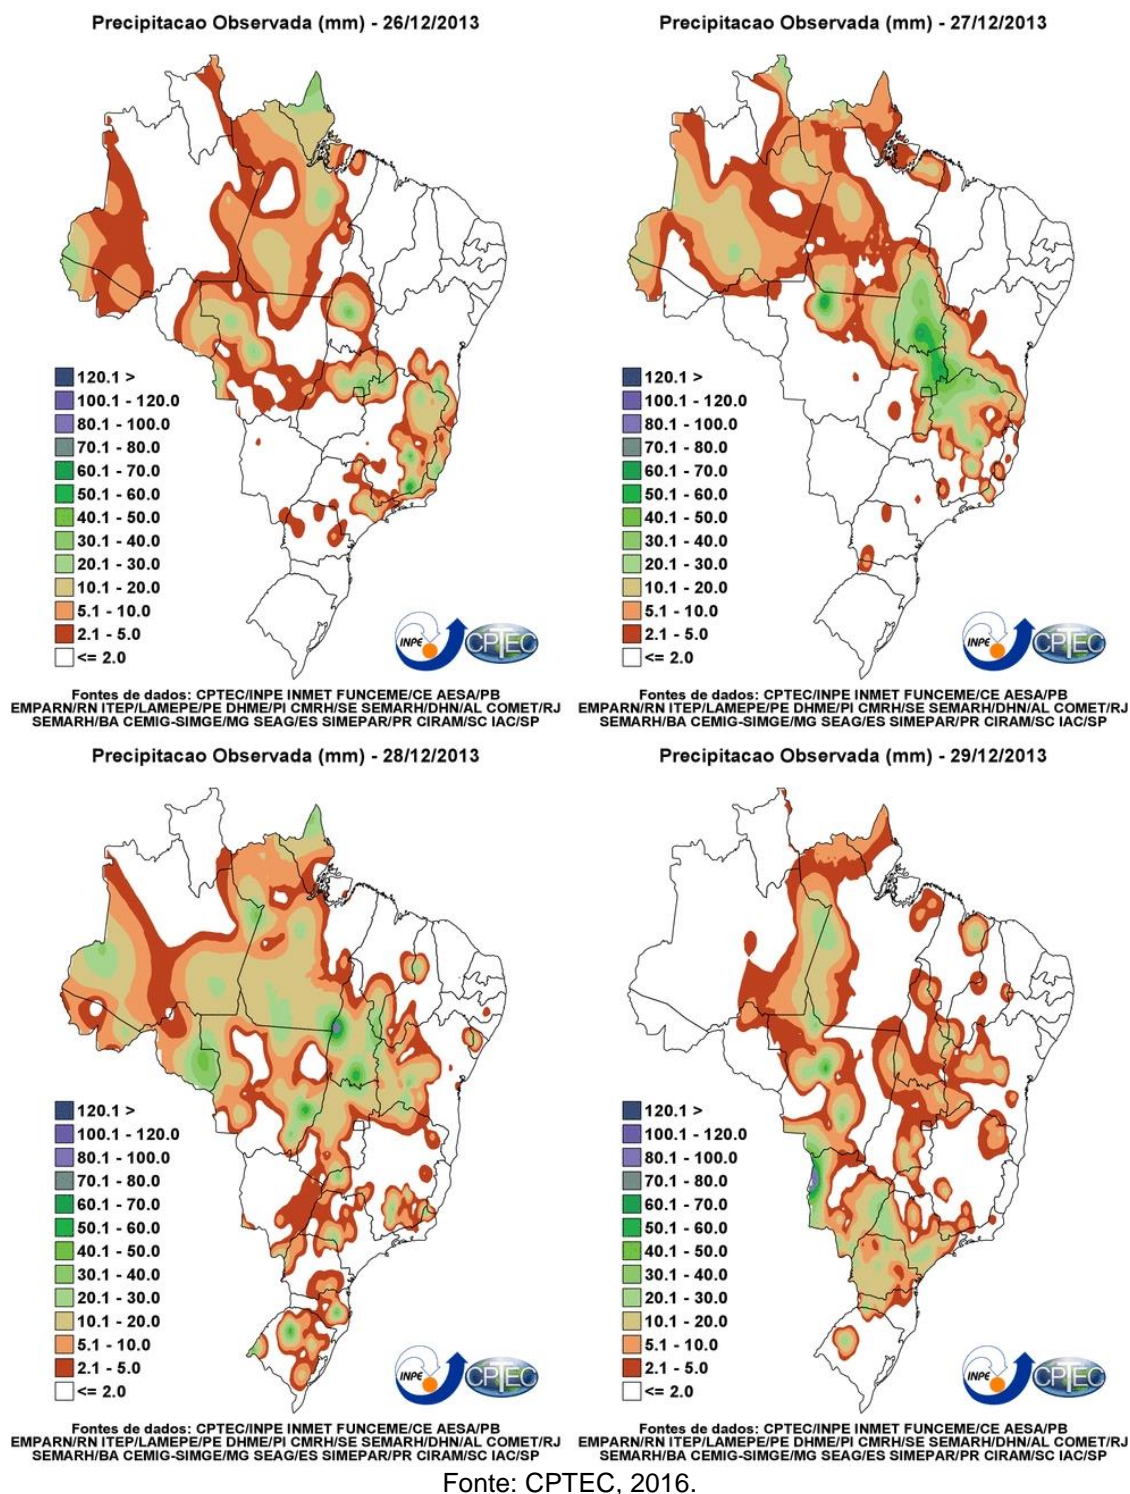
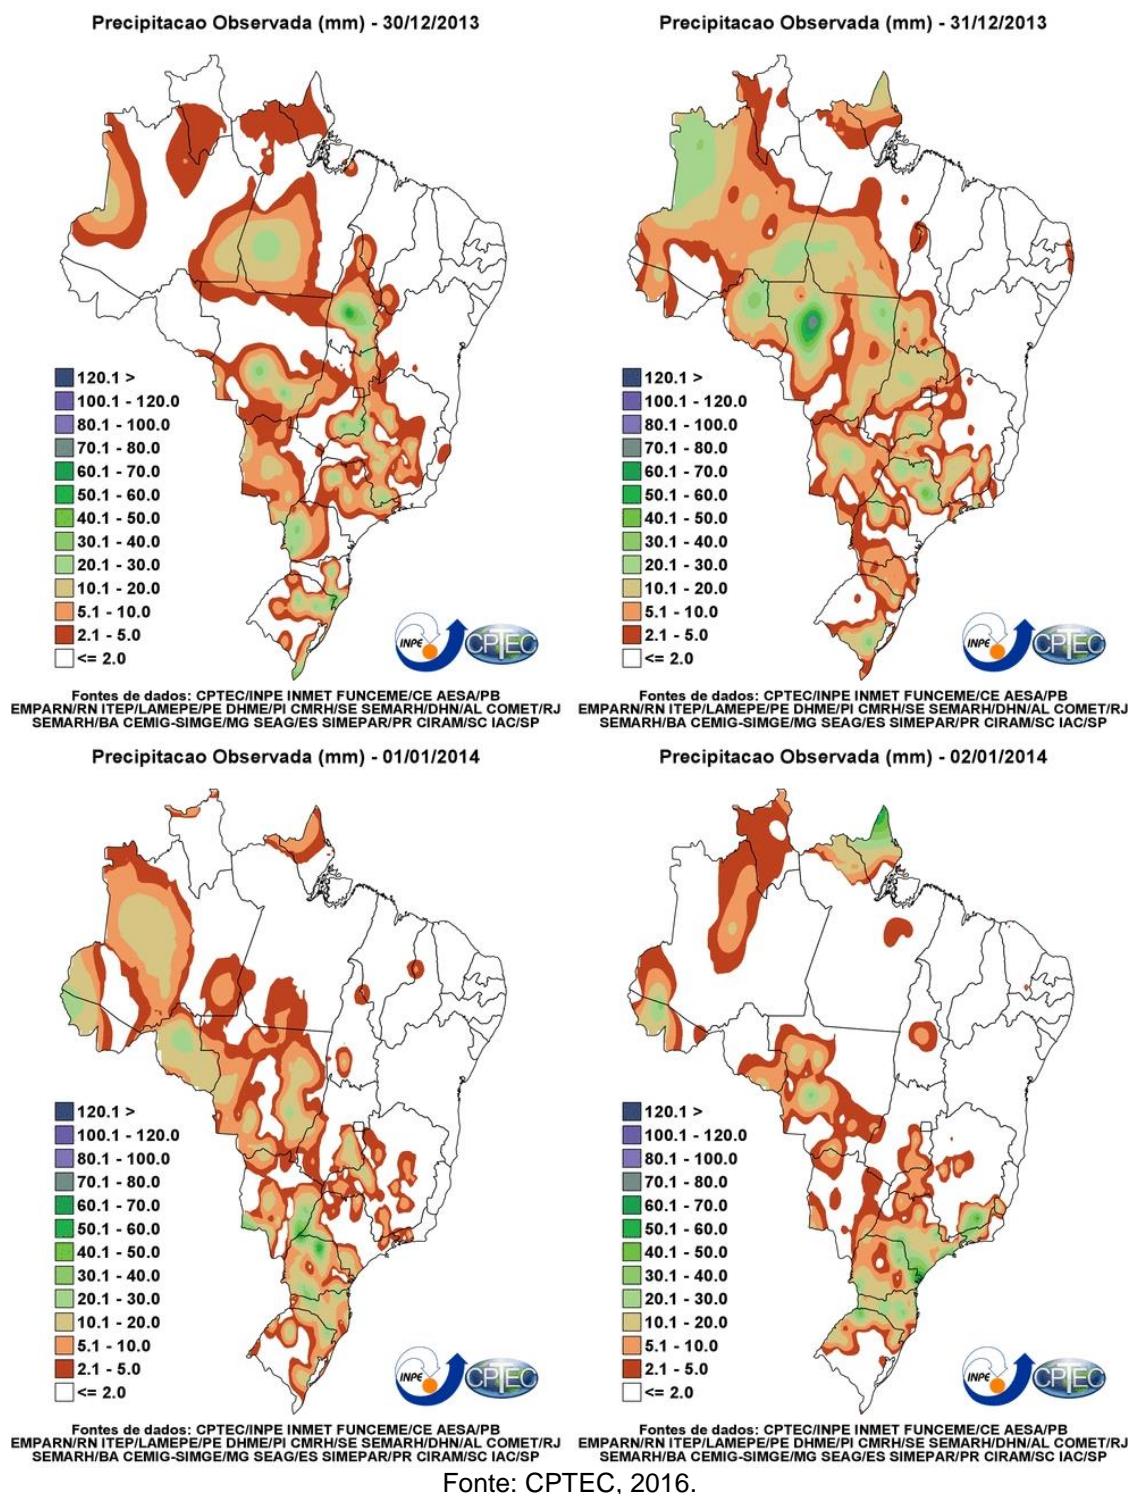


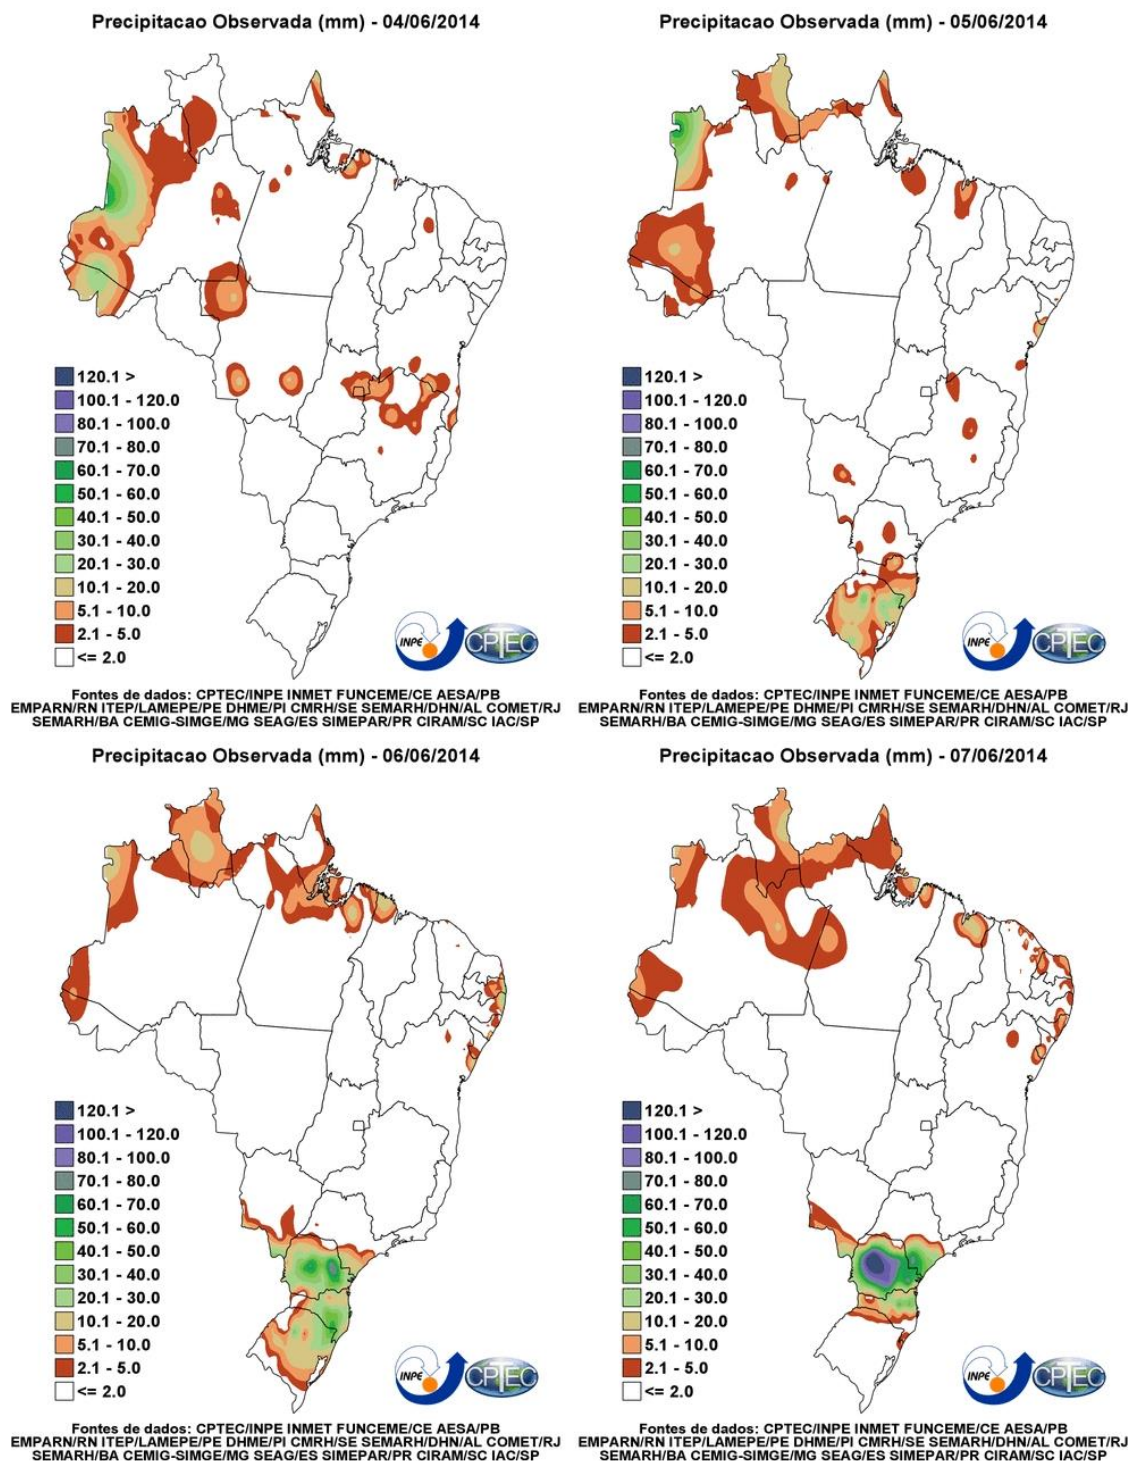
Figura 6: Precipitação observada entre os dias 30/12/2013 à 02/01/2014.



Para os mapas observados em junho (Figuras 7 e 8), pode ser observado que houve um evento chuvoso de aproximadamente 5mm exatamente no dia 11/06/2014, data da passagem do sensor OLI. Este fato ajuda a explicar a grande diferença encontrada sobretudo no albedo de superfície, temperatura de superfície e

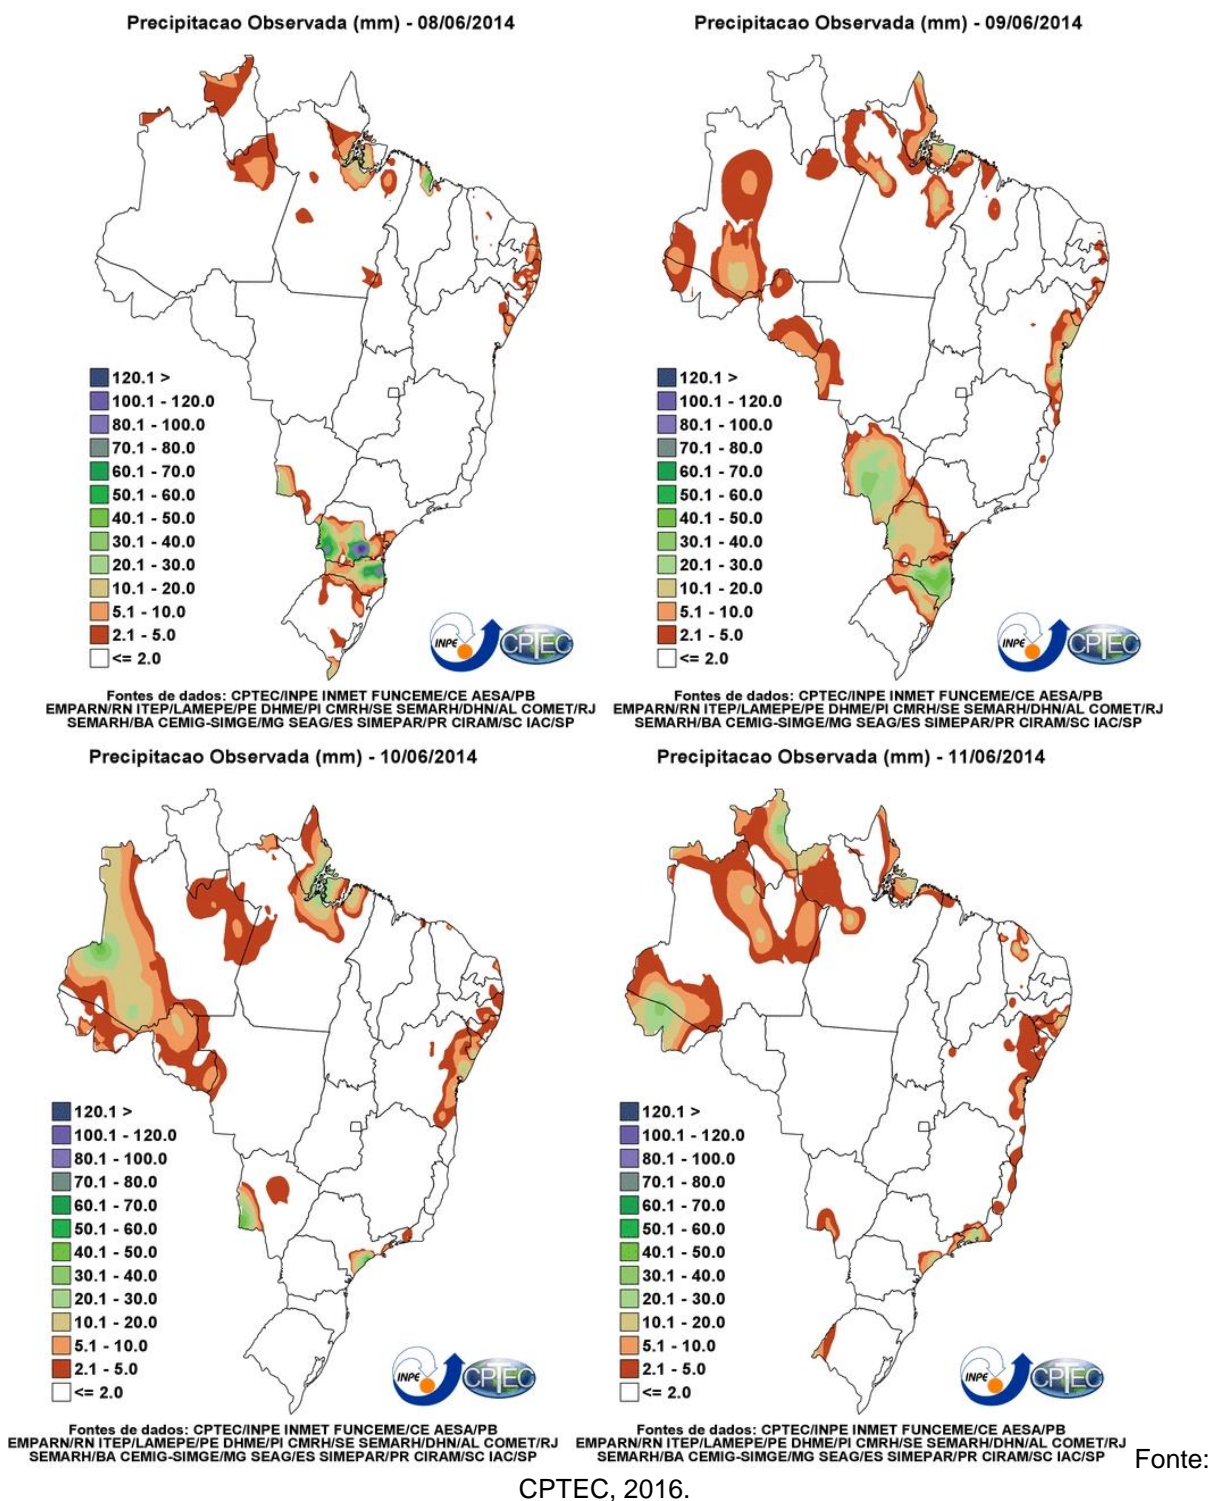
saldo de radiação, pois são diretamente impactados pelas condições meteorológicas no momento da captação da imagem.

Figura 7: Precipitação observada entre os dias 04/06/2013 à 07/06/2014.



Fonte: CPTEC, 2016.

Figura 8: Precipitação observada entre os dias 08/06/2014 à 11/06/2014.

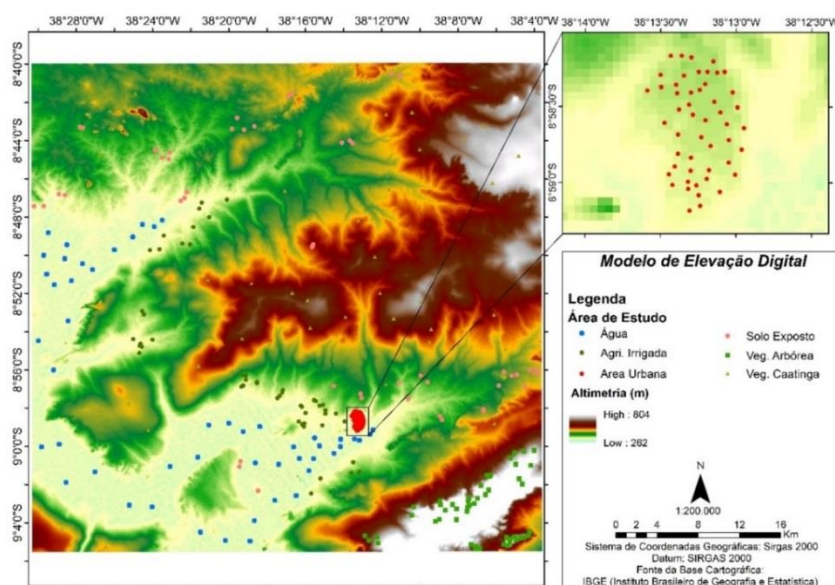


#### 4.2.3 Modelo de elevação digital

O modelo de elevação digital (Figura 9) foi utilizado para identificar a influência da altitude no uso do solo. Os dados foram obtidos através da página Brasil em Relevo da EMBRAPA. É possível notar que a presença da vegetação

arbórea se dá nas áreas de maior altitude. Os areais e o solo exposto predominam em áreas que fazem parte da drenagem da região. A agricultura irrigada se localiza em áreas próximas à represa e com características de relevo menos acentuadas, assim como o núcleo urbano do município (área em destaque).

Figura 9: Modelo de elevação digital.



Fonte: EMBRAPA, 2015. Edição: O autor.

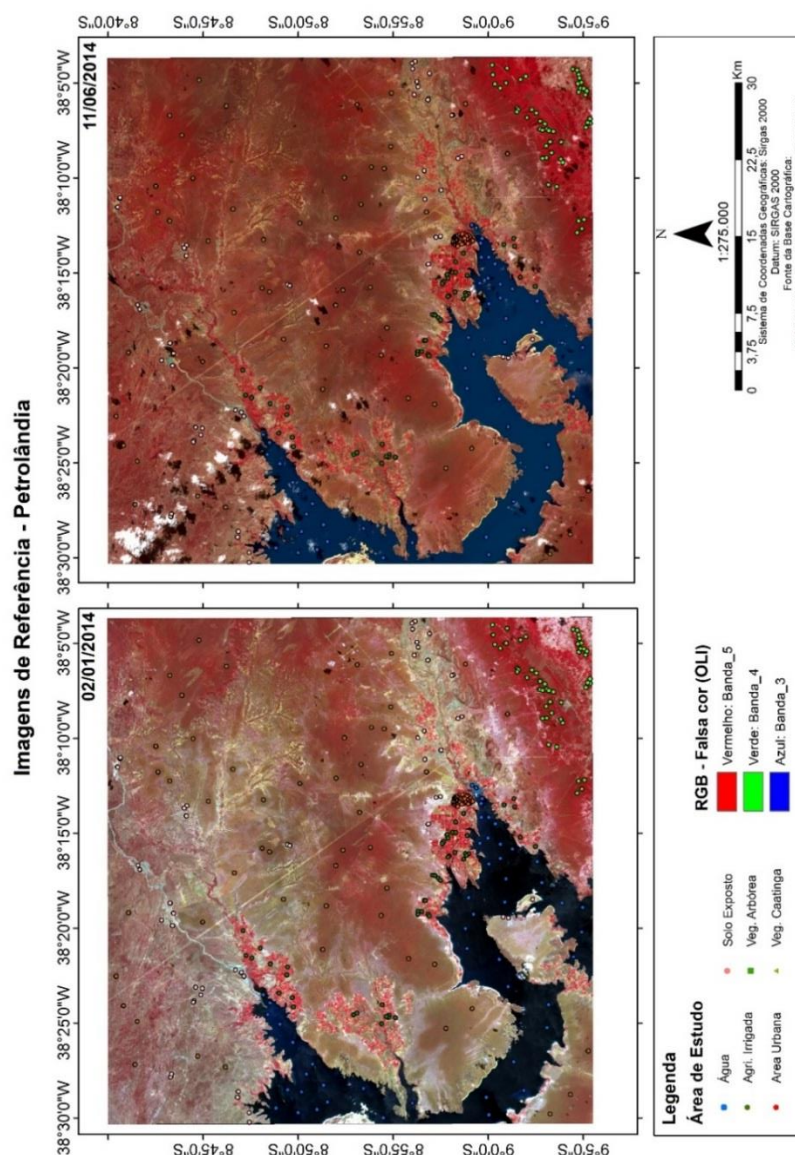
#### 4.2.4 Pontos amostrais

A interpretação visual de imagens orbitais de sensoriamento remoto utiliza os métodos de fotointerpretação, em especial, os elementos de reconhecimento para identificação do alvo, como forma, tonalidade, cor, localização, textura e padrão, em que o conhecimento e a experiência do analista a respeito da cena são fundamentais para resultados de boa qualidade, bem como as suas aptidões, como, por exemplo, o grau de percepção de detalhes (Jensen, 2009).

A partir desses conhecimentos, foram definidos 50 pontos para cada uma das seguintes classes: Água, agricultura irrigada, área urbana, solo exposto, vegetação arbórea e vegetação de caatinga, (Figura 10). Os pontos localizados na água foram espacializados pelo reservatório da represa de Itaparica. Os pontos de agricultura irrigada foram distribuídos pelos cultivos localizados próximos à margem do reservatório. Os de área urbana foram todos concentrados na cidade de Petrolândia, por ser o único núcleo urbano abrangido pela imagem. O solo exposto foi marcado

em áreas de areais e leitos secos de rios. A vegetação arbórea é predominantemente marcada em áreas de encostas e de maior altitude. Os de vegetação de caatinga foram especializados pela imagem toda, por ser a classe predominante na região.

Figura 10: Imagens utilizadas e pontos amostrais para as classes de uso do solo para as duas datas.



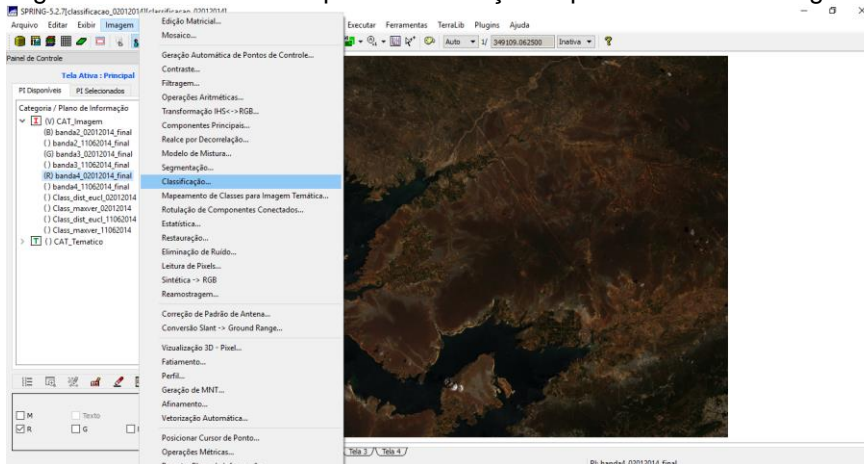
### 4.3 CLASSIFICAÇÃO SUPERVISIONADA

Existem diferentes tipos de classificação, e softwares classificadores. No presente trabalho, foram utilizadas a classificação por Máxima Verossimilhança e por Distância Euclidiana, ambas com uso do software Spring, versão 5.2.7.

Para realização das classificações por ambos os métodos, o processamento é semelhante, apenas alterando-se a escolha do método no último passo do processo de classificação.

Inicialmente deve-se atribuir aos canais do RGB, as respectivas bandas espectrais utilizadas como base para a classificação. A banda 2 no canal azul, a banda 3 no canal verde e a banda 4 no canal vermelho. Após isso, deve ser acionada a opção “Imagem” e em seguida “Classificação”, (Figura 11)

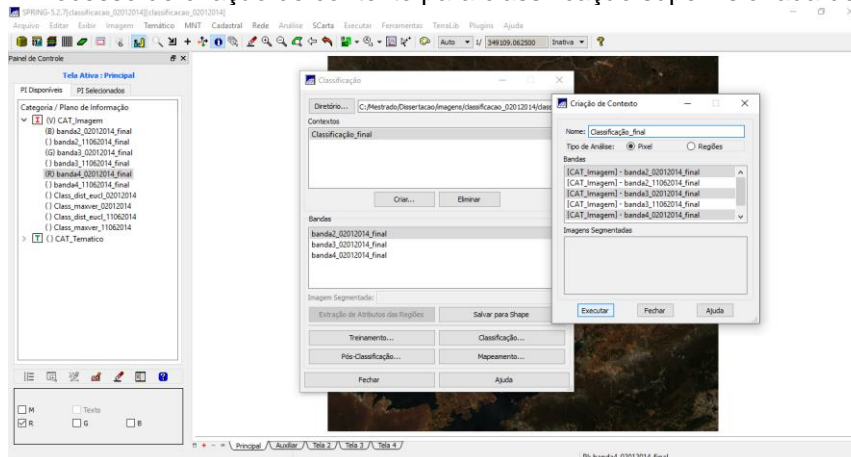
Figura11: Processo inicial para classificação supervisionada de imagens.



Fonte: Software Spring 5.2.7.

Em seguida cria-se e nomeia-se um “Contexto” (Figura 12) selecionando as bandas espectrais que serão utilizadas para a classificação, e clica-se em “Executar”. Após isso, deve-se clicar em “Treinamento”.

Figura 12: Processo de criação de contexto para classificação supervisionada de imagens.

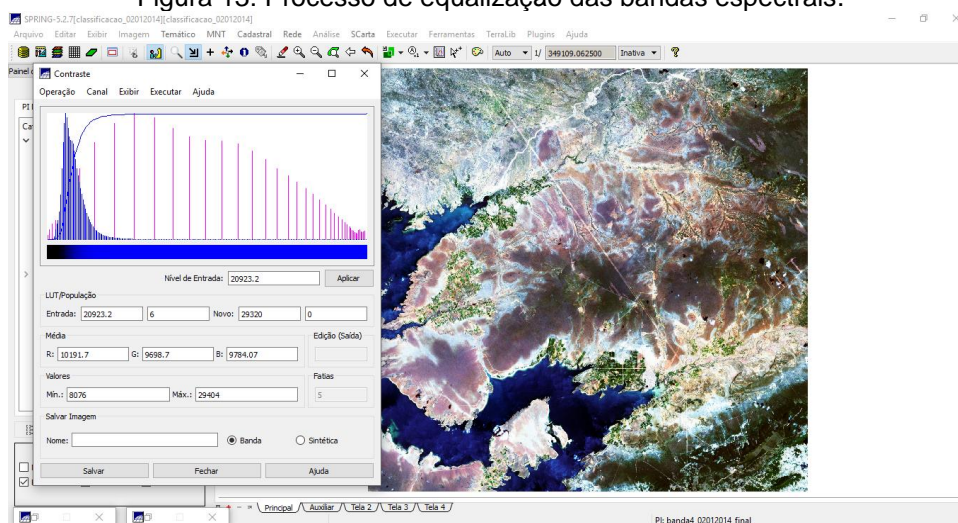


Fonte: Software Spring 5.2.7.



Para melhor visualização dos alvos e facilidade de obtenção de amostras que representem com fidedignidade as classes de uso do solo pode ser aplicado o processo de contraste nas bandas espectrais (Figura 13). Clica-se em “Imagem” na parte superior do menu, e seleciona-se a opção “Contraste”. A operação utilizada é a “Equalização de Histograma” e deve ser aplicada em cada um dos canais utilizados na classificação.

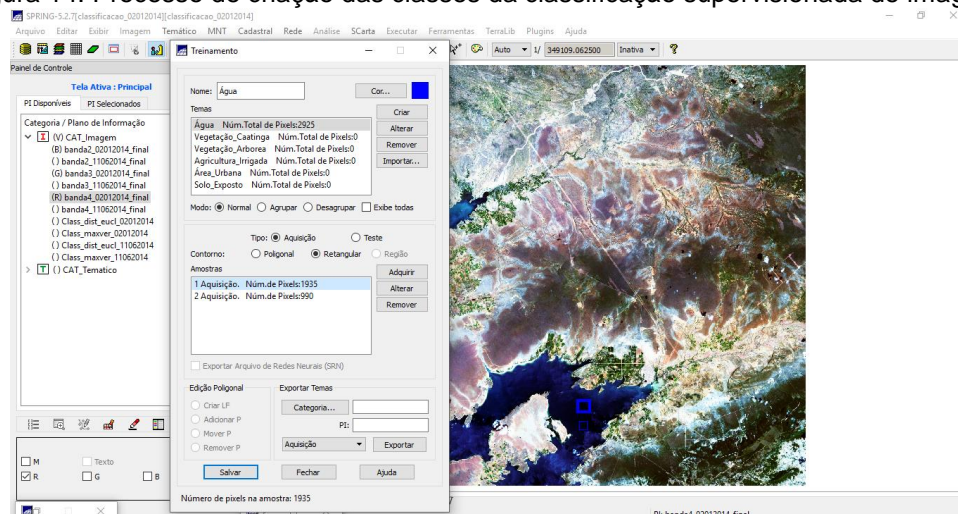
Figura 13: Processo de equalização das bandas espectrais.



Fonte: Software Spring 5.2.7.

O passo seguinte é criar as classes e atribuí-las as cores que serão utilizadas para diferenciar as classes no produto final (Figura 14).

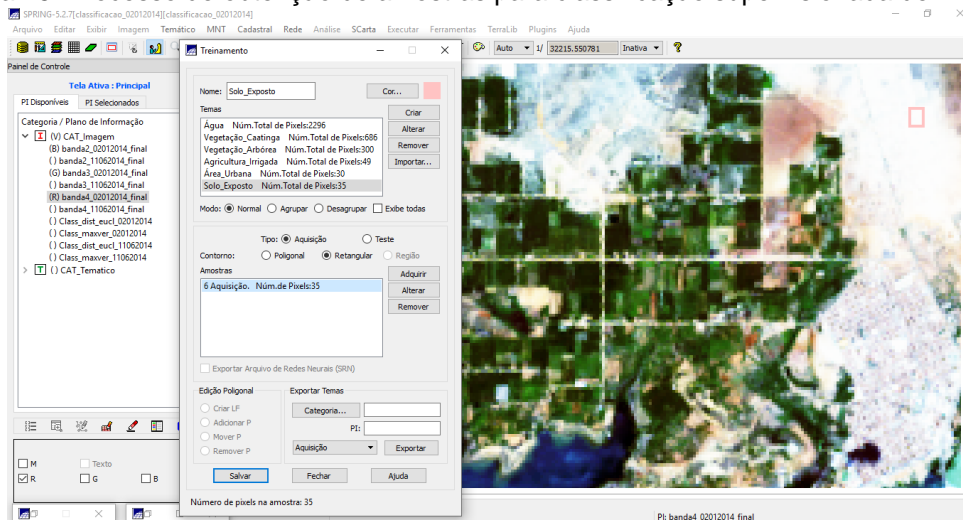
Figura 14: Processo de criação das classes da classificação supervisionada de imagens.



Fonte: Software Spring 5.2.7.

Após a obtenção de amostras para todas as classes presentes na imagem, deve-se salvar o treinamento (Figura 15).

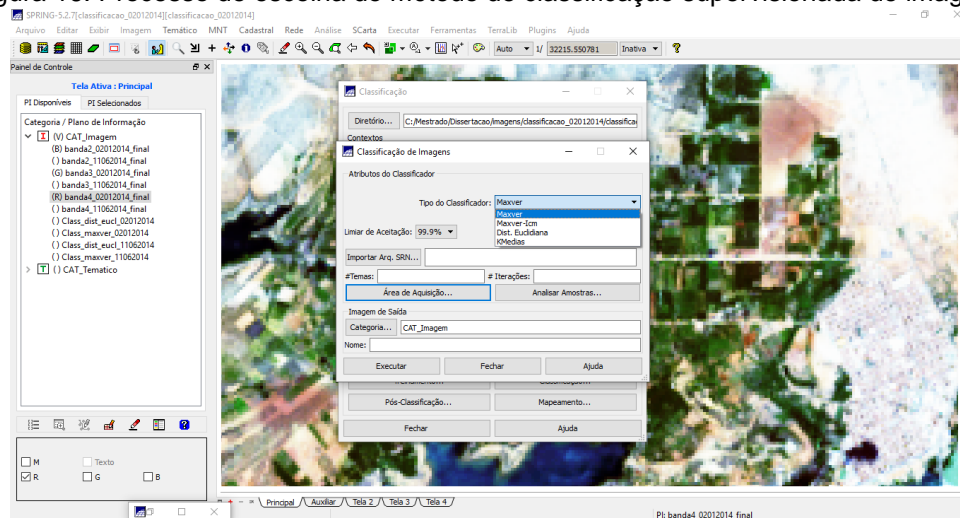
Figura 15: Processo de obtenção de amostras para classificação supervisionada de imagens.



Fonte: Software Spring 5.2.7.

O processo seguinte na aba de classificação é a escolha do método que será utilizado pelo programa para classificação (Figura 16). Além disso, nessa seção as amostras podem ser analisadas para a visualização da precisão da classificação de acordo com o método escolhido. É nessa etapa que se obtêm a matriz de confusão, precisão geral, índice Kappa e TAU, além das precisões do produtor e usuário que serão detalhadas na seção dos resultados.

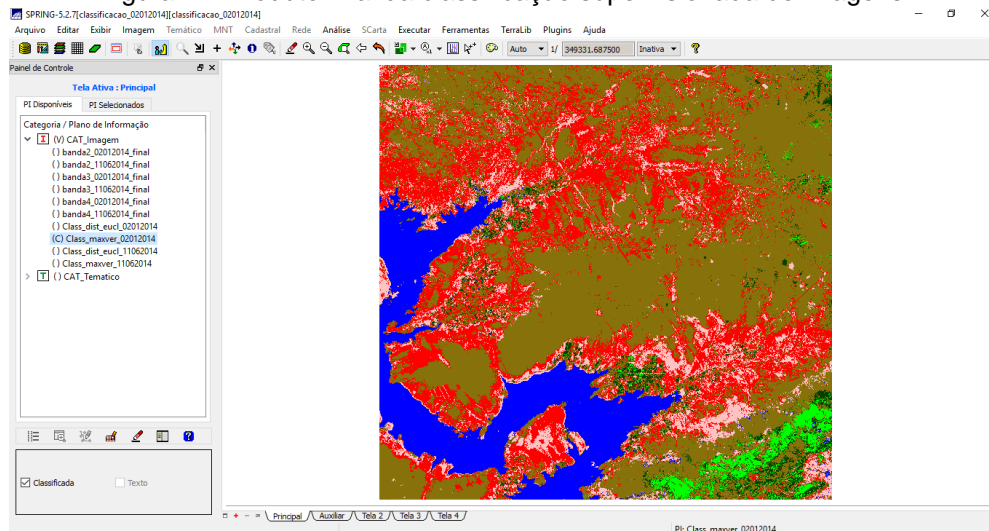
Figura 16: Processo de escolha do método de classificação supervisionada de imagens.



Fonte: Software Spring 5.2.7.

A Figura 17 representa o produto final da classificação supervisionada pelo método da máxima verossimilhança para a imagem do dia 02/01/2014. Nela pode-se observar as diferentes classes na região de estudo.

Figura 17: Produto final da classificação supervisionada de imagens.



Fonte: Software Spring 5.2.7.

#### 4.4 PROCESSAMENTO DAS IMAGENS OLI/TIRS

As imagens do Landsat 8 são disponibilizadas ortorretificadas, ou seja, corrigidas de deslocamentos da projeção de referência, processo que anteriormente era realizado manualmente pelo usuário, e que poderia aumentar o fator de erro, diminuindo a precisão do mapeamento.

O satélite Landsat 8 transporta uma carga de dois sensores, o Operacional Land Imager (OLI) e o Sensor de Infravermelhos Térmicos (TIRS), e estão resumidos na Tabela 1. As bandas espectrais OLI e TIRS permanecem globalmente comparáveis ao Thematic Mapper Landsat 7 (ETM +). Em comparação com a ETM +, a OLI tem duas faixas adicionais de comprimento de onda reflexiva: um novo comprimento menor de onda na faixa do azul ( $0,43 \mu\text{m} - 0,45\mu\text{m}$ ), e destina-se a melhorar a sensibilidade à clorofila e outros materiais em suspensão nas águas costeiras e para recuperar propriedades de aerossóis atmosféricos, e uma nova faixa de ondas curtas no infravermelho ( $1,36\mu\text{m} - 1,39\mu\text{m}$ ) para a detecção de cirros, (Roy, 2014).

Para geração dos índices propostos no algoritmo SEBAL, os seguintes passos devem ser seguidos:

#### 4.4.1 Conversão dos números digitais para radiância no topo da atmosfera

Os Números Digitais (ND) da imagem foram transformados para valores de radiância por meio da (Equação 9) segundo recomenda a USGS (2016):

$$L_{\lambda} = M_L Q_{cal} + A_L \quad (9)$$

onde: ( $L_{\lambda}$ ) é a radiância espectral no topo da atmosfera ( $W m^{-2}$ ); ( $M_L$ ) é o fator multiplicativo de redimensionamento específico para cada banda; ( $A_L$ ) corresponde ao fator de redimensionamento aditivo específico para cada banda e ( $Q_{cal}$ ) aos valores dos Números Digitais de cada pixel.

#### 4.4.2 Conversão dos números digitais para Refletância no Topo da Atmosfera

Para a obtenção da reflectância, é realizado a seguinte processo (Equação 10) segundo a USGS (2016).

$$\rho_{\lambda}' = M_p Q_{cal} + A_p \quad (10)$$

sendo: ( $\rho_{\lambda}'$ ) é a refletância planetária no topo da atmosfera sem correção para o ângulo solar; ( $M_p$ ) é o fator multiplicativo de redimensionamento específico para cada banda; ( $A_p$ ) é o fator de redimensionamento aditivo específico para cada banda e ( $Q_{cal}$ ) corresponde aos valores dos Números Digitais de cada pixel.

#### 4.4.3 Albedo Planetário ( $\alpha_{toa}$ )

O cálculo do albedo planetário ( $\alpha_{toa}$ ) para cada banda, isto é, o albedo não ajustado a transmissividade atmosférica, é obtido através de combinação linear entre as reflectâncias monocromáticas, pela equação 13, obtidos em Allen et al. (2002).

$$\alpha_{toa} = 0,300_{p1} + 0,276_{p2} + 0,233_{p3} + 0,143_{p4} + 0,035_{p5} + 0,012_{p7} \quad (13)$$


---

onde  $\rho_1$  é referente à banda 1 do sensor OLI,  $\rho_2$  se refere à banda 2,  $\rho_3$  à banda 3,  $\rho_4$  à banda 4,  $\rho_5$  à banda 5, e  $\rho_7$  se refere à banda 7.

Os coeficientes de peso para cada cálculo de cada banda foram obtidos em Ruhoff (2015).

#### 4.4.4 Transmissividade Atmosférica ( $\tau_{sw}$ )

A transmissividade atmosférica para condições de céu claro no domínio da radiação solar ( $T_{sw}$ ) é determinada em função da altitude da estação hidrometeorológica por Oliveira et al. (2010):

$$T_{sw} = 0,75 + 2 \cdot 10^{-5} z \quad (14)$$

onde  $z$  = altitude da região obtida pelo Modelo Digital de Elevação (MDE).

#### 4.4.5 Albedo de Superfície ( $\alpha$ )

O albedo da superfície ou albedo corrigido os efeitos atmosféricos ( $\alpha$ ) corresponde a equação 15:

$$\alpha = \frac{\alpha_{toa} \alpha_p}{T_{sw}^2} \quad (15)$$

sendo:  $\alpha_{toa}$  = albedo planetário;  $\alpha_p$  = porção da radiação solar refletida pela atmosfera, considerado 0,03 conforme Bastiaanssen (2000) e  $T_{sw}$  = transmissividade atmosférica para os dias de céu claro.

#### 4.4.6 Normalized Difference Vegetation Index (NDVI)

O NDVI (*Normalized Difference Vegetation Index*) utiliza uma razão entre as reflectâncias das bandas do vermelho e do infravermelho próximo (Equação 16). Essas bandas são escolhidas pelo fato de haver diferentes comportamentos da vegetação quanto à absorção e reflexão de energia em cada uma delas.

Segundo Wagner (2004) na faixa do vermelho, a absorção de energia solar é alta, influenciada pelos pigmentos presentes na planta, onde a mesma, se utiliza

---

dessa energia para realizar seus processos internos de nutrição, o que gera uma baixa reflectância. Em contrapartida, na faixa do infravermelho próximo, a absorção é baixa, resultado da mudança do índice de refração nas áreas frontais de ar/célula do mesófilo, gerando dessa maneira uma alta reflectância. Essa relação, possibilita a análise das características da vegetação, e a distinção das classes vegetais quanto à porte, biomassa fotossintetizante e conteúdo hídrico.

$$NDVI = \frac{(\rho_{IV} - \rho_V)}{(\rho_{IV} + \rho_V)} \quad (16)$$

onde  $\rho_{IV}$  significa a banda do infravermelho próximo, e  $\rho_V$  a banda do vermelho.

#### 4.4.7 Soil Adjusted Vegetation Index (SAVI)

Para o cálculo do SAVI (*Soil Adjusted Vegetation Index*) (Equação 17) que é um índice que busca amenizar os efeitos da reflectância do solo na vegetação, pode-se utilizar a expressão (Huete, 1988):

$$SAVI = \frac{(1+L)(\rho_{IV} - \rho_V)}{L + (\rho_{IV} + \rho_V)} \quad (17)$$

onde  $\rho_{IV}$  significa a banda do infravermelho próximo, e  $\rho_V$  a banda do vermelho e L, é a constante de correção do solo e corresponde ao valor de 0,5.

Com imagens dos satélites Landsat 5 e 7 eram utilizadas as bandas 3 e 4, vermelho e infravermelho próximo respectivamente, com o Landsat 8, essas bandas agora se tornaram a 4 e a 5, devido a inserção de banda do azul, resultado da maior sensibilidade do sensor à menores comprimentos de onda.

#### 4.4.8 LAI (Leaf área index)

O LAI (*Leaf Area Index*) é a razão entre a área foliar da vegetação em relação à unidade de área que esta vegetação é ocorrente. Dessa forma, segundo Allen (2002), este índice é um indicador da biomassa presente em cada pixel da imagem, e pode ser obtido pela equação empírica obtida pelo mesmo, (Equação 18):

$$LAI = \frac{\ln\left(\frac{0,69 - SAVI}{0,59}\right)}{0,91} \quad (18)$$

#### 4.4.9 Emissividades

Na determinação da emissividade ( $\epsilon_{NB}$ ), empregou-se a expressão, em que o LAI é o índice de área foliar obtido com base no índice de vegetação ajustado para efeitos do solo (SAVI) que é função da reflectância do infravermelho próximo e vermelho. Esta equação tem validade para  $IAF < 3$  e, em casos que  $LAI \geq 3$ , considera-se  $\epsilon_{NB} = 0,98$  e, para corpos de água  $\epsilon_{NB} = 0,99$ , (Oliveira et al, 2012). Segundo Allen et al. (2002), as emissividades  $\epsilon_{NB}$  (Equação 19) e  $\epsilon_0$  (Equação 20) podem ser obtidas, para  $NDVI > 0$  e  $IAF < 3$ , segundo, (Machado, 2010):

$$\epsilon_{NB} = 0,97 + 0,00331 * LAI \quad (19)$$

$$\epsilon_0 = 0,95 + 0,01 * LAI \quad (20)$$

Para pixels com  $IAF \geq 3$ , ( $\epsilon_{NB} = \epsilon_0 = 0,98$ ). Para corpos de água ( $NDVI < 0$ ), no caso do lago de Sobradinho e do leito do Rio São Francisco, Silva & Cândido (2004) utilizaram os valores de 0,99 e 0,985, conforme Allen et al. (2002).

#### 4.4.10 Temperatura de Superfície ( $T_{sup}$ )

Para a obtenção da temperatura da superfície ( $T_{sup}$ ) são utilizadas a radiância espectral da banda termal  $L_{\lambda 10}$  e a emissividade ( $\epsilon_{NB}$ ).

$$T_{sup} = \frac{K_2}{\left( \frac{\epsilon_{NB} K_1}{L_{\lambda,6}} + 1 \right)} \quad (21)$$

onde:  $T_{sup}$  = Temperatura da superfície (K ou Celsius);  $K_1 = 607,76$  ( $Wm^{-2} sr^{-1} \mu m^{-1}$ ) e  $K_2 = 1260,56$  (K) são constantes de calibração específicas do TM Landsat 5;  $L_{\lambda 6}$  = radiância espectral da banda termal, (Allen et al., 2002; Silva et al., 2005). Para o Landsat 8 são utilizadas as bandas 10 ou 11.

A temperatura é inicialmente obtida em graus Kelvin, podendo ser posteriormente transformada para graus Celcius.

#### 4.4.11 Radiação de Onda Curta Incidente ( $R_{OC\_INC}$ )

A radiação de onda curta incidente ( $R_{OC\_INC}$ ) em  $W m^{-2}$ , segundo Bastiaanssen (2000) refere-se ao fluxo de radiação solar global (direta juntamente com difusa) que

---

incide em cada pixel na passagem do satélite e pode ser obtida através da equação 22:

$$R_{OC\_INC} = S \cos Z d_r T_{SW} \quad (22)$$

onde:  $S$  = constante solar ( $1367 \text{ W m}^{-2}$ );  $Z$  = ângulo zenital solar;  $T_{SW}$  = transmissividade atmosférica para condições de céu claro no domínio da radiação solar;  $d_r$  = inverso do quadrado da distância Terra-Sol num determinado dia do ano.

#### 4.4.12 Radiação de Onda Longa Incidente ( $R_{OL\_INC}$ )

A radiação de onda longa incidente à superfície  $R_{OL\_INC}$  ( $\text{W m}^{-2}$ ) representa o fluxo da radiação termal emitido pela atmosfera na direção da superfície e foi obtida através da equação de Stefan-Boltzmann, Silva (2004).

$$R_{OL\_INC} = \epsilon_a \sigma T_{ar}^4 \quad (23)$$

em que  $\epsilon_a$  é a emissividade atmosférica, obtida segundo Duarte et al. (2006),  $\sigma$  é a constante de Stefan-Boltzmann ( $5,67 \times 10^{-8} \text{ W m}^{-2} \text{ K}^{-4}$ ) e  $T_a$  é a temperatura do ar (K).

$$\epsilon_a = 0,85 (-1nT_{SW})^{0,09} \quad (24)$$

sendo:  $T_{SW}$  = transmissividade atmosférica para condições de céu claro no domínio da radiação solar, que foi calculada pela equação 14.

#### 4.4.13 Radiação de Onda Longa Emitida ( $R_{OL\_EMI}$ )

Da mesma forma que a anterior, a radiação de onda longa emitida pela superfície ( $R_{OL\_EMI}$ ) em  $\text{W m}^{-2}$ , é calculada segundo a equação de Stefan-Boltzmann:

$$R_{OL\_EMI} = \epsilon_0 \sigma T_{ar}^4 \quad (25)$$

onde:  $T_{sup}$  = temperatura da superfície (K);  $\epsilon_0$  = emissividade no domínio da banda larga;  $\sigma$  = constante de Stefan-Boltzman ( $\sigma = 5,67 \times 10^{-8} \text{ Wm}^{-2} \text{ K}^{-4}$ ).

---



#### 4.4.14 Saldo de Radiação à Superfície (Rn)

O saldo de radiação é definido pela equação 26 de Allen et al (2002).

$$R_n = R_{OC\_INC} (1-\alpha) + R_{OL\_INC} - R_{OLEMI} - (1-\epsilon_0) R_{OL\_INC} \quad (26)$$

sendo:  $R_{OC\_INC}$  = radiação de onda curta incidente ( $W\ m^{-2}$ );  $R_{OL\_INC}$  = radiação de onda longa incidente ( $W\ m^{-2}$ );  $R_{OLEMI}$  = radiação de onda longa emitida pela superfície ( $W\ m^{-2}$ );  $\alpha$  = albedo da superfície (%);  $\epsilon_0$  = emissividade no domínio da banda larga de cada pixel.

---

## 5 RESULTADOS E DISCUSSÃO

A seguir, serão apresentados e discutidos os resultados obtidos pelos métodos anteriormente explanados.

### 5.1 CLASSIFICAÇÃO PELO SOFTWARE SPRING

Nesta seção, serão abordados os produtos gerados a partir da classificação supervisionada gerada no software SPRING.

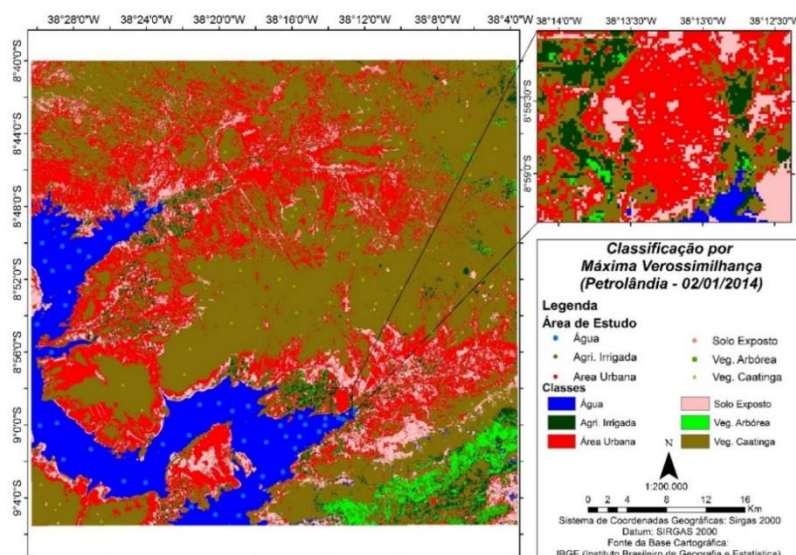
#### 5.1.1 Classificação pelo método da Máxima Verossimilhança

Os tópicos a seguir trazem a apresentação e discussão dos dados obtidos pela classificação através do método da Máxima Verossimilhança para as imagens do sensor OLI nas duas datas, assim como as estatísticas obtidas através da coleta dos pontos amostrais nas diferentes classes de uso do solo.

##### 5.1.1.1 Imagem de 02/01/2014

O método de classificação por Máxima Verossimilhança para a imagem datada de 02/01/2014 (Figura 18).

Figura 18: Classificação por Máxima Verossimilhança (02/01/2014).



Fonte: O autor.

A classificação apresentou um desempenho geral de 95.16% (Tabela 1), porém, por este parâmetro considerar apenas os valores da diagonal principal da

matriz de confusão (Tabela 2), o alto desempenho neste caso é reflexo da grande quantidade de amostras das classes de água e vegetação de caatinga, onde houve menor confusão por estas classes se destacarem das demais, dessa forma, elas exerceram maior influência na classificação.

O índice Kappa, que considera todos os valores da matriz resultou em 92.99%, o que segundo Landis e Koch (1977) é considerado excelente, porém também influenciado pela grande quantidade de pixels das duas classes predominantes na imagem, vegetação de caatinga e água. O índice TAU também apresentou um elevado coeficiente (94.19%), se aproximando assim do Kappa.

Tabela 1: Estatísticas gerais da classificação por máxima verossimilhança (02/01/2016).

Desempenho Geral	95.16%
Confusão Média	4.84%
Estatística KAPPA	92.99 %
Estatística TAU	94.19%

Fonte: Software Spring 5.2.7.

Tabela 2: Matriz de Confusão da Classificação por Máxima Verossimilhança (02/01/2014).

Classes	Água	Agri. Irrigada	Área Urbana	Solo Exposto	Veg. Arbórea	Veg. Caatinga	Soma (Linha)
Água	1371	0	0	6	0	0	1377
Agri. Irrigada	0	48	0	0	29	0	77
Área Urbana	0	0	50	3	0	0	53
Solo Exposto	0	0	35	262	0	0	297
Veg. Arbórea	0	18	0	0	308	0	326
Veg. Caatinga	0	18	35	7	0	931	911
Soma (Coluna)	1371	84	120	278	337	931	3121

Fonte: Software Spring 5.2.7.

Uma forma melhor de observar a qualidade da classificação é por meio das exatidões do usuário e do produtor (Tabela 3). A exatidão do produtor significa a proporção da quantidade de pixels classificados corretamente na categoria que lhe foi atribuída no processo de aquisição de amostras, pelo número total de pixels coletados nessa classe, ou seja, é a porcentagem de pixels que foram classificados

corretamente dentro de própria classe. Já a exatidão do usuário significa a proporção nessa classe de pontos atribuídos decorrentes de erros nas outras classes.

A exatidão do produtor das classes de água e vegetação de caatinga, aponta para que 100% dos pixels coletados como ambas as classes, foram realmente classificados como tal. Na exatidão do usuário, a água com 99.56%, ou seja, nessa proporção, das vezes que um observador visualizar um pixel referente a água, realmente esse pixel estará classificado como água. A vegetação de caatinga apresentou exatidão do usuário de 93.95%. O solo exposto obteve exatidão do produtor de 94.24% e 88.22% de exatidão do usuário, sendo bem classificado por ambos os parâmetros. A vegetação arbórea apresentou valores de 91.39% para exatidão do produtor, e 94.48% de exatidão do usuário. A classe referente à agricultura irrigada teve exatidão do produtor de 57.14% e exatidão do usuário de 62.34%. Esta classe, apesar de estar classificada como boa, seu desempenho foi menor que as classes anteriores. Nessa classe por suas características espectrais, houve confusão com a vegetação arbórea. A classe de área urbana, que na realidade está concentrada na cidade de Petrolândia, região destacada pelo enquadramento na figura, obteve 41.67% de exatidão do produtor, porém 94.24% de exatidão de usuário. Essa classe foi em grande parte superestimada, sendo atribuído à ela, a maior parte do solo exposto. Ambas as classes apresentam valores espectrais semelhantes e dessa forma gerou essa confusão.

Tabela 3: Exatidão do produtor e usuário da classificação por máxima verossimilhança (02/01/2016).

<b>Classe</b>	<b>Exatidão do Produtor</b>	<b>Exatidão do Usuário</b>
Água	100.00%	99.56%
Agricultura Irrigada	57.14%	62.34%
Área Urbana	41.67%	94.34%
Solo Exposto	94.24%	88.22%
Vegetação Arbórea	91.39%	94.48%
Vegetação de Caatinga	100.00%	93.95%

Fonte: Software Spring 5.2.7.

#### 5.1.1.1.1 Estatística para os pontos coletados

Foram obtidos 50 pontos por análise visual de cada uma das classes. A exatidão global foi de 88% (Tabela 4) e o índice Kappa resultante foi de 86%, resultante da matriz de confusão (Tabela 5) a partir dos pontos amostrais coletados

na imagem. A partir das exatidões do produtor e do usuário (Tabela 6) é possível observar uma menor acurácia da classificação entre as áreas de solo exposto e área urbana, assim como as de vegetação arbórea e agricultura irrigada. Água e vegetação de caatinga demonstraram os melhores desempenhos.

Tabela 4: Estatísticas gerais da classificação para os pontos por máxima verossimilhança (02/01/2016).

Estatísticas	Valor
Exatidão Global	88%
Confusão Média	12%
Índice KAPPA (K)	86%

Fonte: O autor

Tabela 5: Matriz de Confusão da classificação por Máxima Verossimilhança obtida pelos pontos amostrais (02/01/2014).

Classes	Água	Agri. Irrigada	Área Urbana	Solo Exposto	Veg. Arbórea	Veg. Caatinga	Soma (Linha)
Água	50	1	0	0	0	0	51
Agri. Irrigada	0	36	0	0	7	0	43
Área Urbana	0	0	45	6	0	5	56
Solo Exposto	0	0	5	44	0	0	49
Veg. Arbórea	0	10	0	0	43	0	53
Veg. Caatinga	0	3	0	0	0	45	48
Soma (Coluna)	50	50	50	50	50	50	300

Fonte: O autor.

Tabela 6: Exatidão do produtor e usuário da classificação por Máxima Verossimilhança obtida pelos pontos amostrais (02/01/2014).

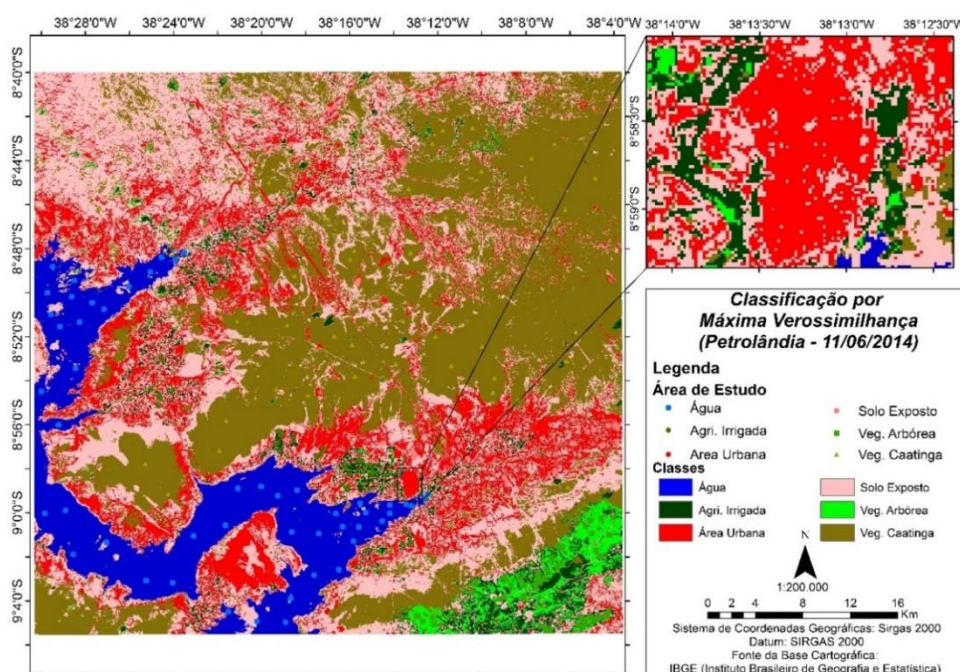
Classe	Exatidão do Produtor	Exatidão do Usuário
Água	100%	98%
Agricultura Irrigada	72%	84%
Área Urbana	90%	80%
Solo Exposto	88%	90%
Vegetação Arbórea	86%	81%
Vegetação de Caatinga	90%	94%

Fonte: O autor.

### 5.1.1.2 Imagem de 11/06/2014

Para a classificação por máxima verossimilhança para a imagem referente à data de 11/06/2014 (Figura 19), foi obtido um desempenho geral de 93.91%, estatística Kappa de 91.44% e estatística TAU de 92.69% (Tabela 7) a partir da matriz de erros (Tabela 8). Valores estes mais baixos em comparação com a imagem da data anterior, que estão relacionados à ocorrência da precipitação, pois a variação entre as classes de vegetação tendem a diminuir por conta da umidade presente.

Figura 19: Classificação por Máxima Verossimilhança (11/06/2014).



Fonte: O autor.

Tabela 7: Estatísticas gerais da classificação por máxima verossimilhança (11/06/2016).

Desempenho Geral	93.91%
Confusão Média	6.09%
Estatística KAPPA	91.44 %
Estatística TAU	92.69%

Fonte: O autor.

Desta vez, a classe de água apresentou 100% (Tabela 8) de exatidão do produtor e do usuário, e a vegetação de caatinga também demonstrou alta porcentagem de acerto na classificação com 99.36% e 99.87% de exatidão do produtor e usuário respectivamente. O solo exposto foi classificado com boa

eficiência na exatidão do produtor (97.25%), e maior confusão na exatidão do usuário (76.96%). A vegetação arbórea foi classificada com 75.0% e 92.0% respectivamente nas supracitadas exatidões, e dessa forma apresentou bom desempenho. A classe de agricultura irrigada seguiu a tendência e foi confundida com vegetação arbórea, resultando em alta discrepância entre as exatidões (85.98% e 56.79%), respectivamente. Por fim, a classe de solo urbano foi mais uma vez extrapolada e confundida com a classe de solo exposto. Dessa forma, sua exatidão do produtor foi de apenas 43.01%, porém a do usuário foi de 88.89%.

Tabela 8: Matriz de Confusão da Classificação por Máxima Verossimilhança (11/06/2016).

Classes	Água	Agri. Irrigada	Área Urbana	Solo Exposto	Veg. Arbórea	Veg. Caatinga	Soma (Linha)
Água	978	0	0	0	0	0	978
Agri. Irrigada	0	92	0	0	69	1	162
Área Urbana	0	0	40	5	0	0	45
Solo Exposto	0	0	53	177	0	0	230
Veg. Arbórea	0	14	0	0	207	4	225
Veg. Caatinga	0	1	0	0	0	773	774
Soma (Coluna)	978	107	93	182	276	778	2414

Fonte: Software Spring 5.2.7.

Tabela 9: Exatidão do produtor e usuário da classificação por máxima verossimilhança (11/06/2016).

Classe	Exatidão do Produtor	Exatidão do Usuário
Água	100%	100%
Agricultura Irrigada	85.98%	56.79%
Área Urbana	43.01%	88.89%
Solo Exposto	97.25%	76.96%
Vegetação Arbórea	75%	92%
Vegetação de Caatinga	99.36%	99.87%

Fonte: Software Spring 5.2.7.

#### 5.1.1.2.1 Estatística para os pontos coletados

A relação entre os pontos amostrais e a classificação resultou numa exatidão global de 79% e um índice Kappa de 77% (Tabela 10). Essa queda é resultado das mudanças do uso e ocupação do solo entre as imagens de datas distintas.

Tabela 10: Estatísticas gerais da classificação por máxima verossimilhança (11/06/2016).

Desempenho Geral	79 %
Confusão Média	21 %
Estatística KAPPA	77 %

Fonte: O autor.

Os pontos (Tabela 11) foram coletados na imagem de janeiro, e sua comparação com a imagem de junho denota o panorama das alterações ocorridas nos locais durante o período, além da confusão entre as classes que são similares em termos espectrais. As classes de maior confusão (Tabela 12) foram as de Agricultura irrigada e solo exposto, como confirma a matriz de confusão. É importante ressaltar que vários pontos classificados anteriormente como agricultura irrigada foram classificados como solo exposto, decorrente da presença de culturas temporárias como abóbora e melancia segundo a CODEVASF (Companhia de Desenvolvimento dos Vales do São Francisco e do Parnaíba). A confusão entre solo exposto e área urbana é resultado da semelhança espectral entre as classes, que fez o classificador agregar como área urbana, muitas áreas com ausência de vegetação referentes à solo exposto.

Tabela 11: Matriz de Confusão da Classificação por Máxima Verossimilhança obtida pelos pontos amostrais (11/06/2014)

Classes	Água	Agri. Irrigada	Área Urbana	Solo Exposto	Veg. Arbórea	Veg. Caatinga	Soma (Linha)
Água	46	0	0	0	0	0	46
Agri. Irrigada	0	28	0	0	9	0	37
Área Urbana	0	0	48	18	0	1	67
Solo Exposto	4	11	2	31	2	4	54
Veg. Arbórea	0	8	0	0	39	0	47
Veg. Caatinga	0	3	0	1	0	45	49
Soma (Coluna)	50	50	50	50	50	50	300

Fonte: O autor.



Tabela 12: Exatidão do produtor e usuário da classificação por Máxima Verossimilhança obtida pelos pontos amostrais (11/06/2014).

Classe	Exatidão do Produtor	Exatidão do Usuário
Água	92%	100%
Agricultura Irrigada	56%	76%
Área Urbana	96%	72%
Solo Exposto	62%	57%
Vegetação Arbórea	78%	83%
Vegetação de Caatinga	90%	92%

Fonte: O autor.

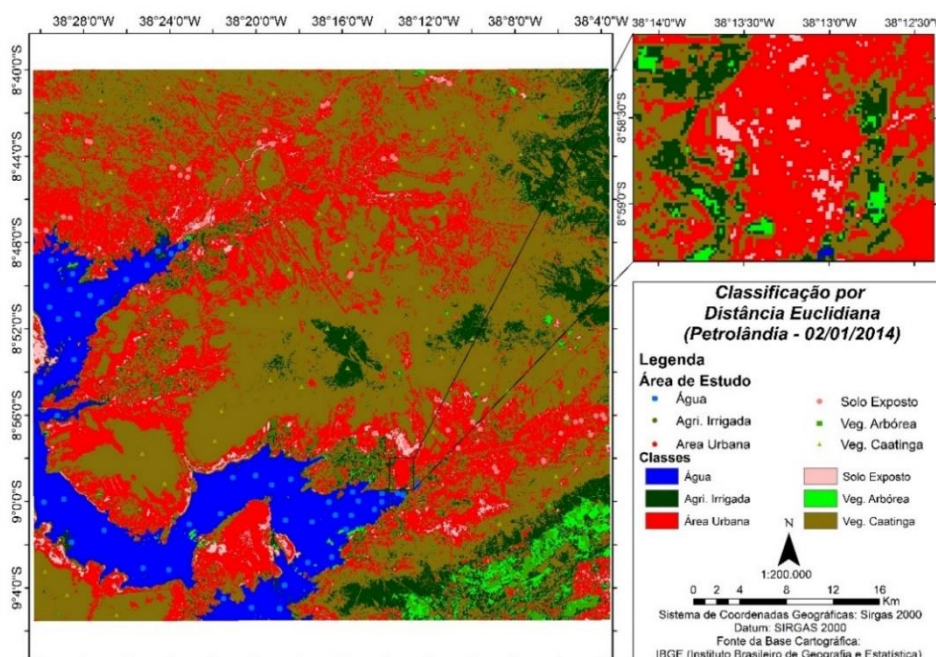
### 5.1.2 Classificação pelo método da Distância Euclidiana

Os tópicos a seguir trazem a apresentação e discussão dos dados obtidos pela classificação através do método da Distância Euclidiana para as imagens do sensor OLI nas duas datas, assim como as estatísticas obtidas através da coleta dos pontos amostrais nas diferentes classes de uso do solo.

#### 5.1.2.1 Imagem de 02/01/2014

Na classificação por distância Euclidiana (Figura 20), é comparada a distância do valor do pixel à média de cada classe de acordo com os valores obtidos através das amostras de treinamento, sendo este atribuído à classe que mais se aproxima.

Figura 20: Classificação por Distância Euclidiana (02/01/2014).



Fonte: O autor.

Esta apresentou um resultado de menor precisão ao se comparar com o gerado pela classificação por máxima verossimilhança. Com um desempenho geral de 85.71%, índice Kappa de 80.09% e um índice TAU de 82.85% (Tabela 13).

Tabela 13: Estatísticas gerais da classificação por distância euclidiana (02/01/2014).

Desempenho Geral	85.71 %
Confusão Média	14.29%
Estatística KAPPA	80.09 %
Estatística TAU	82.85%

Fonte: Software Spring 5.2.7.

No entanto a classificação derivada da matriz de confusão (Tabela14) obteve bons resultados para algumas classes, como por exemplo a de água que obteve 100% de exatidão do produtor, e 94.63 de exatidão do usuário (Tabela 15).

Tabela 14: Matriz de Confusão da Classificação por Distância Euclidiana (02/01/2014).

Classes	Água	Agri. Irrigada	Área Urbana	Solo Exposto	Veg. Arbórea	Veg. Caatinga	Soma (Linha)
Água	1371	0	0	6	0	0	1377
Agri. Irrigada	0	48	0	0	29	0	77
Área Urbana	0	0	50	3	0	0	53
Solo Exposto	0	0	35	262	0	0	297
Veg. Arbórea	0	18	0	0	308	0	326
Veg. Caatinga	0	18	35	7	0	931	991
Soma (Coluna)	0	84	120	278	337	0	3121

Fonte: Software Spring 5.2.7.

Tabela 15: Exatidão do produtor e usuário da classificação por distância euclidiana (02/01/2014).

Classe	Exatidão do Produtor	Exatidão do Usuário
Água	100%	94.63%
Agricultura Irrigada	12.93%	58.44%
Área Urbana	33.55%	98.11%
Solo Exposto	99.58%	79.46%
Vegetação Arbórea	90.52%	90.80%
Vegetação de Caatinga	98.93%	74.97%

Fonte: Software Spring 5.2.7.

A classe de solo exposto mostrou conformidade de 99.58% nos pixels que ao serem classificados como solo exposto no processo de aquisição de amostras realmente foram classificados como solo exposto. No entanto, sua exatidão do usuário foi de 79.46%, em função da confusão desta classe com a de área urbana.

A área urbana mais uma vez foi superestimada e gerou um resultado razoável segundo a escala de Landis e Koch (1977) na exatidão do produtor com apenas 33.55%. Apesar do treinamento ter ocorrido todo concentrado no perímetro urbano do município de Petrolândia, muitas áreas de solo exposto apresentam comportamento espectral semelhante ao da área urbana. Sendo o solo urbano afetado pela não uniformidade das respostas espectrais decorrentes da mistura de pixels pelo vários componentes do dossel urbano, essa classe foi extrapolada para muitas áreas de solo exposto, que apresentam algum resquício de vegetação que possa interferir nos valores de reflectância do pixel. Por causa dessa confusão, a classificação gerou uma exatidão do usuário de 98.11%.

A classe de vegetação arbórea expressou um bom resultado tanto na exatidão do produtor (90.52%), quanto na do usuário (90.80%). Esta classe apresentou uma leve confusão com a classe de agricultura irrigada.

A agricultura irrigada por sua vez, apresentou uma exatidão do produtor de apenas 12.93%, valor mais baixo entre todas as classes. A maior parte dos pixels coletados como sendo pertencentes a essa classe foram agrupados na classe de vegetação arbórea, por essa última além das similaridades, apresentar maior representatividade. A exatidão do usuário foi de 58.44%. O classificador agregou várias áreas pertencentes à vegetação arbórea, nos locais de maior declividade. A vegetação de caatinga obteve excelente exatidão do produtor com 98.93%. Porém, a exatidão do usuário foi de 74.97%. Algumas áreas dessa categoria foram atribuídas à classe de agricultura irrigada. Isso ocorreu em áreas de caatinga mais conservadas e em regiões de maior altitude, o que torna a média das reflectâncias dos pixels semelhantes à cultivos controlados.

#### *5.1.2.1.1 Estatística para os pontos coletados*

A matriz de confusão resultante dos pontos amostrais gerou uma exatidão global de 80% e o índice Kappa foi de 78% (Tabela 16) referente à distribuição das amostras que podem ser observadas pela matriz de confusão (Tabela 17).

---

Tabela 16: Estatísticas gerais da classificação por Distância Euclidiana obtida pelos pontos amostrais (02/01/2014).

Desempenho Geral	80 %
Confusão Média	20%
Estatística KAPPA	78 %

Fonte: O autor.

Tabela 17: Matriz de Confusão da classificação por Distância Euclidiana obtida pelos pontos amostrais (02/01/2014).

Classes	Água	Agri. Irrigada	Área Urbana	Solo Exposto	Veg. Arbórea	Veg. Caatinga	Soma (Linha)
Água	47	0	0	0	0	0	46
Agri. Irrigada	1	30	0	0	6	7	37
Área Urbana	2	0	48	17	0	4	67
Solo Exposto	0	0	2	33	0	0	54
Veg. Arbórea	0	13	0	0	44	0	47
Veg. Caatinga	0	7	0	0	0	39	49
Soma (Coluna)	50	50	50	50	50	50	300

Fonte: O autor.

As classes de água e área urbana apresentaram exatidões acima dos 90% (Tabela 18). A classe de água tem destaque por obter uma acurácia do usuário de 100%. As classes que foram notadas mais confusão foram as de agricultura irrigada com vegetação arbórea e solo exposto com área urbana.

Tabela 18: Exatidão do produtor e usuário da classificação por Distância Euclidiana obtida pelos pontos amostrais (02/01/2014).

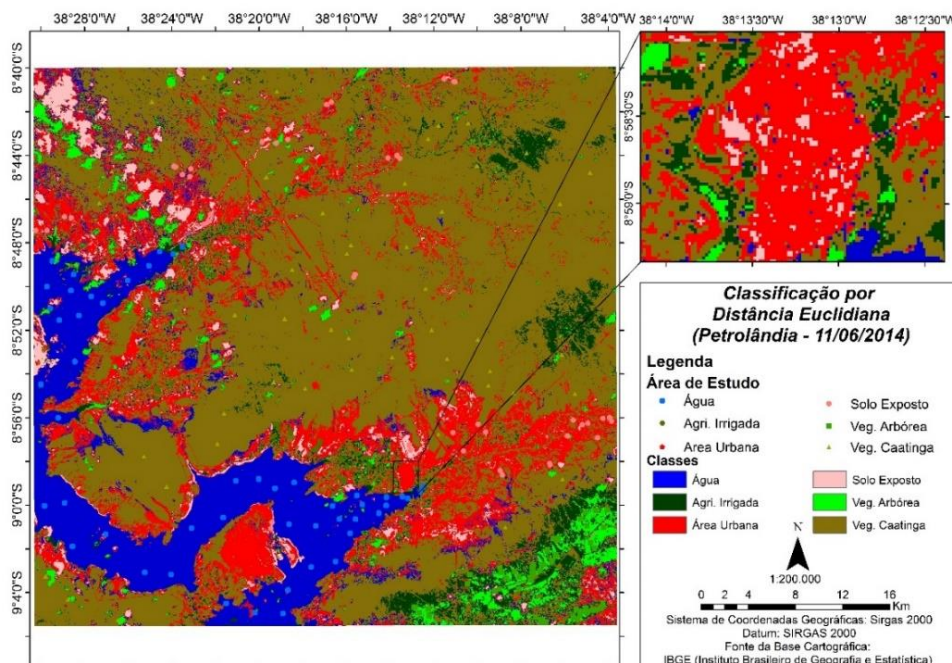
Classe	Exatidão do Produtor	Exatidão do Usuário
Água	94%	100%
Agricultura Irrigada	60%	68%
Área Urbana	96%	68%
Solo Exposto	66%	94%
Vegetação Arbórea	88%	77%
Vegetação de Caatinga	78%	85%

Fonte: O autor.

### 5.1.2.2 Imagem de 11/06/2014

A carta-imagem resultante da classificação por Distância Euclidiana para a data de 11/06/2014 (Figura 21) apontou para uma grande predominância da vegetação de caatinga na região, e expressou mais uma vez uma grande extrapolação da classe de área urbana.

Figura 21: Classificação por Distância Euclidiana (11/06/2014).



Fonte: O autor.

A estatística da classificação afirma a obtenção de um desempenho geral de 81.48%, estatística Kappa de 74.97%, e estatística TAU de 77.78% (Tabela 19). Sendo estes os menores valores entre todas as classificações.

Tabela 19: Estatísticas gerais da classificação por Distância Euclidiana (11/06/2014).

Desempenho Geral	81.48 %
Confusão Média	18.52 %
Estatística KAPPA	74.97 %
Estatística TAU	77.78%

Fonte: Software Spring 5.2.7.

Mais uma vez, na matriz de confusão (Tabela 20), por sua representatividade, a classe de água apresentou os maiores valores percentuais de acerto na classificação com 99.77% e 86.91% de exatidão do produtor e do usuário

respectivamente (Tabela 21). Este foi o desempenho mais baixo para esta classe, em que algumas áreas de vegetação de caatinga e vegetação arbórea foram classificadas como sendo água.

Tabela 20: Matriz de Confusão da Classificação por Distância Euclidiana (11/06/2014).

Classes	Água	Agri. Irrigada	Área Urbana	Solo Exposto	Veg. Arbórea	Veg. Caatinga	Soma (Linha)
Água	850	118	0	0	10	0	978
Agri. Irrigada	1	79	0	0	71	11	162
Área Urbana	1	0	37	6	0	1	45
Solo Exposto	0	0	102	128	0	0	239
Veg. Arbórea	0	25	0	0	200	0	225
Veg. Caatinga	0	101	0	0	0	673	774
Soma (Coluna)	852	323	139	134	281	685	2414

Fonte: Software Spring 5.2.7.

Tabela 21: Exatidão do produtor e usuário classificação por Distância Euclidiana (11/06/2014).

Classe	Exatidão do Produtor	Exatidão do Usuário
Água	99.77%	86.91%
Agricultura Irrigada	24.46%	48.77%
Área Urbana	26.62%	82.22%
Solo Exposto	95.52%	55.65%
Vegetação Arbórea	71.17%	88.89%
Vegetação de Caatinga	98.25%	86.95%

Fonte: Software Spring 5.2.7.

A classe de vegetação de caatinga foi classificada e, 98.25% de precisão segundo a exatidão do produtor, e obteve 86.95% de exatidão do usuário e a maior confusão desta classe se deu com áreas de agricultura irrigada.

A vegetação arbórea por sua vez, obteve 71.17% e 88.89% das respectivas exatidões, e foi confundida predominantemente com áreas de agricultura irrigada. Nesta classe foram atribuídas algumas áreas referentes à sombras das nuvens, resultado da cor escura que a área apresentava no momento da tomada da imagem.

O solo exposto mostrou concordância de 95.52% das amostras na exatidão do produtor e apenas 55.65% de exatidão do usuário. Na classe solo exposto, houve grande confusão com a área urbana, sendo esta última atribuída à porções do

terreno com ausência de vegetação, e/ou com importante presença de solos rochosos. Por serem as áreas com de presença de areais majoritariamente muito claras, as nuvens foram em sua maior parte confundidas com solos arenosos e foram enquadradas na categoria de solo exposto.

A classe de área urbana mais uma vez foi confundida com o solo exposto, sendo atribuída em diversas áreas onde sua presença é inexistente devido à sua resposta espectral semelhante. A exatidão do produtor foi de 26.62% e a do usuário de 82.22%.

A classe com menores valores de desempenho de classificação foi a de agricultura irrigada. Suas exatidões foram de 24.46% e 48.77% respectivamente. Esta classe apresentou confusão com as classes de água, de vegetação de caatinga e com vegetação arbórea. Contribui para esse resultado, a ocorrência do período chuvoso na região ocorrer nos meses antecedentes à tomada da imagem, aumentando o porte sobretudo da vegetação de caatinga, fazendo com que sua resposta espectral se assemelhe a ponto de gerar confusão para o classificador, que o engloba à realidade da região onde o pixel está inserido.

#### 5.1.2.2.1 Estatística para os pontos coletados

Para esta classificação, a exatidão global obtida foi de 73% e o índice Kappa de 70% (Tabela 22), resultado da matriz de confusão (Tabela 23). Segundo a tabela de Landis e Koch (1977), estaria enquadrada na categoria (Muito Boa). A menor eficiência com relação às anteriores (Tabela 24), neste caso, se explica pelas mudanças no uso do solo assim como foi no classificação por Máxima Verossimilhança. As classes que mais contribuíram para que o desempenho geral fosse menor que as anteriores foram o solo exposto e a agricultura irrigada, resultado da oscilação de porte de áreas vegetadas e da temporariedade de algumas culturas.

Tabela 22: Estatísticas gerais da classificação por Distância Euclidiana obtida pelos pontos amostrais (11/06/2014).

Estatísticas	Valor
Desempenho Geral	73%
Confusão Média	27%
Índice KAPPA (K)	70%

Fonte: O autor.

Tabela 23: Matriz de Confusão da Classificação por Distância Euclidiana obtida pelos pontos amostrais (11/06/2014).

Classes	Água	Agri. Irrigada	Área Urbana	Solo Exposto	Veg. Arbórea	Veg. Caatinga	Soma (Linha)
Água	44	1	0	0	0	0	45
Agri. Irrigada	3	27	0	1	14	4	49
Área Urbana	0	0	45	22	0	1	68
Solo Exposto	1	2	5	25	1	1	35
Veg. Arbórea	1	4	0	0	33	0	38
Veg. Caatinga	1	16	0	2	2	44	65
Soma (Coluna)	50	50	50	50	50	50	300

Fonte: O autor.

Tabela 24: Exatidão do produtor e usuário da classificação por Distância Euclidiana (11/06/2014).

Classe	Exatidão do Produtor	Exatidão do Usuário
Água	88%	98%
Agricultura Irrigada	54%	55%
Área Urbana	90%	66%
Solo Exposto	50%	71%
Vegetação Arbórea	66%	87%
Vegetação de Caatinga	88%	64%

Fonte: O autor.

## 5.2. ÍNDICES FÍSICOS

Neste tópico serão apresentados e discutidos os resultados obtidos a partir do processamento de imagens a partir da metodologia indicada pelo algoritmo SEBAL.

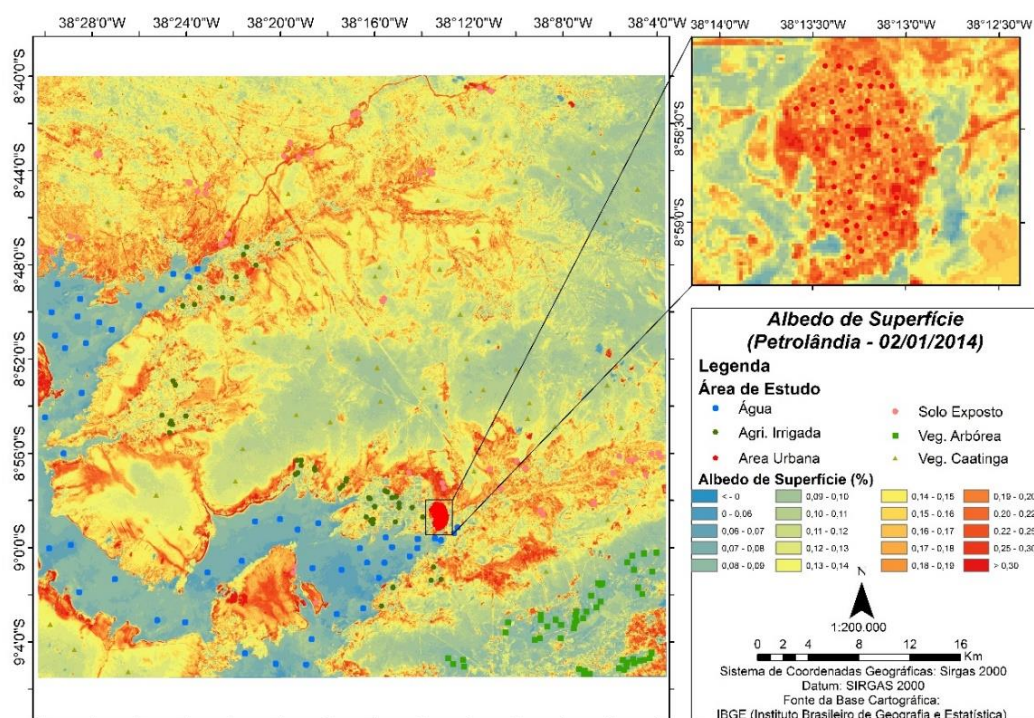
### 5.2.1 Albedo de Superfície ( $\alpha$ )

#### 5.2.1.1 Imagem de 02/01/2014

A carta-imagem do albedo de superfície (Figura 22) demonstrou variações consideráveis entre as classes destacadas.



Figura 22: Carta-imagem do Albedo de Superfície (02/01/2014).




Fonte: O autor.

Os valores mais altos se relacionam com a presença de bancos de areia em leitos secos dos riachos, solo exposto e na área urbana. Essas classes apresentaram valores geralmente acima de 25% de albedo. Em Matos et al (2016) foram obtidos valores de albedo na área urbana de Petrolândia variando entre 20 e 40%. A presença de nuvens nas porções leste e sul da imagem ocasionou um pico de albedo acima de 50%, e imediatamente ao seu lado, foi notado pixels com baixos valores ( $\alpha$  entre 7 e 8%), característicos de área com baixa intensidade de radiação solar nas áreas sombreadas pelas nuvens, justamente por essas refletirem a maior parte da radiação. Este comportamento corrobora os valores encontrados por Oliveira (2012), que encontrou valores de albedo de cerca de 7% em áreas sombreadas. A água expôs valores entre 6 e 8% nas áreas de menor turbidez, e onde a presença de material particulado foi mais notada visualmente esses valores variaram entre 9 e 11%, e esses valores mais baixos são resultado da alta absorção de energia pelos corpos hídricos. A agricultura irrigada e a vegetação arbórea também apresentaram baixos valores de albedo, variando entre 7 e 13%, justificados pela presença de umidade decorrente da irrigação e/ou altitude da área. Esses valores são semelhantes aos encontrados por Matos et al (2015) para a

mesma região, onde para um ponto de controle localizado na área do cultivo irrigado, foi observado albedo de cerca de 17%, numa imagem do ano de 2010. A vegetação de caatinga é a classe que mais apresenta variação, pois esta variou entre 12 e 20% de albedo. A influência do solo, em maior ou menor magnitude, assim como o maior espaçamento da vegetação em áreas mais acidentadas como na porção norte da região, ajudam a explicar essa discrepância entre os valores para a classe.

O gráfico 2 exibe os valores do albedo de superfície para os pontos amostrais. Assim como no índice anterior, há semelhanças nas classes de agricultura irrigada e vegetação arbórea. No entanto, as classes referentes à área urbana e ao solo exposto apresentaram uma ligeira distinção, já que o albedo da área urbana indicam valores próximos à 20%, e os pixels de solo exposto variaram aproximadamente entre 25% e 30%. Em um dos pontos da área urbana, a presença de nuvens o elevou causando o ponto de maior discrepância no gráfico.

Gráfico 2: Variação do Albedo de Superfície entre as classes (02/01/2014).

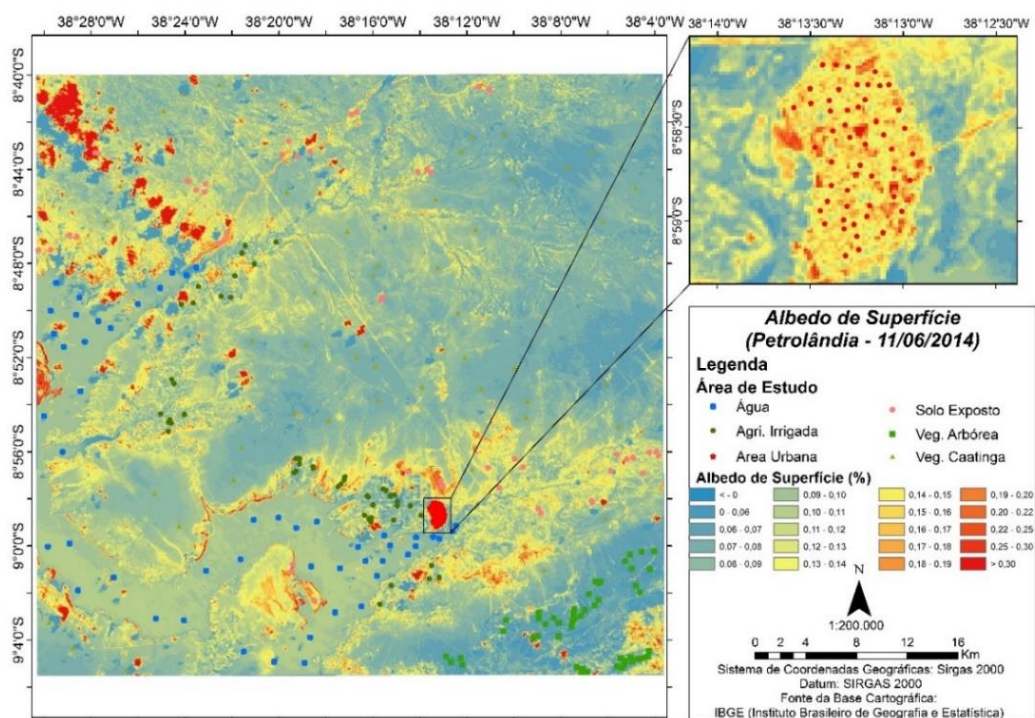


Fonte: O autor.

#### 5.2.1.2 Imagem de 11/06/2014

O geral aumento no porte físico da vegetação ocorrido após os meses mais úmidos que precederam a data da imagem, assim como a maior presença de umidade em decorrência do evento chuvoso no dia da passagem do sensor, ocasionou uma queda considerável no albedo verificado no período (Figura 23).

Figura 23: Carta-imagem do Albedo de Superfície (11/06/2014)



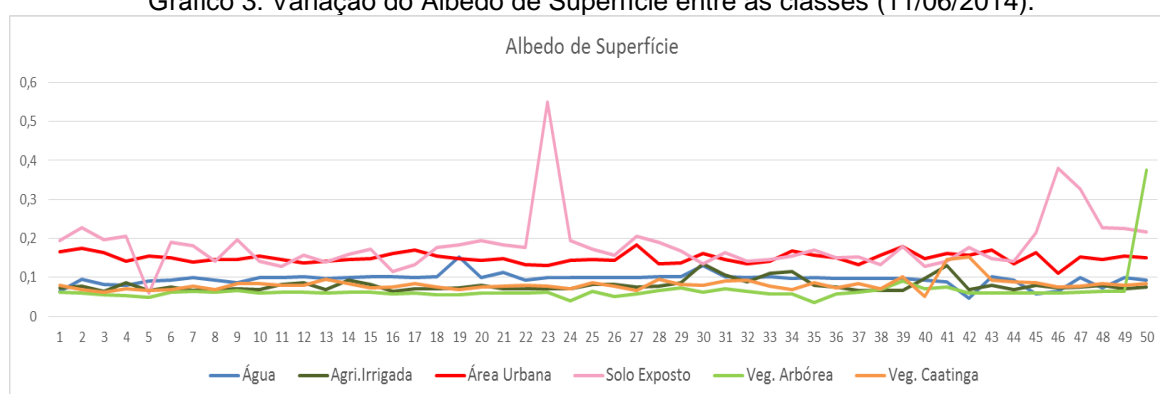
Fonte: O autor.

Os maiores valores foram obtidos nas nuvens, com mais de 30% de albedo. Em contrapartida, nas áreas adjacentes, referentes à área sombreada os valores se aproximam dos 6%. A maior parte da imagem apresentou valores entre 7 e 15%, dependendo da presença ou não e densidade da vegetação. Regiões onde a vegetação se encontrava mais exuberante, externaram valores de albedo entre 7 e 9%, inclusive, na maioria dos casos, estes valores foram menores que os notados no rio. Este por sinal, apresentou valores em torno dos 10%. Atribui-se isso à turbidez da água, e à luminosidade no dia da captação da imagem. As áreas referentes ao solo urbano e exposto variaram entre 13 e 25% de albedo, sendo os maiores destas duas classes encontradas nas bordas do espelho d'água, predominantemente ocupados por bancos de areia.

O gráfico 3, obtido através dos pontos amostrais aponta para uma grande variação do albedo na região. Os pontos referentes às classes de água, vegetação arbórea, vegetação de caatinga e agricultura irrigada se mostraram muito semelhantes de forma geral, variando entre os valores de 6 a 12% de albedo. Valores muito próximos aos encontrados por Ruhoff (2015) para áreas de floresta

ombrófila densa em áreas escarpadas que variaram entre 10 e 11%. As classes de solo exposto e área urbana apresentaram valores entre 18 e 22%, havendo nos pontos de solo exposto alguns pixels com grande variação, porém, resultante da presença de nuvens, o que justifica os pontos mais discrepantes no gráfico. Cerqueira (2012) observou valores de albedo entre 18 e 28% para áreas de solo urbano. Esse comportamento permite afirmar que em épocas mais úmidas, o albedo não apresenta um bom desempenho para a análise da interface água/solo, por seus valores se assemelharem.

Gráfico 3: Variação do Albedo de Superfície entre as classes (11/06/2014).



Fonte: O autor.

## 5.2.2 NDVI

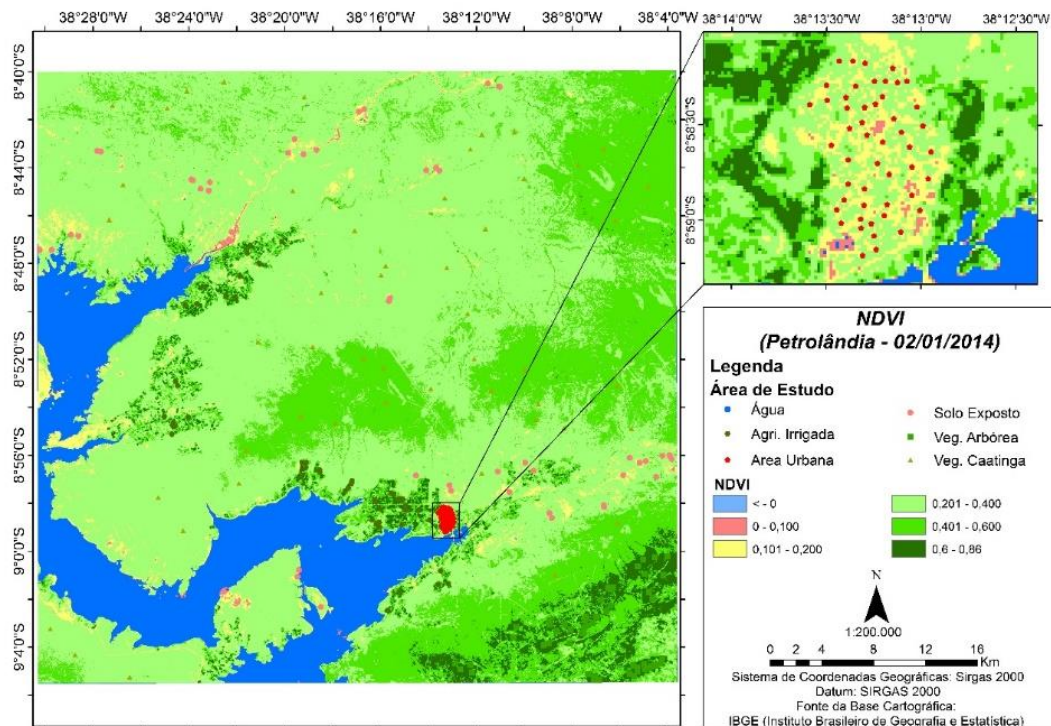
### 5.2.2.1 Imagem de 02/01/2014

A imagem resultante do NDVI (Figura 24) para a região apresenta mais coerência com as classificações ao determinar os valores negativos para o espelho d'água da represa, e ao estimar as áreas de maior biomassa e vigor para as áreas onde foi detectada a presença de cultivos irrigados e/ou vegetação arbórea nas áreas de cotas altimétricas mais elevadas na porção sudeste da imagem.

Essas duas classes de vegetação, apresentaram no geral, valores de NDVI acima de 0,600. Matos et al (2015) obteve valores de 0,632 de NDVI para a área de cultivo irrigado próxima ao reservatório de Itaparica. Cunha et al (2012) observou a influência do aumento da elevação, como fator influente para o desenvolvimento da vegetação. Algumas áreas referentes à vegetação de caatinga apresentaram valores entre 0,401 a 0,600, como reflexo da influência da precipitação na época, que apesar de ter apresentado valores significativos, foram antecidos de meses muito secos, ocasionando nessas plantas de maior porte uma resposta mais demorada ao

evento chuvoso. Silva e Galvínio (2012) observaram valores de NDVI próximos à 0,400 em uma área de caatinga preservada no município de Petrolina-PE.

Figura 24: Carta-imagem do NDVI (02/01/2014).




Fonte: O autor.

Os pontos marcados como solo exposto apresentaram valores entre 0,101 e 0,200, às vezes obtendo valores a baixo disso em áreas da borda do espelho d'água, resultado de bancos de areia criados pela diminuição do nível do reservatório.

A área urbana em decorrência da mistura de pixels variou entre 0,150 e 0,300. A presença de diferentes materiais influentes no dossel urbano, além da não regularidade da ocupação, e distribuição não uniforme de áreas verdes é responsável para variação do índice nesta porção do território.

O gráfico 4 demonstra de forma mais clara a variação do NDVI em cada uma das classes. Pode-se perceber com o índice a semelhança entre as classes de agricultura irrigada e vegetação arbórea, assim como nas classificações supervisionadas. Assim como as classes de área urbana e solo exposto apresentaram valores parecidos. É importante observar que um ponto de agricultura irrigada e um de vegetação arbórea foram afetados pela presença de nuvens.

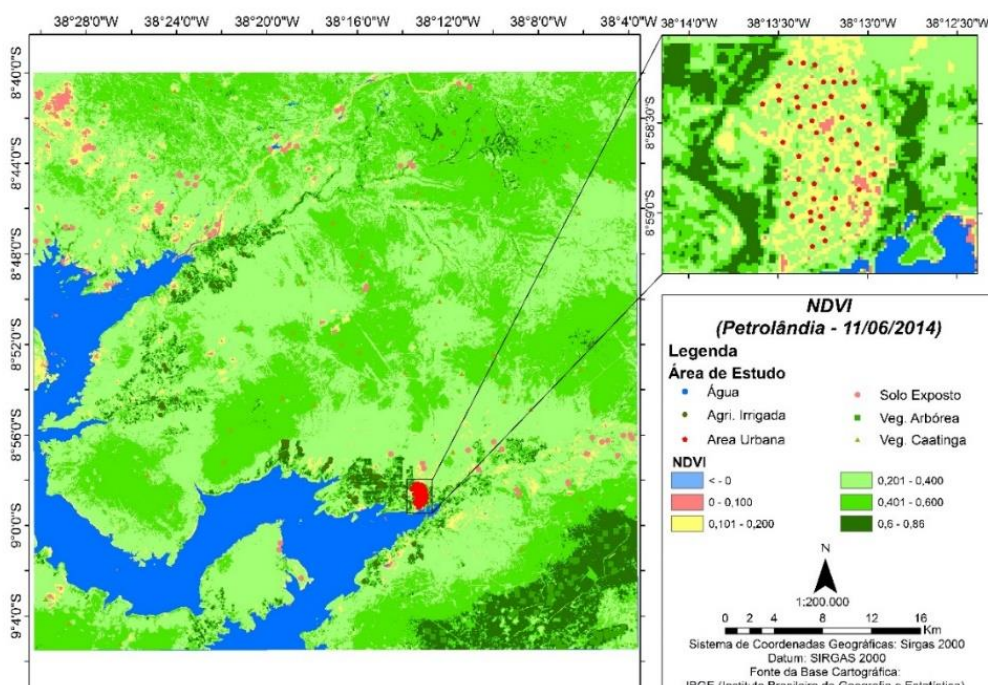
Gráfico 4: Variação do NDVI entre as classes (02/01/2014).



### 5.2.2.2 Imagem de 11/06/2014

O NDVI estimado para a data de 11/06/2014 (Figura 25) em termos gerais foi maior que a imagem da data anterior, decorrente do evento chuvoso e dos meses de abril e maio com precipitação de aproximadamente 90mm, e seus impactos na variabilidade sobretudo na vegetação de caatinga.

Figura 25: Carta-imagem do NDVI (11/06/2014).



Fonte: O autor.

Essa classe apresentou vastas áreas com valores acima de 0,400, localizadas nas porções centrais, norte e sudoeste da imagem. Esses valores são típicos de


áreas com presença de vegetação arbustiva e arbórea baixa, com conteúdo hídrico considerável.

Em relação à imagem anterior, as áreas com valores entre 0,100 e 0,200, característicos de solo exposto e/ou solo urbano foram menos representativas, exceto nas bordas das nuvens. Nas partes mais centrais das nuvens, geralmente mais espessas, os valores se encontram entre 0 e 0,100, características espectrais de áreas com ausência total de material fotossintetizante. Valores semelhantes à esses foram encontrados na área da captação da água do Rio São Francisco referente à transposição para o município de Floresta, e em alguns pontos do centro urbano do município de Petrolândia.

Nesta imagem, a presença de áreas com NDVI acima de 0,600 foi mais frequente, sobretudo onde há a predominância de vegetação arbórea mais densa à sudeste da região, e onde as altitudes são maiores. Como o porte geral da vegetação se mostrou superior, em menos porções do território foram notados valores entre 0,201 à 0,400. E seguindo a tendência, a maioria dos pixels referentes ao rio apresentaram valores negativos, exceto onde a presença de nuvens causou interferência.

O gráfico 5 corrobora com a tendência apresentada na imagem anterior, apresentando leve aumento nos valores médios da maioria das classes. A vegetação arbórea e a agricultura irrigada apresentaram algumas discrepâncias, porém no geral foram similares. Alguns pontos de grande variabilidade são resultado de interferência causada pela presença de nuvens. A vegetação de caatinga permaneceu com valores entre 0,400 e 0,600. Os pontos obtidos em áreas de solo urbano e exposto oscilaram em valores próximos à 0,200. E os pixels observados no rio permaneceram com valores negativos.

Gráfico 5: Variação do NDVI entre as classes (11/06/2014).



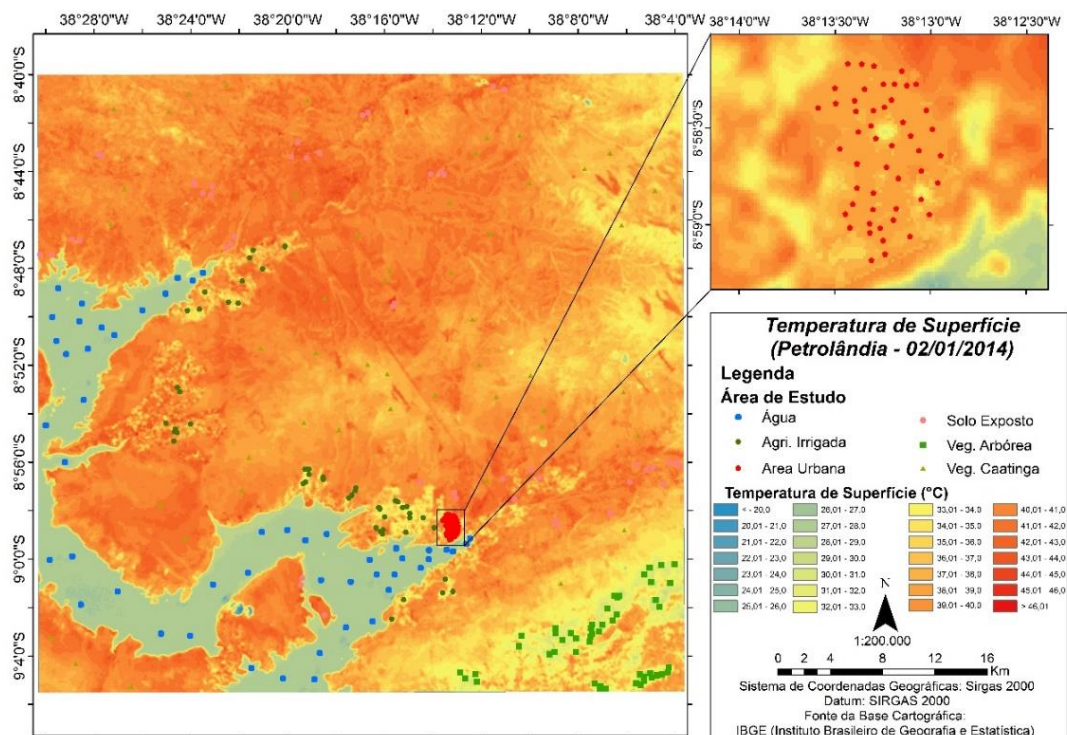
Fonte: O autor.

## 5.2.3 Temperatura de Superfície

### 5.2.3.1 Imagem de 02/01/2014

A temperatura de superfície (Figura 26) é um parâmetro que apresenta discrepâncias mais sensíveis entre as classes de uso de solo, no entanto, mostra um contraste forte entre as classes de solo e os corpos hídricos.

Figura 26: Carta-imagem da Temperatura de Superfície (02/01/2014).



Fonte: O autor.

Na água, foram observados valores médios em torno de 27°C. A classe que apresentou valores mais próximos à esses foi a vegetação arbórea, com temperaturas mínimas pouco abaixo dos 30°C em alguns locais, mas num geral seus valores aproximam-se dos 32°C. Essa relativa baixa temperatura, é também influenciada pela altitude do local.

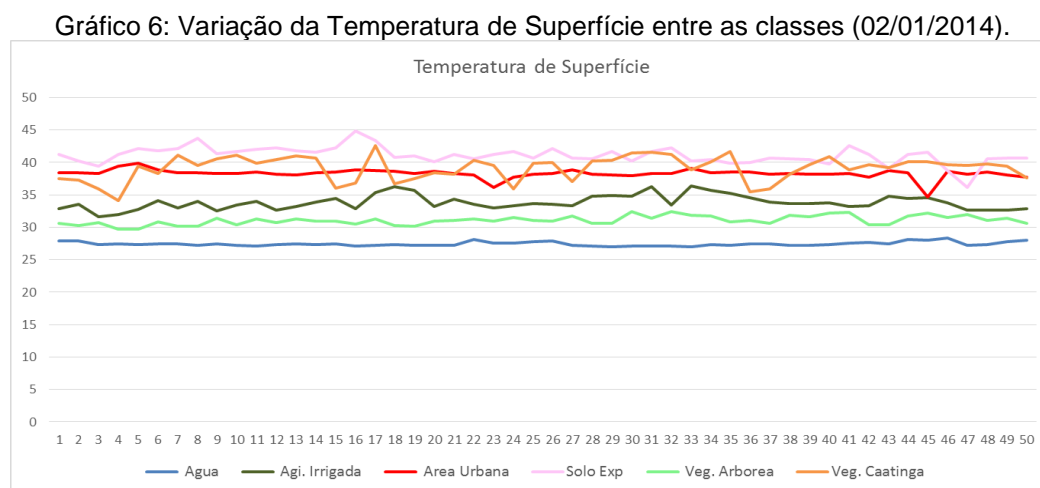
A vegetação irrigada variou entre 32°C e 35°C, dependendo do quão ocupada está a parcela de terreno com cultivo.

Na área referente ao núcleo urbano, foram obtidas temperaturas variantes entre 37°C e 38°C. Onde a classe predominante era o solo exposto, foram encontrados valores acima dos 40°C, podendo chegar a 45°. Essas temperaturas elevadas correspondem à áreas secas, com predominância de bancos de areia e



pouco ou nenhum conteúdo orgânico que possa amenizar esses valores. Porém, a maior parte dessa classe apresenta valores em torno dos 42°C.

O gráfico 6 denota que a temperatura é o indicador que menos varia dentro de cada classe. Ainda assim o padrão que cada uma delas expressa, deixa clara a tendência de que cada uma das classes se mantêm em um determinado intervalo que pode caracterizá-lo.



Fonte: O autor.

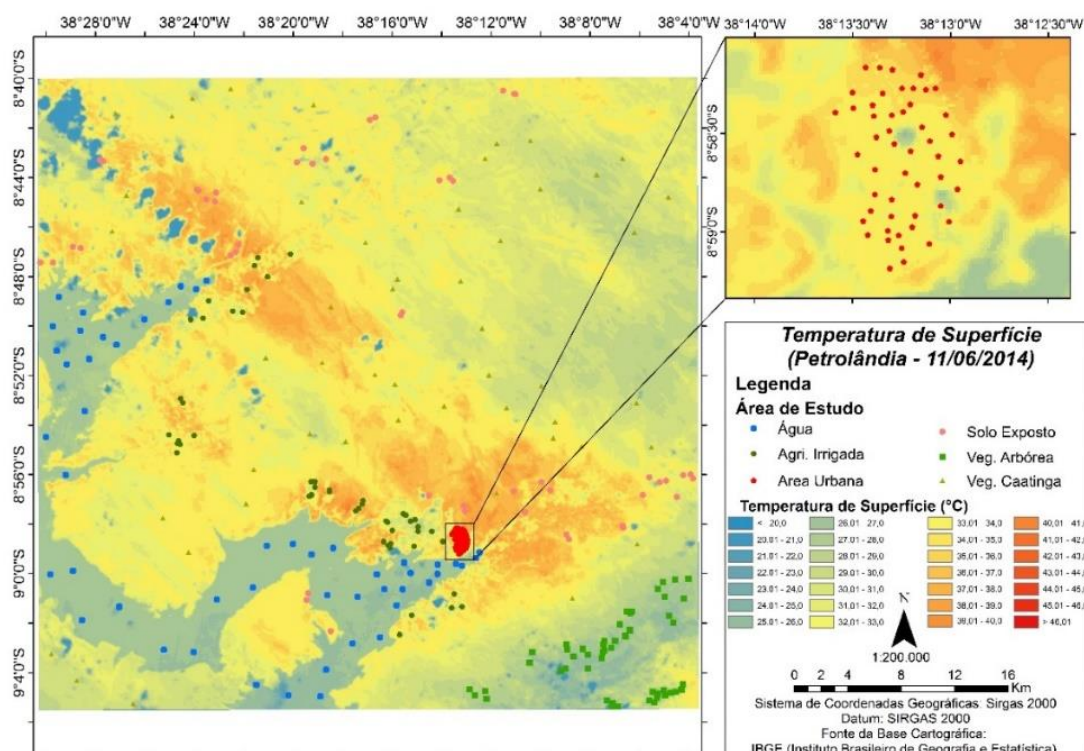
### 5.2.3.2 Imagem de 11/06/2016

A carta-imagem de temperatura de superfície referente à data 11/06/2014 (Figura 27), demonstrou uma queda de temperatura acentuada na região. Como afirmado anteriormente, o evento chuvoso no dia da passagem do sensor influencia fortemente o perfil térmico das classes de solo, e reduz as discrepâncias de temperatura entre os tipos de vegetação. Por certo, a queda de temperatura ocorreu de forma geral na imagem, porém em escalas diferentes nas variadas feições.

A vegetação de caatinga, predominante na imagem apresentou os maiores decréscimos em relação à imagem da data anterior. Nesta classe, a variação de temperatura foi próxima a 7°C, onde seus valores para junho variavam próximos aos 30°C.

Na área de solo urbano foram notados valores próximos à 35°C e em solo exposto, valores entre 35 e 40°C. O espelho d'água da represa de Itaparica variou em menor escala devido à maior inércia térmica do meio aquático, apresentando temperatura próxima aos 25°C.

Figura 27: Carta-imagem da Temperatura de Superfície (11/06/2014).




Fonte: O autor.

A classe de agricultura irrigada se mostrou semelhante à vegetação de caatinga de maior biomassa, onde sua temperatura se aproximou dos 30°C.

As áreas de vegetação arbórea localizadas nas áreas de maior altitude de destacaram por apresentar em alguns casos, pontos com temperaturas menores que os encontrados na represa. Os valores dessas áreas variaram entre 24 e 28°C. Este resultado denota o impacto da altimetria na temperatura superficial.

O gráfico 7 aponta para a proximidade da temperatura entre os pontos amostrais na imagem. Desta vez as diferentes classes não apresentaram delimitações tão claras quanto na imagem de janeiro. É possível notar dois pontos discrepantes no gráfico, resultado da ocorrência de nuvens. Os pontos referentes às classes de água e vegetação arbórea se destacaram pelas baixas temperaturas de superfície, enquanto as classes de solo exposto e área urbana tenderam à valores mais elevados dentre as classes analisadas. A vegetação de caatinga e a agricultura irrigada, sendo que esta última sofreu influência da periodicidade de algumas culturas, tenderam à valores médios em relação à área no geral.

Gráfico 7: Variação da Temperatura de Superfície entre as classes (11/06/2014).

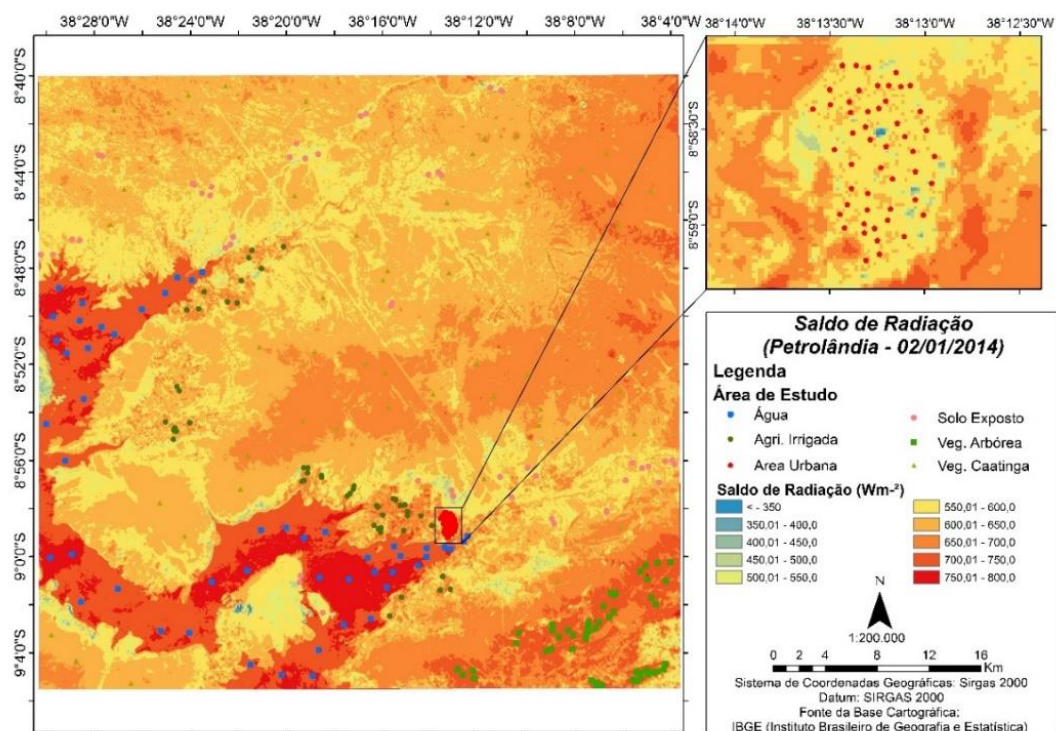


## 5.2.4 Saldo de Radiação (Rn)

### 5.2.4.1 Imagem de 02/01/2014

O saldo de radiação (Figura 28) é influenciado pela presença de umidade nas classes. Por isso, as classes que apresentam maiores valores de troca de massa com a atmosfera são as que possuem maiores conteúdos hídricos, pois estas fornecem mais energia para os processos de evapotranspiração, aquecimento do ar e do solo, assim como a fotossíntese (Oliveira. 2012).

Figura 28: Carta-imagem do Saldo de Radiação (02/01/2014).



No reservatório foram notados valores entre  $730 \text{ W m}^{-2}$  a  $760 \text{ W m}^{-2}$ . Estes valores são condizentes com os encontrados para o lago de Sobradinho por (Andrade, 2008) onde foi constatado que o saldo de radiação foi da proporção de  $751,3 \text{ W m}^{-2}$  e  $750,7 \text{ W m}^{-2}$  em imagens do sensor Landsat 5 para os anos de 2000 e 2001.


A classe de que apresentou valores próximos à anterior foi a vegetação arbórea, onde seus valores variaram no intervalo comportado entre  $710 \text{ W m}^{-2}$  e  $730 \text{ W m}^{-2}$ . Lopes (2014) obteve valores de  $728 \text{ W m}^{-2}$  em áreas de caatinga arbórea florestada também nas proximidades do reservatório de Itaparica. Seguida pela agricultura irrigada apresentou variação entre  $650 \text{ W m}^{-2}$  e  $720 \text{ W m}^{-2}$ . Essas duas classes de vegetação que apresentaram valores de saldo de radiação elevados, contribuem para o balanço de energia de forma acentuada, devido sua alta evapotranspiração.

A vegetação de caatinga é a classe em que há maior variação, num intervalo compreendido entre  $600 \text{ W m}^{-2}$  e  $690 \text{ W m}^{-2}$ . Também resultado da distinção tanto de porte quando de contexto espacial em que esta se insere. Silva (2005), observou que a vegetação de caatinga teve valores médios de  $621 \text{ W m}^{-2}$ , sendo um resultado semelhante ao encontrado nesse estudo. Área urbana e solo exposto expuseram os menores valores, porém, a área urbana apresentou constantemente valores superiores aos do solo exposto. A primeira variou entre  $550 \text{ W m}^{-2}$  e  $600 \text{ W m}^{-2}$ , sendo que a segunda dificilmente ultrapassou o valor de  $500 \text{ W m}^{-2}$ . Essa medida baixa do saldo ocorre em áreas que apresentam valores altos de albedo, e vice-versa, como constatou Filgueiras (2015).

O gráfico 8 aponta para a padronização que foi observada no gráfico referente à temperatura de superfície. Sendo o comportamento do saldo de radiação inversamente proporcional à temperatura, as classes de área urbana e solo exposto, assim como as classes de agricultura irrigada e vegetação arbórea expressam comportamento padronizados que permite a distinção dessas classes para fins de análise de classificação de imagens.

---

Gráfico 8: Variação do Saldo de Radiação entre as classes (02/01/2014).

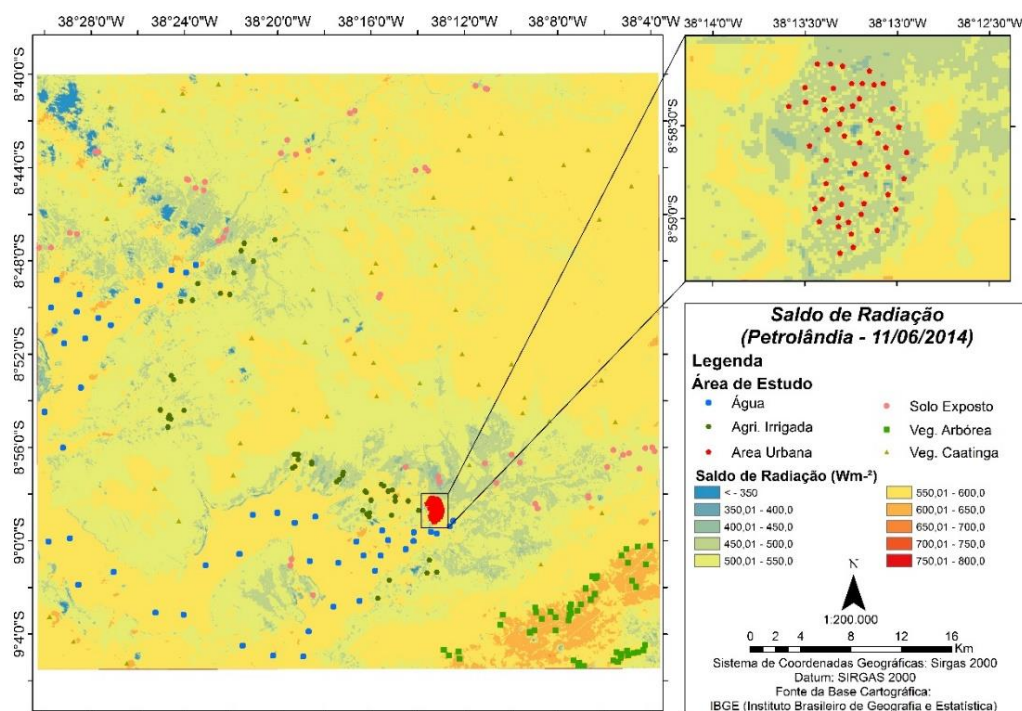


Fonte: O autor.

#### 5.2.4.2 Imagem de 11/06/2014

Assim como observado nos índices anteriores, a diferenciação dos diferentes alvos na imagem para o mês de junho se torna difícil devido à espacialização da umidade e temperatura. O saldo de radiação (Figura 29) apresentou comportamento incomum pois a classe onde geralmente se encontram os maiores valores são os corpos hídricos. Neste caso, a vegetação localizada nas áreas mais altas se destacaram com valores altos de saldo de radiação.

Figura 29: Carta-imagem do Saldo de Radiação (11/06/2014).




Fonte: O autor.

Em praticamente toda área onde predominava essa classe de vegetação, foi observado um saldo acima de  $600 \text{ W m}^{-2}$ . Mesmo com a maior umidade presente na vegetação, as temperaturas mais amenas influenciam na diminuição das trocas de massa entre os alvos terrestres e a atmosfera. O espelho d'água da represa de Itaparica demonstrou valores pouco abaixo à  $600 \text{ W m}^{-2}$ .

As áreas de cultivo irrigado e vegetação de caatinga revigorada pelo período chuvoso oscilaram seus valores no intervalo compreendido entre  $550$  e  $600 \text{ W m}^{-2}$ . As áreas com presença de solo exposto e urbano apresentaram os menores valores de saldo. Ambas as classes oscilaram no intervalo de  $400$  a  $500 \text{ W m}^{-2}$ , sendo relacionado ao solo exposto os valores absolutos mais baixos. A proximidade dos valores de saldo obtidos nas condições de pós período chuvoso, se torna praticamente impraticável a distinção de forma satisfatória dos alvos através do saldo de radiação.

O gráfico 9 aponta para uma baixa discrepância dos valores de saldo entre as classes de vegetação e do corpo hídrico. Excetuando-se as classes de solo exposto e área urbana, os valores observados nos pontos amostrais se mostraram com valores similares. É possível notar a presença de ruído na imagem decorrente da presença de nuvens nos pontos que divergem da tendência de cada classe.

Gráfico 9: Variação do Saldo de Radiação entre as classes (11/06/2014).



Fonte: O autor.

## 5.2.5 Relação entre os índices

### 5.2.5.1 Índices obtidos nas imagens de 02/01/2014


O gráfico 10 aponta para a associação que os baixos valores de NDVI têm com os altos valores de albedo para os alvos terrestres. Deve-se destacar que à água são atribuídos valores negativos de NDVI, e por suas características de

absorver a maior parte da radiação nela incidida, como citado anteriormente, é a classe que apresenta os menores valores de albedo de superfície.

As essas classes de área urbana e solo exposto têm os menores valores de NDVI, e os maiores valores de albedo. A agricultura irrigada e a vegetação arbórea apresentaram baixos valores de albedo e grandes valores de NDVI. Esse é o comportamento mais frequente para essas classes, pois a significativa presença de biomassa, e conseqüentemente umidade, tendem a absorver a maior parcela da radiação incidente. É importante destacar os valores de albedo da vegetação arbórea que em média foram menores que os encontrados na água. Esse comportamento está relacionado com o fato de que os pontos coletados referentes à vegetação arbórea na imagem se encontram em áreas de cobertura preservada e bem desenvolvida nas porções de maior altitude da região, onde a presença da sombra das árvores deixa o local como sendo uma superfície mais escura que as feições próximas.

A vegetação de caatinga apresentou valores sistematicamente maiores de albedo que as outras classes de vegetação, e um NDVI próximo à 0,374. Esse valor intermediário de NDVI é resultado da inconstância da vegetação na área do pixel, sendo a valor deste, influenciado pelo background do solo, este que segundo Huntington et al (2016) gera dificuldade para a obtenção de resultados mais precisos, e pela presença maior de vegetação seca, onde os galhos e troncos possuem cores mais claras que a vegetação verde.

Gráfico 10: Relação entre o albedo de superfície e o NDVI (02/01/2014).




Fonte: O autor.

O gráfico 11 mostra a clara relação que o albedo de superfície tem com a temperatura de superfície. Ma et al (2011) aplicou a associação destes dois parâmetros no estudo de detecção de áreas de desertificação, e observou que ambos tem potencial para o monitoramento ambiental de forma eficiente. As classes com menores valores de albedo são as que possuem menores temperaturas, e à medida que uma variável aumenta, a outra segue a mesma tendência. É de se destacar que mesmo com um albedo ligeiramente superior, as áreas do espelho d'água do reservatório de Itaparica apresentam valores de temperatura bem menores que a vegetação arbórea. Este fato está condicionado às propriedades de inercia térmica dos corpos hídricos, onde é preciso uma quantidade maior de radiação térmica para elevação de sua temperatura, quando comparada à outros elementos de superfície.

Nesta associação, se destaca ainda a vegetação de caatinga, que mesmo tendo um albedo inferior ao encontrado no solo exposto e na área urbana, apresentou valores de temperatura muito similares à estas classes. Este comportamento está ligado ao espaçamento entre as plantas e a influência do solo na retenção de calor.

Gráfico 11: Relação entre o Albedo de superfície e a temperatura de superfície (02/01/2014).



Fonte: O autor


Na associação apresentada no gráfico 12 pode ser observada a relação inversamente proporcional das variáveis albedo e saldo de radiação. Nas classes onde foram obtidos baixos valores de albedo, como por exemplo a água, a



vegetação arbórea e a agricultura irrigada, os valores de saldo de radiação são altos.

Pode-se inferir desse comportamento que a alta absorção de energia dessas classes, associado às temperaturas da época do ano em média mais altas em janeiro ao serem comparadas à junho, agem em favor da evaporação do conteúdo hídrico presente no alvo, e aumenta as trocas de massa com a atmosfera em forma de vapor. No saldo de radiação, as classes apresentaram valores bastante estratificados, isto permite a sua diferenciação e conseqüentemente, junto com o albedo, podem auxiliar no mapeamento do uso do solo.

Gráfico 12: Relação entre o albedo de superfície e o saldo de radiação (02/01/2014).




Fonte: O autor

O gráfico 13 traz a relação entre o NDVI e a temperatura de superfície. O comportamento dessas variáveis é semelhante ao que aconteceu entre o NDVI e o albedo. As áreas onde o NDVI obteve baixos valores, coincidem com as áreas de maior temperatura, mais uma vez se destacando nessas características as classes de solo exposto, área urbana e vegetação de caatinga. As classes de vegetação arbórea, agricultura irrigada apresentaram os maiores valores de NDVI e temperaturas mais amenas. A classe de água teve baixas temperaturas e como já citado, valores negativos de NDVI.

Este padrão serve para reforçar o fato de que a presença de vegetação e corpos hídricos interferem diretamente no microclima da região, como afirmam Pal e Ziaul (2016) onde destacam a influência da cobertura do solo na temperatura de

superfície. Sendo a manutenção da flora e preservação de recursos hídricos fundamentais em regiões semiáridas.


Gráfico 13: Relação entre o NDVI e a temperatura de superfície (02/01/2014).



Fonte: O autor

O gráfico 14 a seguir relaciona o NDVI e o saldo de radiação. É possível notar a tendência que as classes onde a presença de conteúdo hídrico se faz mais acentuada, a terem valores maiores de saldo de radiação. Nesse aspecto, a vegetação arbórea e a agricultura irrigada se destacam, além obviamente da água. Além disso, fica claro que mesmo a área urbana e o solo exposto apresentarem valores próximos de NDVI, obteve-se nessas classes, valores bem destacados de saldo. Já a vegetação de caatinga, se aproximou mais das outras classes de vegetação nesta comparação que nas anteriores.


Gráfico 14: Relação entre o NDVI e o saldo de radiação (02/01/2014).



Fonte: O autor

A seguir, no gráfico 15 é apresentada a relação entre a temperatura de superfície e o saldo de radiação. Mais uma vez, é possível notar um padrão onde as áreas mais vegetadas tem menor temperatura apresentam os maiores saldos de radiação, excetuando-se a água. Sendo assim, o conteúdo hídrico torna-se essencial para a observação dos comportamentos das classes de uso de solo. A vegetação arbórea que se localiza em áreas de maior altitude onde as temperaturas são mais amenas e a agricultura irrigada, que tem seu fornecimento hídrico mantido de forma regular, impactam no microclima local amenizando as temperaturas pela manutenção da umidade, juntamente com o reservatório de Itaparica. E o contrário também ocorre, onde as classes de solo exposto e área urbana contribuem para um aumento das temperaturas locais à superfície, pois refletem a maior parte da radiação incidente, e apresentam aquecimento acentuado.

Gráfico 15: Relação entre a temperatura de superfície e o saldo de radiação (02/01/2014).



Fonte: O autor


### 5.2.5.2 Índices obtidos nas imagens de 11/06/2014

O gráfico 16 traz a comparação entre os índices de albedo de superfície e NDVI. Neste caso, algo muito interessante ocorre pois, em média, as classes de vegetação arbórea, agricultura irrigada e vegetação de caatinga, apresentaram valores de albedo menores que na água. Como mostrado anteriormente, isto ocorre em decorrência do evento chuvoso no dia em que a imagem foi obtida. No entanto, ao observar o comportamento do NDVI para essas mesmas classes, pode-se perceber que a variação entre os valores se dá como o esperado. A vegetação arbórea e a agricultura irrigada apontando valores altos, e a vegetação de caatinga

com valores intermediários. As classes de área urbana e solo exposto se comportaram da maneira esperada, apresentando os maiores valores de albedo, e menores valores de NDVI entre as classes terrestres.

Ao comportamento do albedo, é concebível que se trata de uma variável altamente influenciada pelas condições meteorológicas do momento em que a imagem é obtida. Dessa forma, para que a análise espacial ocorra de forma eficiente, é imprescindível que se tenha clareza sobre esses aspectos. E para que não se incorram em erros de interpretação das imagens, se torna importante o estudo em conjunto de diferentes índices e variáveis, visando um trabalho que caracterize o espaço de forma eficiente.

Gráfico 16: Relação entre o albedo de superfície e o NDVI (11/06/2014).




Fonte: O autor

O gráfico 17 traz o comportamento da temperatura frente ao albedo da superfície. A temperatura se comportou de forma mais suavizada entre os diferentes tipos de alvo. A variação não foi tão brusca quanto a observada na imagem de janeiro, e isto reforça a influência que o evento chuvoso, mesmo que de pequena magnitude tem nos parâmetros biofísicos dos alvos superficiais.

Nessas condições, por exemplo, não seria possível distinguir o que é água, e o que é vegetação arbórea, tendo em vista que a diferença entre as duas classes é de apenas 0,2°C em média. Entre a vegetação de caatinga e agricultura irrigada a diferença de temperatura foi ainda menor, reforçando a dificuldade em classificar alvos nas condições especificadas anteriormente. Neste gráfico, tanto o albedo, quanto a vegetação se mostram inadequados à classificação do uso da terra.


Gráfico 17: Relação entre o albedo de superfície e temperatura de superfície (11/06/2014).



Fonte: O autor

A análise do gráfico 18 entre albedo e o saldo de radiação indica a sensibilidade de ambos com relação ao tempo meteorológico. Neste, o saldo de radiação se mostrou inferior na água que na vegetação arbórea. Isto ocorre em função das menores temperaturas na hora da passagem do sensor, onde esta variável é fundamental para a evaporação, e consequente acréscimo do saldo de radiação. Na agricultura irrigada e na vegetação de caatinga foram observados valores idênticos de saldo de radiação. Nessas classes de vegetação, a rápida evaporação da água em sua superfície aumenta a umidade local, condensando a atmosfera mais rapidamente ao comparar com o que ocorre no corpo hídrico, onde este precisa de mais calor para que a água evapore em grandes proporções.


Gráfico 18: Relação entre o albedo de superfície e saldo de radiação (11/06/2014).



Fonte: O autor

O gráfico 19 aponta para uma maior diferenciação das classes de uso do solo no NDVI que na temperatura de superfície. Como já afirmado anteriormente, a temperatura está condicionada às condições do tempo na hora da passagem do sensor, já o NDVI é resultado da evolução da paisagem numa escala temporal maior. Dessa forma, o NDVI reflete as condições do estado da cobertura do solo de forma mais fidedigna.


Gráfico 19: Relação entre NDVI e temperatura de superfície (11/06/2014).



Fonte: O autor

O gráfico 20 traz a relação entre o NDVI e o saldo de radiação. Neste é possível observar que os valores de saldo podem se atrelar às classes do NDVI no sentido de que as classes de vegetação de maior porte apresentaram os maiores valores, ao contrário do solo exposto e da área urbana onde os valores são menores. Assim como analisado pela temperatura, o NDVI aponta para uma maior discrepância entre as classes, facilitando a identificação dos alvos.


Gráfico 20: Relação entre NDVI e saldo de radiação (11/06/2014).



Fonte: O autor

O gráfico 21 apresenta a associação entre a temperatura de superfície e o saldo de radiação, serve apenas para reforçar a baixa variação dos índices entre os alvos estudados. É importante pontuar que estão sendo consideradas como baixa variação as apresentadas nessas imagens, tendo como base as magnitudes observadas na imagem de janeiro, onde as condições de tempo seco propiciaram uma atmosfera com menos vapor d'água, e dessa forma, possibilitando uma maior discrepância entre os alvos. Dessa forma, é provável que em regiões que possuem diferentes características climáticas, as variações entre classes encontradas na imagem de junho, sejam consideradas mais significativas.

Gráfico 21: Relação entre temperatura de superfície e saldo de radiação (11/06/2014).



Fonte: O autor

## 6 CONCLUSÕES

Em relação às classificações supervisionadas, a confusão entre as classes, e portanto, a baixa eficiência para discernir sobretudo as áreas com presença de solo exposto e solo urbano foi influenciada pela predominância de solos claros, em grande parte areias, que refletem grande parte da radiação eletromagnética que sobre elas incide. Dessa forma, se assemelha à resposta espectral dos alvos de solo urbano. Já a confusão entre as áreas de agricultura irrigada e vegetação de caatinga arbórea mais densa ocorre porque ambas apresentaram aspectos de uma vegetação desenvolvida e úmida. Entre os métodos de classificação supervisionada, a máxima verossimilhança apresentou valores mais elevados de Kappa e TAU, dessa forma, apontando para um melhor desempenho temático.

Mesmo com a confusão entre as classes, as classificações obtiveram bom desempenho na distinção entre os alvos de forma geral.

A análise dos resultados para os índices físicos permite concluir que albedo de superfície e o saldo de radiação apresentaram alta correlação entre si, e que ambos são influenciados diretamente pelas condições meteorológicas do momento da passagem do sensor. As imagens de janeiro para ambos os parâmetros demonstraram boa eficiência em destacar as diferentes classes de uso do solo, e a disparidade entre os alvos de solo ficaram claramente demarcados em relação ao reservatório de Itaparica. Tanto o albedo quanto o saldo de radiação podem ser utilizados no estudo de bordas de corpos hídricos. Um dos principais fatores que permitem afirmar isso é que ambos os índices conseguiram gerar uma separação entre o solo exposto e a área urbana, que em sua predominância é influenciada pela reflectância dos telhados das casas, constituídos em maior proporção de argila.

O NDVI e a temperatura de superfície têm uma relação inversamente proporcional nos alvos terrestres. Onde há predominância de altas densidades de vegetação, seja por cultivo irrigado, ou vegetação arbórea, as temperaturas são as mais baixas encontradas entre as classes de uso do solo. A temperatura vai aumentando à medida que a cobertura vegetal se torna mais rala, e a influência da retenção de calor do solo exposto e da área urbanizada se tornam mais presentes. A temperatura de superfície da imagem de 11/06/2014 foi especialmente influenciada pelo evento chuvoso, apresentando grande diferença com relação à imagem de

---



janeiro. Ambos os índices apresentaram diferenças quanto ao potencial de diferenciação dos alvos. O NDVI variou em menor proporção entre as duas datas, e a capacidade de classificação foi praticamente mantida, tornando este índice mais capaz de realizar mapeamentos em diferentes condições meteorológicas. Já a temperatura de superfície sofreu grande influência do evento chuvoso do dia da segunda imagem, e isto praticamente impossibilitou uma distinção eficiente entre os alvos. A imagem de janeiro se mostra muito mais propícia à classificação do uso do solo.

Além disso, é possível inferir que a sazonalidade acarreta uma forte alteração nos aspectos da vegetação, e mesmo o período chuvoso na região se estender apenas até abril, os eventos pluviométricos deste mês, seguidos com os cerca de 30mm de chuva do mês de maio, ajudaram a manter a vegetação em algumas áreas com um aspecto mais úmido e vigoroso. Dessa forma, pode-se inferir a importância da precipitação pluviométrica como fator de decréscimo de desempenho dos índices físicos visando a classificação do uso solo.

Esses fatores se potencializam ainda mais na vegetação de caatinga, altamente sensível à variações meteorológicas, e possivelmente em ambientes que se lhes assemelhem nesse sentido.

Por fim, é possível concluir que os índices físicos tem potencial de auxiliar no estudo da classificação do uso do solo, em caso de condições favoráveis de tempo meteorológico, como forma de complemento das classificações supervisionadas.

---

## 7 RECOMENDAÇÕES FUTURAS

Recomenda-se futuramente a classificação de imagens baseada nos intervalos que apresentaram maior destaque sobretudo nos índices de albedo de superfície e saldo de radiação.

Recomenda-se ainda o desenvolvimento de pesquisas que associem classificações supervisionadas à outros índices físicos que destaquem diferentes tipos de alvo, como por exemplo o NDBI (melhor contraste em áreas construídas) e NDWI (destaque para conteúdo hídrico), buscando uma melhor separação dos alvos terrestres.

---

## REFERÊNCIAS

ALLEN, R.G.; TASUMI, M.; TREZZA, R. 2002. **SEBAL (Surface Energy Balance Algorithms for Land). Advance Training and User's Manual – Idaho Implementation, version 1.0.** 97p.

ANDRADE, R. G.; **Aplicação do algoritmo SEBAL na estimativa da evapotranspiração e da biomassa acumulada da cana-de-açúcar.** Tese de doutorado. Programa de Pós-Graduação em Meteorologia Agrícola. Universidade Federal de Viçosa. Viçosa/MG, 2008.

BASTIAANSEN, W. G. M. **Regionalization of surface flux densities and moisture indicators in composite terrain.** Ph.D. Thesis, Wageningen Agricultural University, Wageningen, Netherlands, 273p, 1995.

BASTIAANSEN, W. G. M. **SEBAL-based sensible and latent heat fluxes in the irrigated Gediz Basin, Turkey.** Journal of Hydrology, v. 229, p. 87-100, 2000.

BHATTARAI, N.; DOUGHERTY, M.; MARZEN, L.J.; KALIN, L. 2012. **Validation of evaporation estimates from a modified surface energy balance algorithm for land (SEBAL) model in the south-eastern United States.** *Remote Sensing Letters*, 3 (6): 511-519.

BONHOMME, V. et al. **Introducing the vectorial Kappa: An index to quantify congruence between vectorial mosaics.** *Ecological Indicators*, nº57 (2015) pag. 96–99.

CERQUEIRA, M.A.; **Sensoriamento remoto no estudo do balanço de energia na área de preservação ambiental da ilha de Santa Rita/AL.** Dissertação de Mestrado. Programa de Pós-graduação em Ciências Geodésicas e Tecnologias da Geoinformação. Universidade Federal de Pernambuco, Recife, 2012.

CHURCHES, C.E., WAMPLER, P.J., SUN, W., SMITH, A.J.; **Evaluation of forest cover estimates for Haiti using supervised classification of Landsat data.** *International Journal of Applied Earth Observation and Geoinformation*, nº 30, (2014), pag. 203 –216.

COHEN, J. A.; **Coefficient of Agreement for Nominal Scales.** *Educational and Measurement*. Vol XX, No 1, p. 37-46, 1960.

CONGALTON, R. G. **A review of assessing the accuracy of classifications of remotely sensed data.** *Remote Sensing of Environment*, v. 49, n. 12, p. 1671-1678, 1991.

COURAULT, D.; SEGUIN, B.; OLIOSO, A. **Review to estimate evapotranspiration from remote sensing data: some examples from the simplified relationship to the use of mesoscale atmospheric models.** In ICID workshop on remote sensing

---

of ET for large regions, Montpellier, France, Sept. 2003; pp. 1-17. Disponível em: [http://water.kimberly.uidaho.edu/water/montpellier/p6/Courault\\_P.pdf](http://water.kimberly.uidaho.edu/water/montpellier/p6/Courault_P.pdf)

CRUZ, Z. Q.; RIBEIRO, G. P.; **Ensaio de segmentação e classificação digital de imagens cbers utilizando o sistema spring em uma unidade de conservação ambiental estudo de caso: parque nacional da serra dos órgãos (Parnaso)**. II Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação. Recife - PE, 8-11 de setembro de 2008.

CUNHA, E. J. B. L., et al; **Dinâmica da cobertura vegetal para a Bacia de São João do Rio do Peixe, PB, utilizando-se sensoriamento remoto**. Revista Brasileira de Engenharia Agrícola e Ambiental. v.16, n.5, p.539–548, 2012.

DAINESE, R.C.; **Sensoriamento remoto e geoprocessamento aplicado ao estudo temporal do uso da terra e na comparação entre classificação não-supervisionada e análise visual**. Dissertação de mestrado. Universidade Estadual Paulista - UNESP. Faculdade de Ciências Agrônômicas. Botucatu/São Paulo. 2001.

D'ARCO, E. **Radiometria e Comportamento Espectral de Alvos**. INPE. Acesso em: 24/06/2016. Disponível em: <http://www.agro.unitau.br>.

DING, H.; ELMORE, A. J.; **Spatio-temporal patterns in water surface temperature from Landsat time series data in the Chesapeake Bay, U.S.A**. Remote Sensing of Environment, n° 168, (2015), pag 335–348

DUARTE, H. F., DIAS, N. L., MAGGIOTTO, S. R. **Assessing daytime downward longwave radiation estimates for clear and cloudy skies in Southern Brazil**. Agricultural and Forest Meteorology, v. 139, p.171–181, 2006.

DUCHEMIN, J.; et al. **Monitoring wheat phenology and irrigation in Central Morocco: on the use of relationship between evapotranspiration, crops coefficients, leaf area index and remotely-sensed vegetation indices**. Agricultural Water Management, v. 79, p. 1 - 27, 2006.

EMBRAPA, **Mapa Exploratório-Reconhecimento de solos do município de Petrolândia, PE**. 2001. Acesso em 02/06/2017, disponível em: <http://www.uep.cnps.embrapa.br/solos/pe/petrolandia.pdf>.

EMBRAPA, **Brasil em Relevo**. 2015. Acesso em 26/10/2015, disponível em: <https://www.cnpm.embrapa.br/projetos/relevobr/download/>

EROGOV, A. V., ROY, D.P., KOMMAREDDY, A., POTAPOV, P.V.; **Image interpretation-guided supervised classification using nested segmentation**. Remote Sensing of Environment, n°165, (2015), pag. 135 –147.

FERREIRA, A. B., PEREIRA FILHO, W.; **Avaliação da reflectância espectral de corpos d'água em Santa Maria-Rs por meio de espectrorradiometria de campo**.

---

Revista Eletrônica do Curso de Geografia – Campus Jataí – UFG, nº 13. Jataí/GO, 2009.

FIGUEREDO, G. C.; **Exatidão posicional e Temática de Imagens Orbitais**. Dissertação de mestrado. Universidade Federal de Viçosa, MG, 2007.

FILGUEIRAS, R et al. **Saldo de radiação por meio de imagens orbitais na região de Botucatu-SP**. Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015.

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

FOLHES, M. T. **Modelagem da evapotranspiração para a gestão hídrica de perímetros irrigados com base em sensores remotos**. (Tese Doutorado em do Curso de Pos-Graduacao em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais – INPE, São Jose dos Campos, 2007.

FRANÇA, A. F.; TAVARES JUNIOR, J.; CANDEIAS, A. L. B.; **Índices Ndvi, Ndwi e Ndbi como ferramentas ao mapeamento temático do entorno da Lagoa Olho D'água, em Jaboatão Dos Guararapes-PE**. IV Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação, Recife - PE, 06- 09 de Maio de 2012 p. 001 – 009.

GOMES, H.B.; **Balances de radiação e energia em áreas de cultivo de cana-de-açúcar e cerrado no estado de São Paulo mediante imagens orbitais**. Tese de Doutorado, Programa de Pós-Graduação em Meteorologia da Universidade Federal de Campina Grande, 2009.

HANDCOCK, R. N.; et al. **Thermal Infrared Remote Sensing of Water Temperature in Riverine Landscapes**. Fluvial Remote Sensing for Science and Management, First Edition, 2012.

HEINSCH, F. A.; ZHAO, M.; RUNNING, S. W.; KIMBALL, J. S.; NEMANI, R. R.; DAVIS, K. J. **Evaluation of remote sensing based terrestrial productivity from MODIS using regional tower eddy flux network observations**. IEEE Transactions on Geoscience and Remote Sensing, v. 44, p.1908–1925, 2006.

HERB, W. R.; JANKE, B; MOHSENI, O.; STEFAN, H. G. **Ground surfasse temperature simulation for different land covers**. Journal of Hydrology, v.356, p.327-343, 2008.

HODGSON, M. E. **Reducing the computacional requirements of the minimum-distance classifier**. Remote Sensing of Environment, vol. 25, p. 117-128, 1988.

HUETE, A. R. (1988). **Adjusting vegetation indices for soil influences**. International Agrophysics, v.4, n.4, p.367-376.

---

HUNTINGTON et al. **Assessing the role of climate and resource management on groundwater dependent ecosystem changes in arid environments with the Landsat archive**. *Remote Sensing of Environment*, n° 185, (2016), pag. 186–197.

IBGE, **Petrolândia**. *Cidades*, 2016. Acesso em 11/12/2016, disponível em: <http://cidades.ibge.gov.br/v3/cidades/municipio/2611002>.

INMET, **Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP)**. 2016. Acesso em 17/02/2016, disponível em: <http://www.inmet.gov.br/projetos/rede/pesquisa/inicio.php>.

INPE, 2002. **Tutorial SPRING**. INPE, São José dos Campos.

IOCCG (2010). **Atmospheric correction for remotely-sensed ocean-colour products**. In M. Wang (Ed.), *Reports of the International Ocean-Colour Coordinating Group*, No. 10. Dartmouth, Canada: IOCCG.

IRONS, J. R., DWYER, J. L., & BARSI, J. A. **The next Landsat satellite: The Landsat Data Continuity Mission**. *Remote Sensing of Environment*, 122, 11–21, (2012).

JENSEN, J.R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**. São José dos Campos: Parêntese, 2009. 604 p.

KE, Y, et al. **Characteristics of Landsat 8 OLI-derived NDVI by comparison with multiple satellite sensors and in-situ observations**. *Remote Sensing of Environment* 164 (2015) 298–313.

KLECKA, W. R. **Discriminant Analysis**. SAGE Publications, Inc., Beverly Hills, California, 71 p., 1980.

LANDIS, J.R., KOCH, G.G. **The measurement of observer agreement for categorical data**. *Biometrics*, Washington, v.33, p.159-154, 1977.

LOPES, H. L., SILVA. B. B., PACHECO, A. D. P.; **Distribuição Espacial do Saldo de Radiação e do Fluxo de Calor no Solo no Território de Itaparica, Nordeste do Brasil**. *Revista Brasileira de Cartografia* (2014) N0 66/2: 233-244. Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto. ISSN: 1808-0936

MA, B.L., L.M. DWYER, C. COSTA, E.R. COBER, M.J. MORRISON. **Early prediction of soybean yield from canopy reflectance measurements**. *Agronomy Journal*. n° 93, pag. 1227-1234, (2001).

MA, Z. et al.; **The Construction and Application of an Aledo-NDVI Based Desertification Monitoring Model**. *International Conference on Environmental Science and Information Application Technology (ESIAT 2011)*. *Procedia Environmental Sciences*, n°10, (2011), pag. 2029 – 2035.

---

MA, Z. & REDMOND, R. **Tau Coefficients for Accuracy Assessment of Classification of Remote Sensing Data**. Photogrammetric Engineering and Remote Sensing, Vol. 61(4), p. 435-439. 1995.

MACHADO, C. C.; SILVA, B. B.; ALBUQUERQUE, M. B.; GALVÍNIO, J. D.; **Estimativa do Balanço de Energia utilizando imagens Tm – Landsat 5 e o algoritmo SEBAL no Litoral Sul de Pernambuco**. Revista Brasileira de Meteorologia, v.29, n.1, 55 - 67, 2014.

MACHADO, C. C., GALVÍNIO, J.D, PEREIRA, E.C.G.; **Utilização do IVAS e da Temperatura da superfície para análise multitemporal das mudanças ambientais no Parque Natural da Serra da Estrela (Portugal)**. Vi Seminário Latino Americano de Geografia Física, Universidade de Coimbra, maio de 2010.

MATHER, P.M. (2004). **Computer processing of remotely-sensed images. An introduction (3rd ed.)**. Chichester, United Kingdom: Wiley (324 pp.).

MATOS, R. C. M., et al.; **Análise multitemporal do albedo, ndvi e temperatura no entorno do reservatório de itaparica – pe: anos de 1985 e 2010**. Revista Brasileira de Cartografia (2015) N° 67/3, pag. 545-554.

MATOS, R. C. M., CANDEIAS, A.L.B., AZEVEDO, J.R.G.; **Estimativas do saldo de radiação instatâneo no entorno do reservatório de Itaparica – PE com uso de imagens orbitais**. Revista Brasileira de Cartografia (2016), N° 68/3: 641-654

MENESES, P. R., ALMEIDA, T.; **Introdução ao Processamento de Imagens de Sensoriamento Remoto**, 2012.

MORAES, E.C.; **Fundamentos de Sensoriamento Remoto**. DSR/INPE, 2002.

NICÁCIO, R. M., 2008, **Evapotranspiração real e umidade do solo usando dados de sensores orbitais e a metodologia SEBAL na bacia do rio São Francisco**. Tese de doutorado. Universidade Federal do Rio de Janeiro, COPPE.

NOBRE, P.; **Mudanças Climáticas e Desertificação: os desafios para o estado brasileiro. Desertificação e Mudanças Climáticas no Semiárido Brasileiro**. INSA- Instituto Nacional do Semiárido. Modulo 1, ISBN: 978-85-64265-02-8, Campina Grande-PB, 2011.

OLIVEIRA, L. M.M., et al; **Análise quantitativa de parâmetros biofísicos de bacia hidrográfica obtidos por sensoriamento remoto**. Pesquisa Agropecuária Brasileira, Brasília, v.47, n.9, p.1209-1217, set. 2012.

OLIVEIRA, L. M.M.; **Estimativa da evapotranspiração real por sensoriamento remoto na bacia do rio Tapacurá-PE**. Recife, 2012. xvii, 136 f. Tese (doutorado) - Universidade Federal de Pernambuco. CTG. Engenharia Civil, 2012.

OLIVEIRA, T.; MACHADO, C.; SILVA, J.; GALVÍNIO, J.; PIMENTEL, R.; SILVA, B.; **Índice de umidade (NDWI) e análise espaço-temporal do albedo da superfície**

---

**da bacia hidrográfica do rio Moxotó-PE.** Revista Brasileira de Geografia Física, América do Norte, nº3, 2010, pag 55-69.

PACHÊCO, A. P.; **Emissividades de Superfícies Naturais no Infravermelho Termal (8 – 12 Mm).** Anais IX Simpósio Brasileiro de Sensoriamento Remoto, Santos, Brasil, 11-18 setembro 1998, INPE, p. 1307-1313.

PAIVA, C.M.; FRANÇA, G.B.; LIU, W.T.H.; ROTUNNO FILHO, O.C. 2011. **A comparison of experimental energy balance components data and SEBAL model results in Dourados, Brazil.** *International Journal of Remote Sensing*, 32 (6): 1731-1745.

PAL, S., ZIAUL, S. **Detection of land use and land cover change and land surface temperature in English Bazar urban centre.** The Egyptian Journal of Remote Sensing and Space Science, Available online 24 November 2016, ISSN 1110-9823, <http://dx.doi.org/10.1016/j.ejrs.2016.11.003>.

PEREIRA, A.C.M.; **Emissividade dos materiais de construção – influência da medição em diferentes variantes.** Dissertação de mestrado. Faculdade de Engenharia. Universidade do Porto, 2015.

PEREIRA, J.S.; **Medida de coeficientes de absorção de óxidos, na faixa do visível ao infravermelho pelo método foto-térmico.** Dissertação de mestrado. Universidade Federal da Bahia. Instituto de Física. Programa de pós-graduação em física, 2011.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação,** São José dos Campos, SP: A. Silva Vieira Ed. p.111-118, 2007.

REYES, A.; et al. **Comparison of different object-based classifications in LandsatTM images for the analysis of heterogeneous landscapes.** *Measurement* n° 97, (2017), pag. 29–37.

RIAZA, A.; ESCUDER, J.; VILLAR, P.; MARTIN ALFAGEME, S. **Reflectância espectral em el e enfrarrojo cercano (400-2500nm) de distintas litologias en un conjunto ígneo y metamórfico (Salamanca España): aplicaciones en cartografía geológica.** Revista – Sociedad Geológica de España. Volume 7 (1-2), 1993.

RICHARDS, J. A; JIA, X. **Remote Sensing digital image analysis: An Introduction.** 4. ed. Australia: Springer. 2006. 439p.

ROY, D. P.; et al. **Landsat-8: Science and product vision for terrestrial global change research.** *Remote Sensing of Environment* 145 (2014) 154–172.

RUHOFF, A. L., SILVA, B. B., ROCHA, H. R.; **Determinação da irradiância solar no topo da atmosfera para cálculo do albedo e balanço de energia a partir de imagens LANDSAT 8 OLI.** Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015, INPE.

---



SAKAMOTO, T.; et al. **A crop phenology detection method using time-series MODIS data**. Remote Sensing of Environment, 96, 366–374, 2005.

SHIMABUKURO, Y.E.; NOVO, E. M.; PONZONI, F. J.; **Índice de vegetação e modelo linear de mistura espectral no monitoramento da região do pantanal**. Pesq. Agropecuária Brasileira, Brasília, v.33, Número Especial, p.1729-1737, out. 1998.

SILVA, B.B., CÂNDIDO, M. V., **Determinação da evapotranspiração em escala regional através do Sebal e imagens Landsat 5 – TM**. XIII Congresso Brasileiro de Meteorologia, Fortaleza. 2004.

SILVA, B.B.; LOPES, G.M.; AZEVEDO, P. V.; **Balço de radiação em áreas irrigadas utilizando imagens landsat 5 – tm**. Revista Brasileira de Meteorologia, v.20, n.2, 243-252, 2005.

SILVA, B.; MENDONÇA, R.; SILVA, S.; FERREIRA, R.; **Mapeamento do Albedo de Áreas Heterogêneas do Estado do Ceará com Imagens TM - Landsat 5**. Revista de Geografia (Recife), América do Norte, 2520, 01, 2010.

SILVA, E.; MELO, J.; GALVÍNCIO, J.D.; **Identificação das Áreas Susceptíveis a Processos de Desertificação no Médio Trecho da Bacia do Ipojuca - PE através do Mapeamento do Estresse Hídrico da Vegetação e da Estimativa do Índice de Aridez (Identification of Areas Susceptible to...)**. Revista Brasileira de Geografia Física, América do Norte, 425 09 (2011).

SILVA, L.G., GALVÍNCIO, J.D.; **Análise Comparativa da Variação nos Índices NDVI e SAVI no Sítio PELD – 22, em Petrolina – PE, na Primeira Década do Século XXI**. Revista Brasileira de Geografia Física, nº 06, (2012), pag. 1446-1456.

STAENZ, K; ITTEN, K.I.; **Reflective properties of asphalt and concrete surfaces**. In: Symposium International de la Commission VII de La Societé Internationale de Photogrammetrie, Actes, V.1, Toulouse, France, 13-17 sep., Societé Internationale de Photogrammetrie et Teledetection, 1982, p.307-316.

STONER, E.R. & BAUMGARDNER, M.F. **Characteristics variations in reflectance of surface soils**. Soil Science Society of America Journal. Am. J., 45:1161-1165, 1981.

TROVÃO, D.M.B.M, et al; **Variações sazonais de aspectos fisiológicos de espécies da Caatinga**. Revista Brasileira de Engenharia Agrícola e Ambiental. Vol.11, nº.3, p.307–311, 2007.

USGS: **Landsat 8 History**. 2016. Acesso em 03/12/2016. Disponível em: <https://landsat.usgs.gov/landsat-8-history>.

USGS: **Using the USGS Landsat 8 product**. 2016. Acesso em 15/08/2016. Disponível em: <https://landsat.usgs.gov/using-usgs-landsat-8-product>.

---

VAREJÃO-SILVA, M. A.; **Meteorologia e climatologia**. Ministério da Agricultura e Abastecimento, Instituto Nacional de Meteorologia, 2ª Ed. (versão digital), 463p., 2006.

WAGNER, A.P.L.; **Aplicação de imagens aster para estudos territoriais no nordeste do estado do Rio Grande do Sul**. Dissertação de Mestrado. Curso de Pós-Graduação em Sensoriamento Remoto. Universidade Federal do Rio Grande do Sul. 2004.

XAVIER. M. B., **Variação Da Temperatura de Superfície na Lagoa Mangueira nas Passagens de Sistemas Frontais, a Partir de Dados de Radiância do Sensor MODIS**. Tese de Doutorado. Universidade Federal do Rio Grande do Sul, 2014.

ZHOU, Y.; et al.; **Mapping paddy rice planting area in rice-wetland coexistent areas through analysis of Landsat 8 OLI and MODIS images**. International Journal of Applied Earth Observation and Geoinformation, n° 46, (2016), pag. 1–12.

---