



UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

DIEGO CASTRO DA SILVA

DINÂMICA ESPAÇO-TEMPORAL DE ÁREAS SALINIZADAS NO
PERÍMETRO IRRIGADO DE JUAZEIRO-BAHIA NO VALE DO SUBMÉDIO
SÃO FRANCISCO

RECIFE – PE

2020

DIEGO CASTRO DA SILVA

**DINÂMICA ESPAÇO-TEMPORAL DE ÁREAS SALINIZADAS NO
PERÍMETRO IRRIGADO DE JUAZEIRO-BAHIA NO VALE DO SUBMÉDIO
SÃO FRANCISCO**

Dissertação apresentada ao programa de Pós-Graduação em Engenharia Agrícola da Universidade Federal Rural de Pernambuco, sob orientação do Prof. Dr. Fabrício Marcos Oliveira Lopes, como parte dos requisitos para obtenção do título de Mestre em Engenharia Agrícola.

RECIFE – PE

2020

Ficha Catalográfica

Dados Internacionais de Catalogação na Publicação

Universidade Federal Rural de Pernambuco
Sistema Integrado de Bibliotecas

Gerada automaticamente, mediante os dados fornecidos pelo(a) autor(a)

S586d Silva, Diego Castro da
Dinâmica espaço-temporal de áreas salinizadas no perímetro irrigado de Juazeiro-Bahia no vale do submédio
São Francisco / Diego Castro da Silva. - 2020.
97 f. : il.

Orientador: Pabricao Marcos Oliveira Lopes.
Inclui referências.

Dissertação (Mestrado) - Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em
Engenharia Agrícola, Recife, 2020.

1. Componentes principais. 2. Condutividade elétrica. 3. Índices de salinidade. 4. Sentinel-2. 5. Semiárido.
I. Lopes, Pabricao Marcos Oliveira, orient. II. Título

CDD 630

DIEGO CASTRO DA SILVA

**DINÂMICA ESPAÇO-TEMPORAL DE ÁREAS SALINIZADAS NO
PERÍMETRO IRRIGADO DE JUAZEIRO-BAHIA NO VALE DO SUBMÉDIO
SÃO FRANCISCO**

Dissertação defendida e aprovada em 17 de fevereiro de 2020 pela banca examinadora:

Orientador:

Pabrcio Marcos Oliveira Lopes, Prof. Dr.

Examinadores:

Cristina Rodrigues Nascimento, Profa. Dra.

José Ivaldo Barbosa de Brito, Prof. Dr.

DEDICO:

Ao nosso senhor Deus e Jesus Cristo;

A toda minha família, em especial aos meus pais Ruberaldo Lopes da Silva e Rita Maria Nunes de Castro;

A meu Orientador Pabício Lopes;

Aos amigos e colegas de jornada da Pós-graduação e da vida;

A sociedade para que possa usufruir desse conhecimento para o bem social e ambiental.

AGRADECIMENTOS

Agradeço primeiramente ao nosso SENHOR DEUS e a seu filho JESUS CRISTO, porque só ele com sua infinita inteligência é detentor de todo o saber. Durante toda a minha vida proporcionou condições para superar as dificuldades, dando saúde, amor, família e amigos, pessoas fundamentais para meu crescimento como pessoa e profissional. Sem Deus eu não seria nada.

Em especial, aos meus pais Ruberaldo Lopes da Silva e Rita Maria Nunes de Castro, que com o mais puro e insubstituível amor, apoiaram as minhas decisões, incentivando a cada passo, não me deixando faltar nada, deram preciosos conselhos nos momentos difíceis da vida.

Sou grato a DEUS por ser fruto do Amor de vocês e espero tê-los o máximo de tempo em minha vida. Espero sinceramente poder retribuir por tudo que fizeram por mim e prometo pôr em prática todo ensinamento, sendo antes de tudo uma pessoa honrada, ética e consciente nas decisões tomadas, visando sempre ajudar as pessoas.

Agradeço aos meus irmãos Thiago Castro da Silva, Thaís Castro da Silva e Débora Castro da Silva, por ter crescido junto comigo, me aconselhando e me ajudando a escolher os melhores caminhos. Por cuidar de mim, pelas broncas e pelos momentos inesquecíveis vividos ao lado de cada um de vocês. Hoje sou mais feliz por ter os melhores sobrinhos do mundo. Por fim, amo cada um de vocês com toda minha força e espero compartilhar os frutos de minhas vitórias com toda nossa família.

Meu agradecimento especial à Mariana Nogueira Bezerra pelo amor, carinho e paciência durante esse período de mestrado, sempre apoiando nas minhas decisões e mesmo longe, nunca mediu esforços para me ajudar.

Ao meu Orientador Fabrício Marcos de Oliveira Lopes, pelos conselhos, paciência, total disponibilidade e boa vontade em me orientar. Graças a você, por acreditar em mim, me senti confiante em seguir firme e forte nos desafios encontrados durante a Pós-graduação.

Agradeço também ao coordenador da Pós-Graduação em Engenharia Agrícola, professor Ênio Farias de França e Silva, pelo comprometimento com o Programa de Pós-Graduação em Engenharia de Agrícola – PGEA, que exaustivamente busca melhorar a qualidade desse programa tão conceituado.

Agradeço aos professores titulares e colaboradores, vocês são a engrenagem desse programa, compartilhando suas experiências e conhecimento conosco, e sempre extraindo o melhor de cada um dos discentes.

Aos colegas e amigos do mestrado, pessoas únicas que me proporcionaram momentos de alegria, compartilharam seus conhecimentos e me ajudaram nas dificuldades.

A FACEPE e a CAPES por acreditar no projeto de pesquisa, pela oportunidade da bolsa, a qual me deu total condições de fazer o mestrado.

Por fim, agradeço a Universidade Federal Rural de Pernambuco, pela excelente estrutura, pelo corpo docente de alto nível e por me proporcionar uma formação acadêmica de qualidade.

Meu muito obrigado a todos...

SUMÁRIO

LISTA DE FIGURAS

LISTA DE TABELAS

LISTA DE ABREVIATURAS E SIGLAS

RESUMO

ABSTRACT

1. INTRODUÇÃO.....	17
2. OBJETIVOS.....	19
2.1. Objetivo geral.....	19
2.2. Objetivos específicos.....	19
3. REVISÃO BIBLIOGRÁFICA.....	20
3.1. Bioma Caatinga.....	20
3.2. Salinidade do solo.....	21
3.3. Sensoriamento Remoto.....	22
3.4. Sistema de satélites Landsat.....	23
3.5. Sentinel-2.....	25
3.6. Correção Atmosférica Subtração de Pixel Escuro (DOS1).....	27
3.7. Índices de vegetação.....	28
3.7.1. NDVI.....	29
3.7.2. SAVI.....	30
3.7.3. EVI.....	31
3.7.4. GDVI.....	31
3.8. Índices de salinidade.....	32
3.8.1. SI-1.....	33
3.8.2. SI-2.....	33
3.8.3. SI-3.....	34
3.8.4. IB.....	34
3.9. Evapotranspiração real pelo método do SEBAL.....	34
3.10. Classificação digital de imagens.....	35

3.10.1. Classificador Máxima Verossimilhança	36
3.10.2. Índice Kappa.....	36
3.11. Análise de componente principal.....	37
4. MATERIAL E MÉTODOS.....	38
4.1. Caracterização da área de estudo.....	38
4.2. Seleção e descrição das áreas de estudo.....	40
4.3. Seleção e obtenção de dados orbitais.....	42
4.4. Pré-processamento de imagens.....	43
4.5. Processamento.....	44
4.5.1. Processamento de imagens Landsat-8	44
4.5.2. Processamento Sentinel-2.....	46
4.6. Classificação Supervisionada.....	47
4.7. Coleta de solo para análise de condutividade elétrica do extrato saturado do solo.....	47
4.8. Dados meteorológicos.....	49
4.9. Análise estatística.....	50
5. RESULTADOS E DISCUSSÃO	51
5.1. Dados meteorológicos na caracterização das áreas.....	51
5.2. Análise de Componentes Principais: Seleção dos melhores índices.....	53
5.3. Avaliação do grau de salinidade nas três áreas de estudo.....	59
5.4. Classificação Supervisionada para avaliação da salinidade sobre máscaras de diferentes classes de uso do solo.....	61
5.5. Níveis de sais distribuídos dentro das classes de uso do solo.....	64
5.6. Seleção dos índices de vegetação e de salinidade para elaboração de cartas temáticas.....	66
5.7. Análise da variabilidade espaço-temporal dos parâmetros indicadores de salinidade.....	68
5.7.1. GDVI e SAVI.....	68
5.7.2. SI-1 e SI-3.....	74

6. CONCLUSÕES	78
7. CONSIDERAÇÕES E SUGESTÕES	80
8. REFERÊNCIAS BIBLIOGRÁFICAS	82

LISTA DE FIGURAS

Figura 1. Distribuição original dos biomas brasileiros.....	20
Figura 2. Comparação da assinatura espectral de um mesmo pixel com correção DOS1, refletância do topo da atmosfera e em números digitais.	28
Figura 3. Localização da área de estudo: (A) Brasil e semiárido; (B) Bahia; (C) município de Juazeiro; (D) Perímetro de Irrigação de Maniçoba e (E) Lotes agrícolas estudados.	39
Figura 4. Ausência de vegetação nativa e agrícola (A); coqueiros mortos (B); herbáceas halófitas (<i>Sesuvium portulacastrum</i> (L.) L.) (C); indivíduos mortos pela salinidade (D); solo escuro e desestruturado (E); crosta de sal na superfície (F).....	41
Figura 5. Localização das áreas 1, 2 e 3 no perímetro irrigado de Maniçoba, Juazeiro-BA, imagem Sentinel-2.	42
Figura 6. Diagrama representativo das etapas para obtenção da evapotranspiração real a partir do algoritmo SEBAL	46
Figura 7. Distribuição dos pontos de coleta de solo: Área 1 (32 pontos), área 2 (32 pontos) e área 3 (32 pontos).	48
Figura 8. Trado de mão na coleta do solo (A); amostras em processo de secagem ao ar (B); extrato de saturação do solo (C); leitura da condutividade elétrica a 25°C (D).....	49
Figura 9. Variação mensal da precipitação pluviométrica e da temperatura do ar para o período de 2014 a 2019.	53
Figura 10. Componentes principais nas áreas 1, 2 e 3 de estudo para o ano de 2019...	55
Figura 11. Componentes principais dos índices indicadores, das variáveis biofísicas calculadas e a condutividade elétrica do solo para as áreas A1, A2 e A3.	56
Figura 12. Classes de salinidade identificadas nas áreas estudadas.	59
Figura 13. Interpolação IDW da distribuição espacial da salinidade do solo nas áreas de estudo (A1, A2 e A3).....	60
Figura 14. Classificação Supervisionada MAXVER para 4 classes de uso do solo e suas respectivas áreas em imagens Sentinel-2.....	63
Figura 15. Carta temática do índice de vegetação da diferença generalizada – GDVI (Landsat-8 e Sentinel-2) de áreas localizadas no perímetro irrigado Maniçoba, município de Juazeiro – BA no período entre 2014 e 2019.....	68
Figura 16. Carta temática do índice de vegetação ajustado ao solo – SAVI (Landsat-8 e Sentinel-2) de áreas localizadas no perímetro irrigado Maniçoba, município de Juazeiro – BA no período entre 2014 e 2019.....	69

Figura 17. Valores médios de GDVI e SAVI em áreas agrícolas (A) e vegetação natural (B), no período de 2014 a 2019.	71
Figura 18. Carta temática do índice de salinidade SI-1 (Landsat-8 e Sentinel-2) de áreas localizadas no perímetro irrigado Maniçoba, município de Juazeiro – BA, no período entre 2014 e 2019.	74
Figura 19. Carta temática do índice de salinidade SI-3 (Landsat-8 e Sentinel-2) de áreas localizadas no perímetro irrigado Maniçoba, município de Juazeiro – BA, no período entre 2014 e 2019.	75
Figura 20. Valores médios de SI-1 e SI-3 em solo exposto no período de 2014 a 2019.	77

LISTA DE TABELAS

Tabela 1. Características da série de satélites Landsat.	24
Tabela 2. Característica espectral e resolução espacial sensores OLI e TIRS/ Landsat-8.	25
Tabela 3. Características do sensor MSI/Sentinel-2A/2B.	26
Tabela 4. Índice Kappa associado a qualidade da classificação.....	37
Tabela 5. Dados referentes às imagens do satélite Landsat-8 e Sentinel-2A e 2B utilizados no estudo.....	43
Tabela 6. Índices espectrais de vegetação e salinidade utilizados.....	45
Tabela 7. Dados meteorológicos da estação automática INMET, para as datas de imageamento dos produtos Landsat-8 e Sentinel-2.....	50
Tabela 8. Precipitação pluviométrica da estação meteorológica automática do INMET no município de Petrolina - PE no período de 2014 a 2019.	52
Tabela 9. Componentes principais das variáveis analisadas nas três áreas de estudo para o ano de 2019.....	54
Tabela 10. Matriz de confusão, erros de omissão, erros de inclusão e índice Kappa....	62
Tabela 11. Níveis de salinidade nas classes de uso do solo.....	64
Tabela 12. Correlação de Pearson e desvio padrão entre a CE e os índices de vegetação	66
Tabela 13. Valores dos parâmetros estatísticos obtidos na análise do GDVI para as datas do imageamento.....	72
Tabela 14. Valores dos parâmetros estatísticos obtidos na análise do SAVI para as datas do imageamento.....	73
Tabela 15. Valores dos parâmetros estatísticos obtidos na análise do SI-1.....	78
Tabela 16. Valores dos parâmetros estatísticos obtidos na análise do SI-3.....	78

LISTA DE ABREVIATURAS E SIGLAS

ACP	Análise de Componentes Principais
ASTER	<i>Advanced Spaceborne Thermal Emission and Reflection Radiometer</i>
AVHRR	<i>Advanced Very High Resolution Radiometer</i>
CE	Condutividade elétrica
CODEVASF	Companhia de Desenvolvimento dos Vales do São Francisco e do Parnaíba
DIM	Distrito de Irrigação Maniçoba
DOS1	<i>Dark Object Substraction-1</i>
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
EOS	<i>Earth Observing System</i>
ESA	<i>European Space Agency</i>
ETM+	<i>Enhanced Thematic Mapper Plus</i>
ETR	Evapotranspiração real
EVI	<i>Enhanced Vegetation Index</i>
FAO	<i>Food and Agriculture Organization of the United Nations</i>
FRB	Refletância Bidirecional Aparente
GDVI	<i>Generalized Vegetation Difference Index</i>
GMES	<i>Global Monitoring for Environment and Security</i>
IAF	Índice de área foliar
IB	Índice de brilho
IBGE	Instituto Brasileiro de Geografia e Estatística
IDW	<i>Inverse Distance Weighting</i>
INMET	Instituto Nacional de Meteorologia
INPE	Instituto Nacional de Pesquisas Espaciais
IRS	<i>Indian Remote Sensing</i>
LANDSAT	<i>Land Remote Sensing Satellite</i>
MaxVer	<i>Maximum Likelihood</i>
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
MSI	<i>Multispectral instrument</i>
NASA	<i>National Aeronautics and Space Administration</i>
ND	Número Digital
NDVI	<i>Normalized Difference Vegetation Index</i>
NIR	Infravermelho próximo

NOAA	<i>National Oceanic and Atmospheric Administration's</i>
OLI	<i>Operacional Land Imager</i>
PCA	<i>Principal Component Analysis</i>
SAVI	<i>Soil-Adjusted Vegetation Index</i>
SCP	<i>Semi-Automatic Classification Plugin</i>
SEBAL	<i>Surface Energy Balance Algorithm for Land</i>
SI-1	<i>Salinity Index 1</i>
SI-2	<i>Salinity Index 2</i>
SI-3	<i>Salinity Index 3</i>
SPOT	<i>Système Pour l'Observation de la Terre</i>
SRTM	<i>Shuttle Radar Topography Mission</i>
SWIR	<i>Infravermelho de ondas curtas</i>
TIRS	<i>Thermal Infrared Sensor</i>
TM	<i>Thematic Mapper</i>
TOA	<i>Top of Atmosphere</i>
UE	<i>European Union</i>
USGS	<i>United States Geological Survey</i>
UTM	<i>Universal Transverse Mercator</i>
WGS	<i>World Geodetic System</i>

SILVA, D. C. **Dinâmica espaço-temporal de áreas salinizadas no perímetro irrigado de Juazeiro-Bahia no vale do submédio São Francisco**. 2020. 96f. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal Rural de Pernambuco – UFRPE.

Autor: Diego Castro da Silva

Orientador: Prof. Dr. Fabrício Marcos Oliveira Lopes

RESUMO: Altas concentrações de sais no solo constituem-se um dos graves problemas ambientais que degradam o meio ambiente, inviabilizam as atividades agrícolas e podem levar a desertificação. Ocorre com maior frequência em perímetros irrigados situados em regiões de clima árido e semiárido, como o projeto de irrigação de Maniçoba, principal projeto irrigado de fruticultura do município de Juazeiro-BA. O monitoramento de áreas salinizadas e a avaliação de seus impactos no uso e ocupação do solo, ao longo do tempo em grande escala, a partir do Sensoriamento Remoto, pode ser uma abordagem efetiva para dar suporte as tomadas de decisões nas atividades de prevenção e controle desse fenômeno. Objetivou-se com esse estudo, analisar a dinâmica espaço-temporal da salinidade no perímetro irrigado de Maniçoba por meio de imagens Landsat-8 e Sentinel-2, aplicando índices de salinidade e vegetação em conjunto com dados meteorológicos. O estudo foi desenvolvido em áreas agrícolas com sinais de salinidade, onde foram coletadas amostras para análise da condutividade elétrica do solo (CE). Utilizou-se imagens dos satélites Landsat-8 e Sentinel-2 em conjunto de dados meteorológicos nos anos de 2014 a 2019. Com o uso do software QGis 2.18.19, as imagens foram pré-processadas, corrigidas as influências atmosféricas, convertido os números digitais em refletância da superfície e cálculo de bandas espectrais para obtenção dos parâmetros biofísicos: índices de vegetação NDVI, SAVI, EVI e GDVI, índices de salinidade SI-1, SI-2, SI-3 e IB, albedo, temperatura de superfície e evapotranspiração real. Foram realizadas as técnicas de interpolação, classificação digital de imagens Maxver, avaliado sua acurácia e extraído os valores de pixels de 4 classes da superfície, para cruzamento de informações das variáveis calculadas. Utilizou-se a estatística multivariada análise de componentes principais (ACP), correlação de Pearson e estatística descritiva para avaliar as relações entre parâmetros e quantificar seu comportamento ao longo do tempo em função da salinidade do solo. As informações meteorológicas caracterizaram as condições climáticas para o período de estudo. Os índices de salinidade SI-1 e SI-3 e índices de vegetação GDVI e SAVI apresentaram as melhores respostas estatísticas. A (ACP) reduziu a dimensão do conjunto de dados e separou grupos de variáveis de maior similaridade, obtendo no acumulado de CP1 e CP2 valores acima de 78% da variância explicada. A CE demonstrou forte relação com a temperatura de superfície, albedo e índices SI-1 e SI-3, além de forte relação indireta com os índices GDVI e SAVI. As análises de CE revelaram que as áreas se encontram bastante degradadas pela salinidade, principalmente em solos expostos, seguido pela vegetação natural e área agrícola. A análise das cartas temáticas geradas a partir dos índices GDVI, SAVI, SI-1 e SI-3, mostraram as alterações ocorridas no uso e ocupação do solo ao longo do tempo, devido a salinização dos solos, confirmados pelas análises estatísticas e gráficos de refletância espectral das diferentes classes. A aplicação conjunta das técnicas de Sensoriamento Remoto mostrou-se eficaz na caracterização da salinidade aos níveis espacial e temporal, e os dados meteorológicos contribuíram para o entendimento dos processos observados no estudo.

Palavras-chave: Componentes principais, condutividade elétrica, índices de salinidade, Sentinel-2, semiárido.

SILVA, D. C. Spatio-temporal dynamics of salinized areas in the irrigated perimeter of Juazeiro-Bahia in the São Francisco sub-middle valley. 2020. 96f. Dissertation (Master in Agricultural Engineering) - Federal Rural University of Pernambuco - UFRPE.

Author: Diego Castro da Silva

Advisor: Prof. Dr. Fabrício Marcos Oliveira Lopes

ABSTRACT: High concentrations of salts in the soil are one of the serious environmental problems that degrade the environment, make agricultural activities unfeasible and can lead to desertification. It occurs more frequently in irrigated perimeters located in arid and semi-arid regions, such as the Maniçoba irrigation project, the main irrigated fruit production project in the municipality of Juazeiro-BA. Monitoring salinized areas and assessing their impacts on land use and occupation, over time on a large scale, using Remote Sensing, can be an effective approach to support decision making in prevention and control activities of this phenomenon. The objective of this study was to analyze the spatial-temporal dynamics of salinity in the irrigated perimeter of Maniçoba using Landsat-8 and Sentinel-2 images, applying salinity and vegetation indices in conjunction with meteorological data. The study was carried out in agricultural areas with signs of salinity, where samples were collected for analysis of the electrical conductivity of the soil (CE). Images from the Landsat-8 and Sentinel-2 satellites were used in meteorological data from 2014 to 2019. Using the QGIS 2.18.19 software, the images were pre-processed, atmospheric influences were corrected, converting the digital numbers into surface reflectance and calculating spectral bands to obtain the biophysical parameters: vegetation indices NDVI, SAVI, EVI and GDVI, and salinity indices SI-1, SI-2, SI-3 and IB, albedo, surface temperature and actual evapotranspiration. The interpolation techniques, digital classification of Maxver images were performed, their accuracy was assessed and the pixel values of 4 soil classes were extracted to cross-check information from the calculated variables. Multivariate statistics of principal component analysis (PCA), Pearson's correlation and descriptive statistics were used to assess the relationships between parameters and to quantify their behavior over time as a function of soil salinity. The meteorological information characterized the climatic conditions for the study period. The SI-1 and SI-3 salinity indices and GDVI and SAVI vegetation indices showed the best statistical responses. The (ACP) reduced the size of the data set and separated groups of variables of greater similarity, obtaining in the accumulated of CP2 values above 78% for the three areas. The EC demonstrated a strong relationship with the surface temperature, albedo and SI-1 and SI-3 indices, in addition to a strong indirect relationship with the GDVI and SAVI. The EC analyzes revealed that the areas are very degraded by salinity, mainly in exposed soils, followed by natural vegetation and agricultural area. The analysis of thematic maps generated from the GDVI, SAVI, SI-1 and SI-3 indexes, showed the changes that occurred in the use and occupation of the soil over time, due to the salinization of the soils, confirmed by the statistical analysis and graphs of spectral reflectance of the different classes. The joint application of Remote Sensing techniques proved to be effective in characterizing salinity at a spatial and temporal level, and meteorological data contributed to the understanding of the processes observed in the study.

Keywords: Main components, electrical conductivity, salinity index, Sentinel-2, semiarid.

1. INTRODUÇÃO

A salinização do solo ocorre quando sais solúveis em água, sódio trocável ou ambos acumulam-se no solo até um nível que afeta a produção agrícola, a saúde ambiental e a economia. Ela é um dos graves riscos ambientais e o principal fator que causa degradação da terra e desertificação, especialmente em regiões de clima árido e semiárido, como o Nordeste brasileiro (METTERNICKT & ZINCK, 2003; BOUAZIZ et al., 2011; ALLBED & KUMAR, 2013; TAGHADOSI & HASANLOU, 2017).

A região semiárida é predominantemente ocupada pela caatinga, que compreende 11% do território nacional, englobando todos estados do Nordeste e o norte de Minas Gerais (MINISTÉRIO DO MEIO AMBIENTE, 2019), abrigando 11,8% da população brasileira (MEDEIROS et al., 2012). A região possui alto potencial agrícola, mas é prejudicada pela escassez de água e irregularidade na distribuição de chuvas (espacial, temporal e volumétrica), que juntamente com a elevadas taxas de evapotranspiração e temperatura, produz longos períodos secos (FERREIRA et al., 2016), favorecendo grandes riscos de salinização do solo em perímetros irrigados (HOLANDA et al., 2016).

O risco de salinização está relacionado aos processos naturais como o intemperismo físico e químico, que produz sais no perfil do solo, a evapotranspiração e as secas, ou causada por atividades humanas, como o uso de irrigação rica em sais, uso ineficiente de água, pouca drenagem, construção de barragem (RICHARDS, 1954; BARROS et al., 2009) o que leva à redução da fertilidade do solo e perda de produtividade (SOIL SALINIZATION, 2017).

O perímetro irrigado de Maniçoba em Juazeiro-BA foi inaugurado em 1980 com área de 1.800 ha, distribuição de água para os lotes agrícolas por gravidade e irrigação por sistema de sulco para produção de culturas temporárias como cebola, tomate, feijão, melancia e melão (MARINOZZI & CORREIA, 1999). O manejo inadequado das práticas de irrigação por sulco (baixo custo) em culturas de ciclo curto (rápido retorno financeiro ao produtor) adotado por muitos anos, associado aos fatores ambientais locais, foi um dos principais responsáveis pela intensificação da salinidade e baixa produtividade em perímetros irrigados (BARROS et al., 2009; HOLANDA et al., 2016).

Hoje, existem lotes dentro do perímetro de Maniçoba que foram abandonados ou transformados em áreas de reserva legal, devido ao problema da alta salinidade, que inviabilizou a atividade agrícola, impactando a produção e conseqüentemente menor retorno financeiro. O desenvolvimento dinâmico da salinidade do solo precisa ser monitorado

regularmente para atualização de sua extensão, distribuição espacial, grau de severidade, natureza e magnitude (AZABDAFTARI & SUNARB, 2016).

A detecção das mudanças de áreas afetadas por sais pode ser avaliada utilizando imagens de satélite tomadas ao longo do tempo (WU et al., 2008; TAGHADOSI & HASANLOU, 2017). Recentemente, satélites multiespectrais mais modernos, equipados com sensores de melhor resolução espacial e temporal, como o Sentinel-2A e Sentinel-2B, foram lançados com objetivo de monitorar a superfície terrestre e integrar com dados históricos das missões dos satélites SPOT e Landsat (DA SILVEIRA, 2018; EUROPEAN SPACE AGENCY, 2019).

Os solos salinos podem ser detectados diretamente utilizando-se índices espectrais calculados de imagens multiespectrais nas faixas do visível e do infravermelho próximo do espectro eletromagnético, ou indiretamente nas mudanças na condição de cultivo e perda da produtividade em campos agrícolas (METTERNICHT & ZINCK, 2003; ALLBED & KUMAR, 2013).

Os índices de vegetação são comumente usados para destacar áreas de vegetação e comportamentos espectrais de dosséis (JI-HUA et al., 2008; ALLBED & KUMAR, 2013). A diminuição nos valores de índices de vegetação ao longo do tempo é provocada pela expansão da salinidade e seus efeitos adversos no crescimento das plantas, podendo ser interpretados como degradação do solo e espalhamento de salinidade (METTERNICHT & ZINCK, 2003; DUBOVYK et al., 2013; ALLBED et al., 2014).

Os índices de salinidade permitem identificar áreas de solo exposto, resultantes de processos de degradação do solo (SCHMID et al., 2008), pois representam uma relação direta com a condutividade elétrica do solo (MOREIRA et al., 2016). Além disso, os índices de salinidade realçam os valores de refletância das regiões afetadas por sais no caso de menor vegetação (ALLBED & KUMAR, 2013). Portanto, o aumento nos valores dos índices de salinidade ao longo dos anos representa a salinização (TAGHADOSI & HASANLOU, 2017).

No interior do perímetro irrigado de Maniçoba em Juazeiro da Bahia existem áreas em processo avançado de salinização, que podem ser avaliadas com imagens de satélite e dados de superfície. Uma vez que as cartas temáticas dos parâmetros biofísicos são feitas, os efeitos antropológicos a longo prazo (gestão de recursos hídricos) e naturais (secas e mudanças climáticas) na qualidade do solo podem ser avaliados, comparando as estimativas de sensoriamento remoto com os inventários de salinidade passados. Além disso, o monitoramento das áreas afetadas por sais e a avaliação das mudanças na cobertura do solo, causadas pela

salinização, podem ser abordagens efetivas para adotar medidas preventivas, recuperar solos salinizados e evitar a expansão dos sais nos campos agrícolas. Neste contexto, os objetivos desta pesquisa estão listados abaixo.

1.1. OBJETIVOS

1.1.1. Objetivo geral

Analisar a dinâmica espaço-temporal da salinidade do solo no perímetro irrigado de Maniçoba em Juazeiro-BA, utilizando técnicas de Sensoriamento Remoto em imagens Landsat-8 e Sentinel-2, aplicando índices de salinidade e vegetação em conjunto com dados meteorológicos.

1.1.2. Objetivos específicos

- Aplicar índices de salinidade e de vegetação nas imagens Landsat-8 e Sentinel-2 para identificar, detectar e monitorar solos possivelmente salinos;
- Utilizar a estatística multivariada por meio da técnica de Análise de Componentes Principais (ACP) para avaliar as relações entre a condutividade elétrica do solo com variáveis meteorológicas como temperatura do solo, evapotranspiração, albedo e índices adotados;
- Identificar os melhores índices de salinidade e de vegetação, a partir dos resultados estatísticos, a fim de gerar cartas temáticas e gráficos de tendências da salinidade;
- Avaliar o potencial da integração dos dados climáticos no processo de classificação de áreas afetadas por sais;
- Quantificar e inferir sobre as alterações ocorridas na área de estudo.

2. REVISÃO BIBLIOGRÁFICA

2.1. Bioma Caatinga

A Caatinga engloba uma área superior a 844.453 quilômetros quadrados, o equivalente a 11% do território nacional, englobando os estados de Alagoas, Bahia, Ceará, Maranhão, Paraíba, Pernambuco, Rio Grande do norte, Sergipe e o norte de Minas Gerais (Figura 1). O bioma é considerado uma das 37 grandes regiões naturais do planeta, abrigando uma população superior a 27 milhões de habitantes (MORO et al., 2014; MINISTÉRIO DO MEIO AMBIENTE, 2019).



Figura 1. Distribuição original dos biomas brasileiros.

Fonte: Ministério do Meio Ambiente - MMA (2019).

O nome caatinga tem origem indígena e significa “mata branca e aberta”, sendo classificada como Savana Estépica, e em nível internacional é considerada como Floresta Tropical Sazonalmente Seca (PENNINGTON et al., 2000, PEREIRA FILHO, 2010). Rica em biodiversidade, a caatinga apresenta grande riqueza de ambientes e espécies. Sua fitofisionomia é adaptada ao clima semiárido (precipitação menor que 800 mm), regulada pelas chuvas (BARBOSA et al., 2006) e as altas temperaturas, calor e iluminação resultam em uma vegetação estépica, espinhosa e decidual (PEREIRA FILHO, 2010).

Segundo o Relatório sobre Monitoramento do Bioma Caatinga, realizado pelo Ministério do Meio Ambiente (MMA), em parceria com o Instituto Brasileiro do Meio

Ambiente (IBAMA), baseado na análise de imagens de satélite Landsat-5 e Landsat-7 em 2008 e 2009, observou-se um decréscimo da vegetação remanescente em torno de 0,23 %, ou seja, 1.921,18 km², sendo 300,927 km² somente no estado da Bahia, estado que mais sofreu com o desmatamento (MINISTÉRIO DO MEIO AMBIENTE, 2011).

Os principais fenômenos causadores de degradação estudados neste bioma são a salinidade e a desertificação, decorrentes de manejo inadequado da irrigação, uso de terras com baixo potencial agrícola, ambos têm motivado pesquisas como as de Souza et al. (2000), Moreira et al. (2016), Dourado (2017), Rocha Neto et al. (2017) e Moura Garcia et al. (2019).

2.2. Salinidade do solo

Solos salinos também são conhecidos como sódicos ou halomórficos, caracterizados pela presença de sais solúveis, sódio trocável, ou ambos nas camadas superiores da superfície e desenvolvem-se em condições de drenagem imperfeita (Ribeiro et al., 2016),

Um solo é dito salino quando há presença dos principais solutos inorgânicos na água do solo, bicarbonatos de sódio (Na⁺), cálcio (Ca²⁺) e magnésio (Mg²⁺), em menor quantidade potássio (K⁺), amônio (NH₄⁺), nitratos (NO₃⁻) e carbonatos (CO₃²⁻) (FERREIRA et al., 2016), sendo que no Brasil predominam cloretos e sulfatos de cálcio, magnésio e sódio (FREIRE et al., 2016). Esses compostos químicos são derivados de ciclos passados de intemperismo geológico que foram continuamente depositados em depressões, para onde os sais convergem, em condições de má drenagem, lençol freático alto e baixa permeabilidade (RIBEIRO, 2016).

Convencionalmente a salinidade é medida pela condutividade elétrica (CE), expressa em deciSiemens por metro (dS/m) a 25°C (MOREIRA et al., 2016). Um solo torna-se salino quando esses sais na solução, excedem aproximadamente 2500mg/l e sua condutividade elétrica (CE) do seu extrato é superior a 4 dS/m (WHITE, 2013).

Os sais podem ser originados através de processos primários que ocorrem naturalmente, por meio do intemperismo de rochas e minerais primários que se desenvolveram *in situ*, e foram transportados pela água e vento, que sofrem influência da topografia, ou então, pelo processo secundário, causado pela ação antrópica através da irrigação de má qualidade, uso intensivo de fertilizantes, desmatamento e pastoreio intensivo (RIBEIRO et al., 2009; ALLBED & KUMAR, 2013).

A salinidade do solo pode ser referida como acúmulo de sais solúveis na superfície do solo ou próximo à mesma (SCHOFIELD et al., 2001). Esse acúmulo é mensurado pela

determinação da condutividade elétrica da pasta da solução do solo saturado, pelo potencial de sódio trocável (PST) de 15% e um PH menor que 8,5 (RICHARDS, 1954). Esse método é mais rápido para estimar o total de sais do solo, pois quanto maior a concentração de íons na solução, maior será a condutividade elétrica (FREIRE et al., 2016).

A salinização é um dos principais riscos ambientais para regiões áridas e semiáridas, constitui-se um sério problema nas áreas irrigadas quando sua intensidade interfere diretamente no desenvolvimento das culturas agrícolas, reduzindo a produtividade das plantas a níveis antieconômicos (DE OLIVEIRA, 1997). A salinidade do solo é considerada um dos mais antigos problemas ambientais e um dos sete principais caminhos para a desertificação (KASSAS, 1995), existindo em centenas de países no mundo (KOOHAFKAN, 2012).

Segundo Wu et al. (2014), a partir da década de 1970, muitos pesquisadores obtiveram resultados promissores em estudos da salinidade do solo e suas características espectrais, utilizando o sensoriamento remoto na aplicação de índices de vegetação e de salinidade em diferentes regiões. Como por exemplo Moreira et al. (2016) que avaliaram a salinidade em áreas semiáridas do Nordeste brasileiro ao nível de laboratório e em imagens OLI/Landsat-8 e Hyperion/EO-1.

2.3. Sensoriamento Remoto

Sensoriamento Remoto (SR) pode ser definido como o uso conjunto de sensores, equipamentos para processamento e transmissão de dados, acoplados em satélites, aeronaves, ou outras plataformas, com a finalidade de estudar fenômenos, eventos e processos sob a superfície terrestre a partir do registro e análise das interações entre a radiação eletromagnética e as substâncias que o compõem nas suas mais diversas manifestações (NOVO, 2012).

O SR utiliza a radiação eletromagnética solar (luz solar) que atravessa a atmosfera e é refletida dos alvos sobre a superfície da terra (KHORRAM et al., 2012). A radiação eletromagnética (REM) é o meio por onde os sensores obtêm as informações, a qual é conceituada como uma forma de energia dinâmica que se manifesta através de sua interação com a matéria, que incluem os diferentes recursos naturais, como os solos, a vegetação, as rochas e os corpos hídricos (PONZONI et al., 2012).

O SR é uma importante ferramenta capaz de identificar parâmetros biofísicos que ocorrem na superfície terrestre por meio de imagens orbitais e, relacionar as informações com dados de clima e dados observados na superfície, recebendo destaque no monitoramento ambiental de determinadas áreas (DEVRIES et al., 2015).

Na sua aplicação é possível explorar diferentes escalas de trabalho, as quais são dependentes da natureza do objeto estudado, este é um dos motivos que fazem essa técnica bastante utilizada, pois agrega informações em pequenas e grandes extensões, com diferentes níveis de resoluções espaço-temporais, o que permite acompanhar as mudanças no uso e ocupação do solo em determinadas áreas (SANTOS et al., 2014; PONZONI & SHIMABUKURU, 2012).

O uso de suas técnicas permite analisar culturas florestais e agrícolas, otimizando tempo e recurso (MOREIRA, 2005; WENG, 2010; PONZONI et al., 2012). Além disso, combinada ao geoprocessamento, o SR é considerado uma abordagem eficaz para extrair informações a partir de imagens, processando grandes quantidades de dados para monitorar as mudanças de solos afetados por saís (FUSHITA et al., 2013; TAGHADOSI & HASANLOU, 2017).

2.4. Sistema de satélites Landsat

O sistema Landsat (*Land Remote Sensing Satellite*) foi desenvolvido pela NASA (*National Aeronautics and Space Administration*) no final da década de 1960 com o objetivo de permitir a aquisição de dados espaciais, espectrais e temporais da superfície terrestre, de forma global, sinóptica e objetiva, para estudar os recursos naturais renováveis e não renováveis (ROSA, 2007; ALVARENGA & MORAES, 2014).

O programa Landsat contou com o lançamento de 8 satélites, partindo de 1972 (ERTS Landsat-1), 1975 (Landsat-2), 1978 (Landsat-3), 1982 (Landsat-4), 1984 (Landsat-5), 1993 (Landsat-6), 1999 (Landsat-7) e 2013 (Landsat-8), dos quais, opera atualmente o Landsat-8, o mais moderno da família (ALVARENGA & MORAES, 2014). O Landsat-7 disponibilizou informações de qualidade somente até 31 de maio de 2003, e suas características são similares ao seu antecessor Landsat-5 (ENGESAT, 2018).

O Landsat-8 opera a uma altitude de 705 km, inclinação de 98,2° em relação ao plano do equador, apresentando dois sensores a bordo, o OLI (*Operational Land Imager*) e o TIRS (*Thermal Infrared Sensor*). Semelhante às órbitas das séries Landsat-5 e 7, sua passagem na linha do equador ocorre às 10 h, sua cobertura de imagens recobre todo o globo, com exceção para altas latitudes polares (COELHO & CORREA, 2013; ALVARENGA & MORAES, 2014).

Os produtos desses satélites podem ser obtidos gratuitamente através do Serviço Geológico dos Estados Unidos (USGS, sigla em inglês), na página eletrônica <https://landsat.usgs.gov/> ou pelo catálogo de imagens do Instituto Nacional de Pesquisas

Espaciais (INPE) (<http://www.dgi.inpe.br/>). Além disso, as cenas também estão disponíveis no EarthExplorer, GloVis e LandsatLook Viewer em até 24 h após aquisição.

As principais informações dos satélites da série Landsat constam no Tabela 1, e as características do sensor OLI e TIRS na Tabela 2.

Tabela 1. Características da série de satélites Landsat.

Missão Land Remote Sensing Satellite (Landsat)			
País/Região	Estados Unidos		
Satélite	LANDSAT-5	LANDSAT-7	LANDSAT-8
Lançamento	01/03/1984	15/04/1999	11/02/2013
Situação atual	Inativo (22/11/2011)	Ativo (Interrompido no Brasil em 31/05/2003)	Ativo
Órbita	Quase-Polar, Heliossíncrona	Quase-Polar, Heliossíncrona	Circular, Polar, Heliossíncrona
Altitude	705 km	705 km	705 km
Inclinação	98,20°	98,20°	98,20°
Tempo de duração da órbita	99 min	98,9 min	99 min
Resolução temporal	16 dias	16 dias	16 dias
Resolução radiométrica	8 bits	8 bits	12 bits
Resolução espectral	7 bandas	8 bandas	11 bandas
Resolução espacial	30 metros	30 metros	30/15 metros
Instrumentos/sensor	TM (Thematic Mapper)	ETM+ (Enhanced Thematic Mapper Plus)	OLI (Operational Land Imager) e TIRS (Thermal Infrared Sensor)

Fonte: Adaptado de Embrapa Monitoramento por Satélite (2013).

Tabela 2. Característica espectral e resolução espacial sensores OLI e TIRS/ Landsat-8.

Banda	Comprimento de onda (nm)	Resolução espacial (m)
1 – Aerossol Costeiro	443 – 450	30
2 – Azul	450 - 510	30
3 – Verde	530 - 590	30
4 - Vermelho	640 - 670	30
5 - Infravermelho próximo	850 - 880	30
6 – Infravermelho onda curta 1	1570 - 1650	30
7 – Infravermelho onda curta 2	2110 - 2290	30
8 – Pancromática	500 - 680	15
9 - Cirrus	1360 - 1380	30
10 – Infravermelho termal 1	1060 - 11190	100 (reamostrado para 30)
11 - Infravermelho termal 2	11500 - 12510	100 (reamostrado para 30)

Fonte: Adaptado de Embrapa Monitoramento por Satélite (2013).

2.5. Sentinel-2

Sentinel-2 compreende uma constelação de dois satélites multiespectrais de órbita polar e altitude de 786 km, dispostos 180° entre si, de maneira síncrona ao Sol. Esse satélite possui ampla faixa de imageamento (largura de 290 km) e alto tempo de revisitação (10 dias no equador com um satélite e 5 dias com dois satélites). O Sentinel-2 objetiva monitorar as mudanças na superfície do planeta Terra com limite de cobertura entre latitudes 56° sul e 84° norte (EUROPEAN SPACE AGENCY, 2019).

Ambos satélites formam uma missão imageadora multiespectral da GMES (*Global Monitoring for Environment and Security*), em iniciativa conjunta entre a União Europeia (UE) e a Agência Espacial Europeia (ESA) para observação da Terra, realizando coleta de dados precisos da vegetação, solos, corpos hídricos, áreas costeiras, informações para correção atmosférica, além de garantir a segurança civil. Essas informações são gratuitas e compatíveis com os dados fornecidos pelos programas SPOT (*Système Pour l’Observation de la Terre*) e família Landsat (ENGESAT, 2019).

O programa é considerado um dos mais ambiciosos de observação terrestre, composto por três componentes, sendo o primeiro *in situ*, que realiza coletas de dados locais; o segundo serviço gera e disponibiliza dados para uso de políticas públicas, gestão de emergências e segurança pública; e o terceiro é o componente espacial, que engloba cerca de 40 missões de satélites, incluindo a família Sentinel, composta pelas missões Sentinel-1, Sentinel-2, Sentinel-

3, Sentinel-4 e Sentinel-5, cada uma com características próprias (ASCHBACHER & MILAGRO PÉREZ, 2012).

A missão Sentinel-2 opera com dois satélites idênticos de forma simultânea, ocupando a mesma órbita, síncrona ao Sol com inclinação de 98,62°, a fim de obter melhor iluminação solar, menor cobertura de nuvens e similaridade dos dados (EUROPEAN SPACE AGENCY, 2019). Ambos os satélites Sentinel-2 (2A e 2B) são equipados com o Instrumento multiespectral (*Multispectral instrument* - MSI), cuja características são mostradas na Tabela 3.

Tabela 3. Características do sensor MSI/Sentinel-2A/2B.

Banda	Centro da banda (nm)	Largura da banda (nm)	Resolução espacial (m)
1 – Aerossol costeiro	443	21	60
2 – Azul	490	66	10
3 - Verde	560	36	10
4 - Vermelho	665	31	10
5 – Vermelho próximo	705	15	20
6 - Vermelho próximo	740	15	20
7 - Vermelho próximo	783	20	20
8 - Infravermelho próximo	842	106	10
8A - Vermelho próximo	865	21	20
9 - Vapor de água	945	20	60
10 - Infravermelho de onda curta - Cirrus	1375	31	60
11 - Infravermelho de onda curta	1610	91	20
12 - Infravermelho de onda curta	2190	175	20

Fonte: European Space Agency (2019).

As 13 bandas espectrais cobrem as regiões do visível (VIS) e infravermelho próximo (NIR) ao infravermelho de onda curta (SWIR). Quatro bandas com resolução espacial de 10 m, três bandas RGB clássicas ((azul (~ 493nm), verde (560nm) e vermelho (~ 665nm)) e uma banda de infravermelho próximo (~ 833nm); seis bandas com 20 m de resolução do infravermelho próximo (~ 704nm, ~ 740nm, ~ 783nm e ~ 865nm) e 2 bandas infravermelho de ondas curtas (~ 1610nm e ~ 2190nm), para aplicações como neve / gelo / detecção de nuvens ou avaliação do estresse de umidade da vegetação; e três bandas de resolução espacial de 60 m, são dedicadas para correções atmosféricas (~ 443nm para aerossóis e ~ 945nm para vapor de água) e detecção de cirros (~ 1374nm) (EUROPEAN SPACE AGENCY, 2019).

Outra característica importante do sensor MSI é a resolução radiométrica, que é a capacidade do instrumento em distinguir diferenças na intensidade ou refletância da luz. Assim, quanto maior a resolução, mais precisa será a imagem. Logo, a resolução radiométrica do instrumento MSI é de 12 bits, o permite que a imagem seja adquirida em uma faixa de 0 a 4095 valores potenciais de intensidade de luz (EUROPEAN SPACE AGENCY, 2019).

Os produtos do Sentinel-2 podem ser adquiridos gratuitamente na página oficial do USGS, através do endereço eletrônico <https://earthexplorer.usgs.gov/>, e na página oficial da Agência Espacial Europeia (ESA) pelo endereço eletrônico <https://sentinel.esa.int/web/sentinel/home>. A parceria entre ESA e USGS permite distribuir dados de refletância de nível superior da atmosfera (TOA) de nível 1C com uma projeção e referência UTM / WGS84 (*Universal Transverse Mercator / World Geodetic System 1984*), que inclui produtos com correção radiométrica e geométrica, juntamente com a ortorretificação para gerar imagens altamente precisas (EUROPEAN SPACE AGENCY, 2019; UNITED STATES GEOLOGICAL SURVEY, 2019).

2.6. Correção Atmosférica Subtração de Pixel Escuro (DOS1)

A aquisição de dados da superfície terrestre por meio de instrumentos de sensoriamento remoto aerotransportados é feita considerando a distância entre sensor e objetos, esses dados têm o objetivo de caracterizar os alvos por meio de detecção, registro e análise do fluxo de radiação emitido ou recebido por eles. Entretanto, essas informações que chegam ao sensor podem apresentar limitações devido à grande influência da atmosfera na energia refletida pelos alvos (BORENGASSER et al., 2008).

No processamento de imagens orbitais a correção dos efeitos causados pela atmosfera é indispensável, pois as faixas do comprimento de onda do visível são altamente afetadas pela dispersão atmosférica, principalmente pelo efeito Rayleigh, que produz um espalhamento atribuído aos gases suspensos, aerossóis e vapor d'água (MUSTAK, 2013).

A correção dos efeitos atmosféricos pode ser realizada pelo método de Correção Atmosférica por Pixel Escuro (*Dark Object Subtraction – DOS1*), que em toda e qualquer cena e em qualquer banda espectral, existem pixels que deveriam admitir o valor zero, seja nas imagens com números digitais (NDs) originais ou naquelas já convertidas para Fator de Refletância Bidirecional Aparente (FRB). Portanto, esses pixels (sombras na região do visível, por exemplo) não podem refletir radiação, podendo também absorvê-la totalmente, o que implicaria em valores nulos de reflexão (corpos d'água límpidos na faixa do infravermelho

próximo e médio). Caso esses pixels apresentem valores de NDs ou FRB aparente maiores que zero, o valor excedente deveria ser explicado pela interferência aditiva do espalhamento atmosférico (CHAVEZ, 1988).

O método de correção DOS1 é considerado como um procedimento simples que objetiva identificar, em cada banda espectral da imagem a quantidade de NDs que deveriam ser subtraídas de cada imagem como um todo, considerando que a interferência da atmosfera é uniforme ao longo de toda a cena (PONZONI et al., 2012).

A Figura 2 demonstra uma comparação entre a refletância do topo da atmosfera (TOA), a refletância corrigida por DOS1 e os dados de refletância de superfície do Landsat (verdade do solo) nas assinaturas espectrais de um pixel.

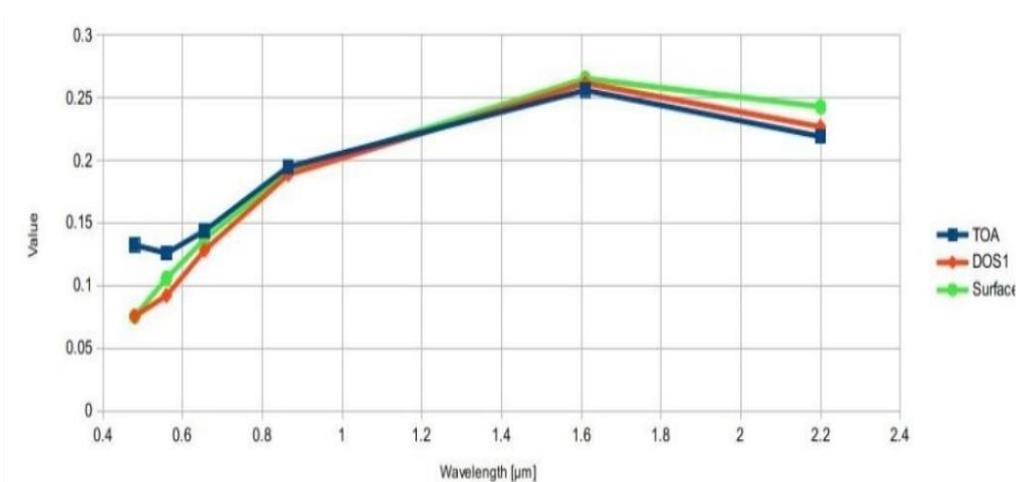


Figura 2. Comparação da assinatura espectral de um mesmo pixel com correção DOS1, refletância do topo da atmosfera e em números digitais.

Fonte: (CONGEDO, 2020).

2.7. Índices de vegetação

Índices de vegetação têm por objetivo explorar as propriedades espectrais da vegetação, principalmente as regiões do vermelho e do infravermelho próximo do espectro eletromagnético. Esses índices relacionam-se a parâmetros biofísicos da cobertura vegetal, biomassa, arquitetura do dossel e índice de área foliar (PONZONI et al., 2012).

As estimativas dos índices de vegetação feita com dados de refletâncias de satélite são importantes parâmetros para o monitoramento de alterações naturais ou antrópicas dentro dos ecossistemas, o que permite identificar a vegetação verde na superfície, determinar a sua distribuição espacial e seus comportamentos (DEMARCHI et al., 2011; RIBEIRO et al., 2016).

Esses índices baseiam-se nas interações entre a radiação eletromagnética e aspectos biofísicos das folhas, onde a baixa reflexão na região do visível decorre da absorção pela ação dos pigmentos fotossintetizantes (clorofila, xantofilas e carotenos), enquanto que a alta refletância na região do infravermelho próximo decorre do espalhamento (transmitância e refletância) da radiação dentro das estruturas internas das folhas como também, da composição química e quantidade de água no interior celular (PONZONI et al., 2012).

A formulação desses índices parte do comportamento antagônico da refletância entre a região vermelho e infravermelho próximo, onde no estudo da vegetação a principal banda de absorção, causada pela ação de pigmentos fotossintetizantes, está situada na região visível de luz vermelha (650nm) e a região de maior refletância, decorre do espalhamento no interior das folhas, região infravermelho próximo entre (760nm a 900nm) (PONZONI et al., 2012).

A razão de banda vermelha pela banda infravermelho próximo resultará em pixels situados nas áreas com vegetação em valores bem maiores do que 1, em contrapartida, alvos como água, sombra de nuvens terão valores abaixo de 1, resultando em pixels mais claros para áreas vegetadas e pixels mais escuros para não vegetadas (MENESES & ALMEIDA, 2012).

Os índices de vegetação são aplicados através de cálculos que envolvem refletâncias em regiões específicas do espectro eletromagnético, em princípio, quanto maior a densidade da cobertura vegetal, menor será a refletância na região visível e maior será a refletância na região do infravermelho próximo (NOVO, 2010). Nesses índices os menores valores da refletância no visível e maiores valores refletidos na região do infravermelho próximo geralmente indica uma vegetação mais saudável (JENSEN, 2011).

2.7.1. NDVI

Índice de Vegetação da Diferença Normalizada (*Normalized Difference Vegetation Index* – NDVI) é amplamente utilizado em estudos climáticos, agrícolas e florestais, sendo um parâmetro de monitoramento da vegetação, para construção de perfis sazonais e temporais das atividades da vegetação, permitindo, ainda, comparações interanuais desses perfis (PONZONI et al., 2012).

O NDVI foi proposto por Rouse et al. (1974) sendo obtido através da normalização da razão simples entre a diferença das refletâncias do infravermelho próximo (ρ_{NIR}) e do vermelho (ρ_R), pela soma das mesmas (ALLEN et al., 2002), conforme Equação 1.

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

Em que: ρ_{NIR} e ρ_R são respectivamente a refletância das bandas do infravermelho próximo e vermelho.

O NDVI é um indicador sensível da quantidade e condição da vegetação, apresentando valores que variam de -1 a +1, onde os valores positivos são obtidos em áreas de cobertura vegetal, variando para mais ou menos de acordo com a atividade fotossintética e densidade de plantas, enquanto que em áreas de superfície com água ou nuvens, o índice geralmente tende a ser menor que zero (ROUSE et al., 1974).

2.7.2. SAVI

Índice de Vegetação Ajustado ao Solo (*Soil Adjusted Vegetation Index* – SAVI), proposto por Huete (1988), que verificou que a maior sensibilidade nos índices de vegetação em relação ao solo ocorre em dosséis em níveis médios de cobertura vegetal. Quando o valor do SAVI se torna baixo, indica que a vegetação diminuiu com o tempo, e quando gera um valor positivo, indica um aumento da vegetação, já quando o valor de SAVI é zero, nenhuma mudança ocorreu na vegetação.

O SAVI considera os efeitos do solo nas imagens analisadas, introduzindo uma constante “L” que tem a função de amenizar os efeitos do solo no resultado final do índice, de acordo com a Equação 2.

$$SAVI = \frac{(\rho_{NIR} - \rho_R)}{(\rho_{NIR} + \rho_R + L)} \times (1 + L) \quad (2)$$

Em que: ρ_{NIR} e ρ_R são respectivamente a refletância do infravermelho próximo e vermelho; L - fator de ajuste do índice, podendo assumir valores de 1,0, 0,5 ou 0,25, sendo 0,25 para vegetação com baixa densidade, 0,5 média densidade e 1,0 vegetação densa. Recomenda-se utilizar L=0,5.

2.7.3. EVI

O Índice de Vegetação Melhorado (*Enhanced Vegetation Index* – EVI) foi desenvolvido visando otimizar o sinal da vegetação pela maior sensibilidade de detecção em regiões com maiores densidades de biomassa, e também para reduzir a influência do solo e da atmosfera sobre a resposta do dossel (HUETE et al., 1997; JUSTICE et al., 1998).

O EVI é uma variação aprimorada do NDVI que utiliza fatores de ajustes juntamente com a refletância da banda azul para corrigir a influência da atmosfera e do solo, este último mais acentuado no ambiente semiárido (HUETE et al., 1997). A inclusão da banda azul somadas às constantes, tornou o EVI sensível para discriminar variações da estrutura do dossel. O EVI é calculado por meio da Equação 3.

$$EVI = \frac{G \times (\rho_{NIR} - \rho_R)}{(1 + \rho_{NIR} + C1 \times \rho_R - C2 \times \rho_B)} \quad (3)$$

Em que: ρ_{NIR} , ρ_R e ρ_B são respectivamente as bandas do infravermelho próximo, vermelho e azul; G - fator de ganho; C1 e C2 - coeficientes de ajuste para efeito de aerossóis da atmosfera. O valor 1,0 representa o fator de ajuste para o solo. Os valores dos coeficientes usados pelo EVI são: C1= 6,0, C2=7,5 e G=2,5 (HUETE et al., 1997; JUSTICE et al., 1998).

2.7.4. GDVI

Índice de Vegetação da Diferença Generalizada (*Generalized Vegetation Difference Index* – GDVI), foi desenvolvido por WU (2014). Quando n é igual a 2 o GDVI é melhor relacionado com IAF (Índice de Área Foliar) em todos os biomas, porém, quando n assume valores elevados, ou seja, 3 ou 4, torna-se saturado e insensível para áreas cultivadas e vegetações densas.

Quando n = 1, GDVI = NDVI, sendo assim, o índice GDVI é relevante para caracterizar biomas secos como o semiárido, onde a vegetação é normalmente pouco densa e espaçada. O GDVI é calculado por meio da Equação 4.

$$GDVI = \frac{\rho_{NIR}^n - \rho_R^n}{\rho_{NIR}^n + \rho_R^n}, \quad \text{para } n = 2 \quad (4)$$

Em que: ρ_{NIR} e ρ_R são respectivamente as bandas do infravermelho próximo e vermelho; n - o número de potência, diferente de 0 e 1.

2.8. Índices de salinidade

Diversos índices de salinidade e de vegetação foram desenvolvidos para identificar e monitorar áreas afetadas por sais (ALLBED & KUMAR, 2013; ALLBED et al., 2014; SATIR & BERBEROGLU, 2016; GORJI et al., 2017; IVUSHKIN et al., 2017).

Os solos salinos podem ser diretamente detectados pelas altas refletâncias de solos expostos nas regiões do visível e infravermelho próximo das imagens multiespectrais, como também, podem ser detectados indiretamente através da redução da vegetação e perda da produtividade em terras agrícolas (METTERNICHT & ZINCK, 2003; ALLBED & KUMAR, 2013). Ambos devem ser considerados na avaliação multitemporal das mudanças de salinidade no solo, principalmente em grandes escalas (TAGHADOSI & HASANLOU, 2017).

Os índices de salinidade funcionam de forma diferente dos índices de vegetação, por apresentarem forte refletância na região do visível e no infravermelho próximo (SCHMID et al., 2008), devido a ocorrência de solo exposto, crostas salinas, vegetação insalubre, pouco densa e com baixa quantidade de folhas por área, enquanto a vegetação saudável tem baixa refletância na região do visível, decorrente da fotossíntese, e maior refletância no infravermelho próximo. Devido a essas características, os índices espectrais de salinidade foram desenvolvidos para detectar e mapear depósitos de sais minerais (ALLBED & KUMAR, 2013).

Os índices de salinidade realçam os valores de refletância espectral das áreas salinas quando nesses locais há menor cobertura vegetal, assim, o acréscimo nos valores dos índices de salinidade no decorrer dos anos de estudo representa a salinização de terras de solo exposto (TAGHADOSI & HASANLOU, 2017).

A detecção remota de solos afetados por sais pode ser dificultada por fatores como a distribuição de sais na superfície do solo, dos variados tipos de sais, das variações espaciais e da associação com outras propriedades do solo, tais como granulometria, umidade, matéria orgânica, cor e rugosidade (METTERNICKT & ZINCK, 2008).

Existem limitações no uso de índices de salinidade por meio de imagens orbitais, quando não há formação de crosta salina visível na superfície do solo e quando surge vegetação halófitas sobre o solo, o que dificulta a abordagem direta produzindo resultados pouco confiáveis (WANG et al., 2013).

Diversas combinações espectrais são destacadas na literatura e utilizadas como índices para o mapeamento de solos salinos (KHAN & ABBAS, 2007; BOUAZIZ et al., 2011; ALLBED et al., 2014; TAGHADOSI & HASANLOU, 2017). Dentre os índices de salinidade destacam-se o SI-1, SI-2, SI-3 propostos por Douaoui et al. (2006) para avaliar a salinidade do solo, baseadas nos dados do SPOT2, e índice de brilho (IB) proposto por Khan et al. (2001) em imagens do satélite de Sensoriamento Remoto Indiano (IRS-1B).

Esses índices variam de 0 a 1, onde os valores dos números digitais (NDs), convertidos em valores físicos reais, representam a refletância de acordo com a superfície analisada, quanto mais próximo de zero (menor refletância), representa superfícies como corpos hídricos, vegetação, áreas úmidas e sombras de nuvens, e quanto mais próximo de 1 (maior refletância), representa solos expostos, rochas, área urbana e nuvens.

2.8.1. SI-1

Índice de Salinidade SI-1 desenvolvido por Douaoui et al. (2006) é comumente utilizado para estudos de pixels de solos descobertos, como indicador indireto da salinidade (BOUAZIZ et al., 2011; ALLBED & KUMAR, 2014; GORJI et al., 2017). Sua formulação baseia-se na interação entre a raiz do produto entre as bandas verde e vermelho (Equação 5).

$$SI1 = \sqrt{\rho G \times \rho R} \quad (5)$$

Em que: ρR e ρG são respectivamente as refletâncias da banda vermelha e verde.

2.8.2. SI-2

Índice de Salinidade SI-2 foi desenvolvido por Douaoui et al. (2006). O SI-2 é utilizado em análises ambientais de solos salinizados (DOUAOUI et al., 2006; ALLBED & KUMAR, 2014; MORSHED et al., 2016) (Equação 6).

$$SI2 = \sqrt{\rho G^2 + \rho R^2 + \rho NIR^2} \quad (6)$$

Em que: ρNIR , ρR e ρG são respectivamente as refletâncias das bandas infravermelho próximo, vermelho e verde.

2.8.3. SI-3

O índice de salinidade SI-3 foi utilizado por autores como DOUAOUI et al. (2006), BOUAZIZ et al. (2011) e ALLBED et al. (2014), os quais concluíram que o SI-3 se assemelha ao SI-1 e diferencia-se do SI-2. O SI-3 consta na Equação 7.

$$SI3 = \sqrt{\rho G^2 + \rho R^2} \quad (7)$$

Em que: ρR e ρG são respectivamente as refletâncias da banda vermelho e verde.

2.8.4. Índice de brilho - IB

Khan et al. (2001) propuseram o IB pelas combinações de bandas espectrais para discernir padrões de superfícies afetadas por sais. O IB é um índice também muito recorrente em pesquisas voltadas em diagnósticos de solos salinos e áreas urbanizadas (DOUAOUI et al., 2006; ALLBED & KUMAR, 2014; MORSHED et al., 2016; TAGHADOSI & HASANLOU, 2017), sua formulação é representada pela Equação 8.

$$IB = \sqrt{\rho R^2 + \rho NIR^2} \quad (8)$$

Em que: ρNIR e ρR são respectivamente as refletâncias da banda infravermelho e vermelho.

2.9. Evapotranspiração real pelo método do SEBAL

A evapotranspiração (ETR) é referida como a combinação de processos nos quais a água é perdida para a atmosfera devido a evaporação direta da água, da água do solo e a transpiração da vegetação (ALLEN et al., 2002; PACHECO et al., 2014). As trocas de energia entre a interface dinâmica solo-vegetação-atmosfera são dadas pelos componentes do saldo de radiação (R_n), dos fluxos de calor no solo (G), sensível (H) e latente (LE). O estudo da ETR é essencial para a gestão de bacias hidrográficas, para o manejo hídrico adequado da agricultura irrigada e em estudos meteorológicas (MACHADO et al., 2014).

O cálculo da ETR pode ser obtido de maneira precisa, por meio de lisímetros de pesagem, por técnicas de correlação por redemoinho e pela técnica da razão de Bowen. Tais métodos são limitados a valores locais de evapotranspiração, não sendo possível estimar em

escala regional (ALLEN et al., 2002; SANTOS, 2010). Essa limitação pode ser resolvida utilizando dados de imagens de satélite e técnicas de sensoriamento remoto, de forma rápida, eficiente e baixo custo (MACHADO et al., 2014).

Segundo Allen et al. (2002) o SR tem grande potencial para melhorar a gestão da água, fornecendo estimativas de ETR para grandes superfícies, usando poucos dados do solo, dessa forma desenvolveu o SEBAL (*Surface Energy Balance Algorithm for Land*), algoritmo que pode ser aplicado as imagens de satélite equipados com sensores que disponham de imagens nas bandas termais, a exemplo dos AVHRR – NOAA, MODIS – TERRA/AQUA, ASTER – TERRA e sensores do TM Landsat-7 e 8 (DA SILVA, 2016).

Este algoritmo tem sido muito utilizado por requerer apenas imagens digitais de sensores capazes de determinar o albedo da superfície, índices de vegetação e temperatura da superfície, fornecendo poucos dados meteorológicos da superfície (ALLEN et al., 2002).

A Organização das Nações Unidas para Agricultura e Alimentação (*Food and Agriculture Organization of the United Nations - FAO*) adota o modelo parametrizado da equação de Penman-Monteith como padrão para determinação da evapotranspiração de referência (PEREIRA et al., 2013), que pode ser comparada ao método SEBAL (MACHADO et al., 2014).

2.10. Classificação digital de imagens

Muito utilizado no sensoriamento remoto, a classificação é um processo automático para extração de informações a partir de imagens. Tem como objetivo reconhecer padrões e objetos homogêneos na superfície, associando cada pixel da imagem em temas de interesse (DEMARCHI et al., 2011).

Estas ferramentas estão implementadas em softwares de processamento de imagens orbitais comerciais e gratuitos, que utilizam esses algoritmos classificadores na forma supervisionada e não supervisionada (NASCIMENTO et al., 2016). A primeira é caracterizada pela predeterminação dos alvos a partir da delimitação de áreas de treinamento pelo operador, e a segunda por não requerer informações prévias e utilizar um algoritmo que agrupa os pixels de acordo com comportamento espectral (RODRIGUES et al., 2016).

2.10.1. Classificador Máxima Verossimilhança

O classificador de máxima verossimilhança (*Maximum Likelihood* - MaxVer) leva em consideração a ponderação das distâncias entre as médias dos valores dos pixels das classes definidas, utilizando parâmetros estatísticos (FRANÇA et al., 2010). O MaxVer é um classificador tido como mais eficiente, pois as classes de treinamento são utilizadas para estimar a distribuição dos pixels contidos em cada classe no espaço de n bandas espectrais, como também a localização do centro de cada classe (MENESES & SANO, 2012).

Essa classificação é de ampla aceitação, considerando a ponderação das distâncias entre os pixels e as médias dos níveis das classes, utilizando parâmetros estatísticos (RIBEIRO & CENTENO, 2001). Além disso, o MaxVer apresenta maior acurácia e melhora significativa quando avaliado o coeficiente Kappa (índice de concordância entre os valores observados e preditos) para toda a faixa de amostras de treinamento (DOURADO, 2017).

2.10.2. Índice Kappa

A eficiência dos classificadores automáticos deve ser avaliada quanto a sua precisão em que a partir da matriz de confusão estima-se o índice Kappa (Equação 9). Este método é recomendado por considerar a concordância e análise dos erros de comissão e omissão obtidas pelos cruzamentos dos dados (BIAS et al., 2012; MENESES & SANO, 2012).

$$K = \frac{n \cdot \sum_{i=1}^c x_{ii} - \sum_{i=1}^c x_{i+} x_{+i}}{n^2 - \sum_{i=1}^c x_{i+} x_{+i}} \quad (9)$$

Em que: K - estimativa do Coeficiente Kappa; x_{ii} - valor da linha i e coluna i; x_{i+} - soma da linha i com x_{+i} com a soma da coluna i da matriz de confusão; n - número total de amostra; c - número total de classes.

O Índice Kappa é um dos mais recomendados, pois utiliza todas as células da matriz e não apenas as células da diagonal principal, sendo mais sensível aos erros de omissão ou comissão, o que garante uma maior precisão e acurácia em relação a outros métodos (DEMARCHI et al., 2011).

A determinação da qualidade da classificação pode ser observada de acordo com desempenho do índice Kappa nos critérios estabelecidos por Landis & Koch (1977) (Tabela 4).

Tabela 4. Índice Kappa associado a qualidade da classificação

Valor de Kappa	Qualidade da classificação
$\leq 0,00$	Péssima
0,00 - 0,20	Ruim
0,20 - 0,40	Razoável
0,40 - 0,60	Bom
0,60 - 0,80	Muito bom
0,80 - 1,00	Excelente

Fonte: Landis e Koch (1977).

2.11. Análise de Componente Principal

A Análise de Componentes Principais (ACP) é uma formulação matemática (estatística multivariada) utilizada para reduzir a dimensão de dados (HARDLE & SIMAR, 2007; ARAÚJO & COELHO, 2009). A ACP é considerada um método fatorial, em que a ideia central é reduzir a dimensionalidade de um grande conjunto de dados que compreende um amplo número de variáveis inter-relacionadas, construindo novas variáveis obtidas pela combinação linear das variáveis iniciais, conservando ao máximo a variação presente no conjunto de dados (KAISER, 1958; JOLLIFFE, 2002).

Essa técnica permite identificar padrões nos dados e suas expressões, enfatizando as semelhanças e diferenças, transformando em um novo conjunto de variáveis, chamadas de componentes principais (CPs), que não se correlacionam e são ordenados de forma que os primeiros retenham a maior parte da variação contida em todas variáveis originais (JOLLIFFE, 2002) sem muita perda de informações (ARAÚJO & COELHO, 2009).

O objetivo é condensar a informação contida nas variáveis originais em um conjunto reduzido e explicar a estrutura da variância e covariância dos dados, por meio de transformação linear de um grupo de variáveis correlacionadas, resultando em combinações (CPs), em que p-variáveis resultam em p-componentes (HARDLE & SIMAR, 2007).

O número de componentes principais é igual ao número de variáveis analisadas, mas as primeiras componentes são as mais importantes, pois explicam a maior parte da variação total. As CPs são geralmente extraídas por meio da criação de matrizes de covariâncias e também de correlação (JOHNSON & WICHERN, 2007).

Os principais resultados estatísticos da ACP são: Autovalores, em que determina o número de componentes principais utilizadas. Segundo o critério de KAISER (1958) usa-se as CPs com os autovalores maiores que 1; a Proporção, determina quais CPs explicam a maioria

da variabilidade dos dados. Quanto maior, mais explicação contida em determinada componente; a Proporção Acumulada determina o número de CPs a serem usadas, as quais explicam um nível aceitável de variância; os Autovetores são compostos pelos coeficientes que correspondem a cada variável usados para calcular os escores dos principais componentes. Assim, quanto maior o valor absoluto do coeficiente, mais importante será a variável correspondente (MINITAB LLC, 2019).

Os modelos estatísticos tradicionais não conseguem investigar a influência de mais de um conjunto de duas variáveis, no entanto, a aplicação da estatística multivariada permite explicar essas influências em conjuntos muito superiores de variáveis envolvidas (MACCIOTTA et al., 2012).

3. MATERIAL E MÉTODOS

3.1. Caracterização da área de estudo

O estudo foi realizado em três propriedades particulares situadas dentro do perímetro irrigado de Maniçoba, latitude 9°19'20.34"S e longitude 40°17'39.25"O, principal projeto de irrigação e fruticultura do município de Juazeiro-BA. O projeto Maniçoba teve seu início no ano de 1980 e atualmente possui uma área total irrigável de 8.542,31 hectares, distribuídos entre 242 lotes familiares e 48 lotes empresariais (CODEVASF, 2019; DIM, 2019) (Figura 3).

De acordo com informações do censo demográfico de 2010, realizado e divulgado pelo Instituto Brasileiro de Geografia e Estatística (IBGE), o município de Juazeiro possui 197.965 habitantes, considerada a sétima cidade mais populosa do estado da Bahia, representa o 12° PIB do Estado e Índice de Desenvolvimento Humano Municipal (IDHM) de 0,677 (IBGE, 2019).

A água para irrigação do projeto é captada diretamente no rio São Francisco e distribuída por três estações de bombeamento através de 156 km de canais em todo perímetro. A outorga de uso de água é de caráter coletivo, sendo administrada pelo Distrito de Irrigação de Maniçoba (DIM), que atende os lotes familiares e empresariais, os quais cultivam manga, uva, melão, coco e cana-de-açúcar, direcionados principalmente para o mercado externo (CODEVASF, 2019).

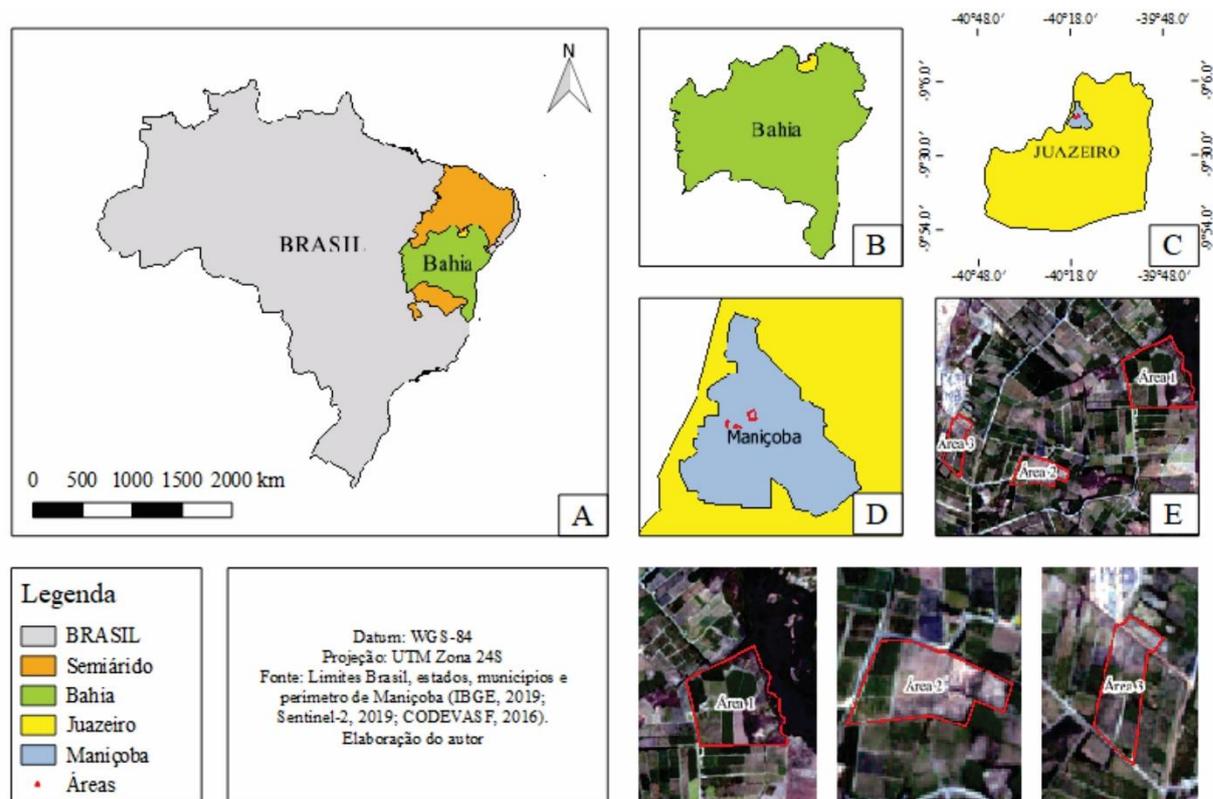


Figura 3. Localização da área de estudo: (A) Brasil e semiárido; (B) Bahia; (C) município de Juazeiro; (D) Perímetro de Irrigação de Maniçoba e (E) Lotes agrícolas estudados.

O município de Juazeiro está inserido na região do Vale do Submédio São Francisco, que abrange uma área de 110.445 km² e, segundo a classificação de Köppen a região apresenta clima BSw'h' (semiárido quente e seco), com elevadas temperaturas (médias de 26,5°C) e valores médios de evapotranspiração de 1.550 mm/ano (MOURA et al., 2006; PINHEIRO et al., 2015). A precipitação pluviométrica média anual é na ordem de 400 a 600 mm, sendo distribuída de forma irregular entre os meses de novembro e março, correspondendo a 90% do total anual, e umidade relativa média anual de 66% (CUNHA, et al., 2008; INMET, 2019).

Os solos são classificados como Argissolo Vermelho-Amarelo, Cambissolo Háplico, Latossolo Amarelo, Luvisolo Cremico, Neossolo Litelico, Planossolo Heplico e Vertissolo Cromado (IBGE, 2001). Apresenta solos de textura arenosa média a argilosa, relevo com declividade inferior a 6 %, plano e levemente ondulado, com vales abertos e altitude entre 200 a 800m (CUNHA et al., 2008; NASCIMENTO et al., 2012), contudo, no perímetro irrigado, o relevo é plano e sua quase totalidade.

A região está sob o domínio do bioma caatinga, caracterizada pela presença de mosaicos de árvores e arbustos espinhosos, de cascas grossas, xerófitas (vivem em regiões semiáridas e desérticas), caducifólias (perdem folhas em períodos de secas), com plantas suculentas,

herbáceas e extrato estacional com poucas folhas largas (PEREIRA FILHO, 2010; MINISTÉRIO DO MEIO AMBIENTE, 2019). Quando bem conservada apresenta grande diversidade em sua cobertura vegetal, que é determinada pelo clima, relevo e embasamento geológico, resultado das múltiplas inter-relações que remetem a paisagens diversas e elevado grau de endemismo (RODAL et al., 2008).

3.2. Seleção e descrição das áreas de estudo

A seleção das áreas iniciou-se a partir de consultas aos moradores locais, os quais relataram conhecer lotes com grandes superfícies com problemas de salinidade, nas quais seus proprietários ou posseiros não obtiveram êxito na implantação agrícola e que em muitos casos, houve abandono dessas áreas.

Partindo dessas informações, visitas pontuais foram marcadas para visualização e registro fotográfico, no intuito de identificar focos e tendências de salinidade do solo, adotando critérios como: ausência de vegetação nativa e agrícola (Figura 4A e 4B), espécies halófitas indicadoras (Figura 4C), fitossanidade da vegetação existente (Figura 4D), solos escuros, desestruturados (Figura 4E) e de crostas de sal sobre a superfície (Figura 4F).



Figura 4. Ausência de vegetação nativa e agrícola (A); coqueiros mortos (B); herbáceas halófitas (*Sesuvium portulacastrum* (L.) L.) (C); indivíduos mortos pela salinidade (D); solo escuro e desestruturado (E); crosta de sal na superfície (F).

Posteriormente às visitas, foram realizadas análises de imagens multiespectrais orbitais em cor verdadeira e falsa cor RGB (R = Red = vermelho; G = Green = verde; B = Blue = azul) para constatação das características do uso e ocupação do solo, recorrendo a imagens atuais e antigas (2019 e 2014, respectivamente) de satélites Landsat-8, Sentinel-2A e 2B, e mapas de apoio disponibilizados pelo software gratuito Google Earth Pro.

Assim, baseado na interpretação visual das imagens e nas observações de campo, três áreas foram selecionadas e identificadas como Área 1 (41,58 ha) de coordenadas centrais $9^{\circ}16'57.16''\text{S}$ e $40^{\circ}15'50.70''\text{O}$; Área 2 (13,0 ha) de coordenadas $9^{\circ}17'28.43''\text{S}$ e $40^{\circ}16'28.40''\text{O}$; e Área 3 (10,33 ha) de coordenadas de $9^{\circ}17'16.52''\text{S}$, $40^{\circ}16'59.48''\text{O}$ (Figura 5). Toda a extensão leste da área A1 margeia um trecho de rio que se encontra degradado e altamente salinizado, devido o mesmo ser utilizado como dreno para dar vazão a água residual de irrigação oriunda das propriedades agrícolas.

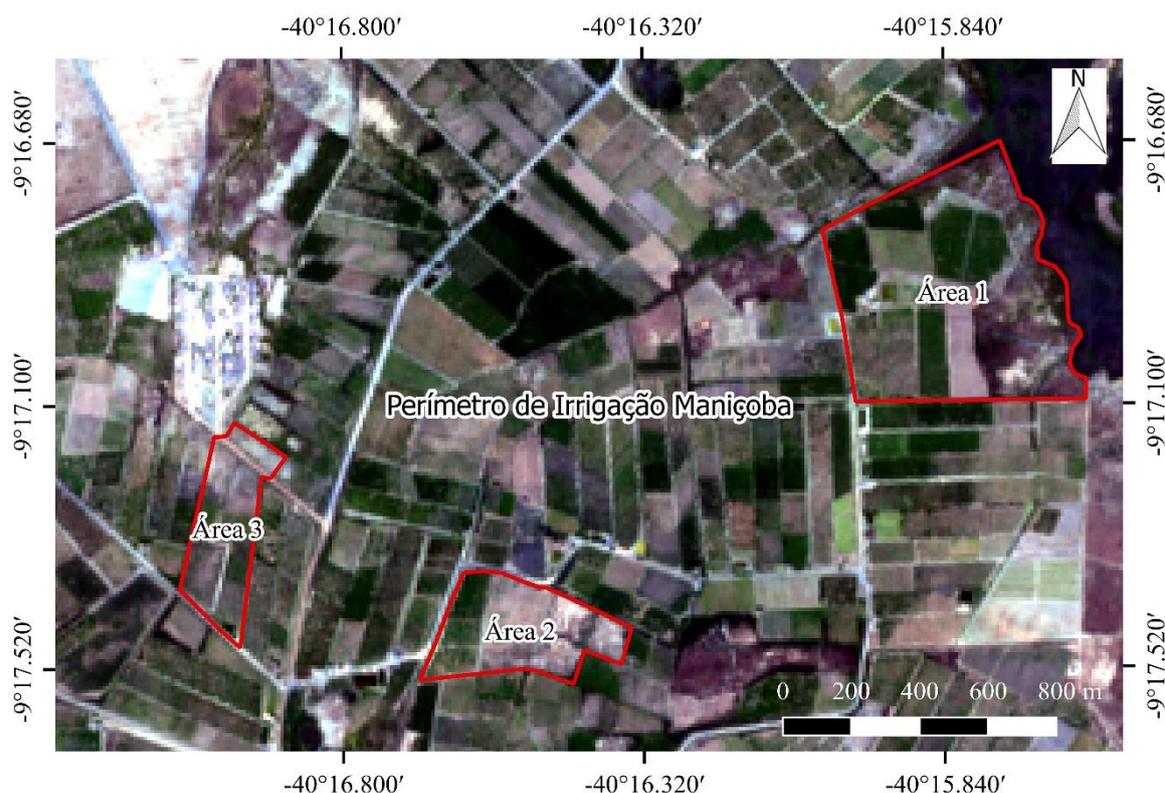


Figura 5. Localização das áreas 1, 2 e 3 no perímetro irrigado de Maniçoba, Juazeiro-BA, imagem Sentinel-2.

Fonte: Elaboração do Autor.

3.3. Seleção e obtenção de dados orbitais

As imagens multiespectrais de satélite Landsat-8 (sensores OLI e TIRS) e Sentinel-2 (sensor MSI) foram adquiridas gratuitamente na página virtual do USGS - (<https://earthexplorer.usgs.gov/>) - no período entre 2014 e 2019 para Landsat-8, e 2016 e 2019 para Sentinel-2. O critério de seleção foi definido com base na escolha de cenas em condições de céu claro, inexistência ou menor cobertura de nuvens (< 20%) e época de menor precipitação pluviométrica (período seco).

Os produtos dessas plataformas são distribuídos em formato GeoTIFF e JPEG2000, com sistema de projeção e referência UTM/WGS84 (*Universal Transverse Mercator / World Geodesic System 1984*), ortorretificada com alta precisão, com correções radiométrica e geométrica, incluindo arquivos auxiliares, indicadores de qualidade e metadados (USGS, 2019). As principais características dos produtos e dos sensores constam na Tabela 5.

Tabela 5. Dados referentes às imagens do satélite Landsat-8 e Sentinel-2A e 2B utilizados no estudo.

Datas	Órbita/Ponto	Resoluções				Sensores
		Espacial (m)	Espectral (bandas)	Temporal (dias)	Radiométrica (bits)	
Landsat-8						
22/09/2014	217/067	30	11	16	12	OLI/TIRS
24/08/2015						
29/10/2016	217/066					
16/10/2017	217/067					
17/09/2018						
20/09/2019						
Sentinel-2A e Sentinel-2B						
13/07/2016	T24LUQ	10	13	5	12	MSI
16/10/2017						
16/09/2018						
01/10/2019						

em que: T24LUQ refere-se ao código quadrante de aquisição da cena.

Fonte: Elaboração do autor.

3.4. Pré-processamento de imagens

As cenas foram importadas para o programa computacional QGis versão 2.18.19, no qual foram utilizadas as bandas espectrais 2 a 7, e 10 para Landsat-8, além das bandas 2 a 4, e 8 para Sentinel-2, o primeiro com resolução espacial de 30 m, resolução temporal de 16 dias e radiométrica de 12 bits, e o segundo com resolução espacial de 10 m, resolução temporal de 5 dias e radiométrica de 12 bits. A projeção do sistema de referência e coordenadas foi padronizada para todas as imagens (WGS84 / UTM zona 24S) e, construída a composição de

banda colorida RGB em cor natural para ambos produtos, Landsat-8 e Sentinel-2 (RGB nas bandas 4, 3 e 2, respectivamente).

Não houve a necessidade de correregistro e correção radiométrica das imagens, processos recomendados para reduzir os deslocamentos, distorções tangenciais de escala e divergências na intensidade dos pixels. Como também, não foi necessário a criação de mosaicos, já que o município de Juazeiro está inteiramente localizado no centro das imagens.

Posteriormente as imagens foram redimensionadas, ou seja, recortadas na área de interesse delimitado na forma de arquivo vetorial (shapefile) do município de Juazeiro. Tal procedimento minimiza a exigência computacional sem perda de informações.

Uma etapa importante antes do processamento é a transformação dos valores de radiância para radiância aparente. De acordo com a metodologia proposta por Markham e Barker (1987), transformando a radiância aparente em radiância bidirecional aparente, e posterior conversão para refletância bidirecional aparente (FRB aparente) com correção do ângulo zenital. Esse processo torna possível realizar operações aritméticas entre bandas espectrais diferentes, as quais os NDs dos parâmetros físicos ficam na mesma escala (PONZONI et al., 2012).

Realizou-se também a correção atmosférica aplicando o Dark Object Subtraction (DOS1), para correção do fenômeno do espalhamento atmosférico, conforme Chavez (1988).

3.5. Processamento

A transformação radiométrica é um procedimento que altera o aspecto visual das imagens, realça informações antes não vistas nas imagens originais e cria um novo produto sem que haja perda dos valores dos NDs. Mesmo com a compatibilidade de uso conjunto dos produtos dos sensores OLI e MSI, cada um possui características próprias, dessa forma o processamento foi realizado separadamente.

3.5.1. Processamento de imagens Landsat-8

O banco de imagens multiespectrais na região do visível do satélite Landsat-8 (sensores OLI e TIRS) foi utilizado nas análises espaço-temporais para avaliar as variações dos índices diretos e indiretos na análise da salinidade. Além disso, as bandas do visível e do termal foram utilizadas para cálculos de albedo e temperatura de superfície. O acervo de cenas do Landsat-8, disponibilizado pela USGS, forneceu dados nas características desejadas a partir de 2014.

Diante disso, efetuou-se o processamento em seis imagens no intervalo de 2014 a 2019 na época seca (Tabela 5).

O processamento das imagens Landsat-8 foi dividido em duas etapas. A primeira consistiu em realizar cálculos de bandas para obtenção de índices de vegetação NDVI, SAVI, EVI e GDVI, e índices de salinidade SI-1, SI-2, SI-3 e IB (2014 e 2015) para, respectivamente, detectar as mudanças da vegetação e áreas agrícolas, e solo exposto nas áreas de estudo (Tabela6).

Tabela 6. Índices espectrais de vegetação e salinidade utilizados.

Índices	Equações	Referências
NDVI	$NDVI = \frac{\rho NIR - \rho R}{\rho NIR + \rho R}$	(ROUSE et al., 1974)
SAVI	$SAVI = \frac{(\rho NIR - \rho R)}{(\rho NIR + \rho R + L)} * (1 + L)$	(HUETE, 1988)
EVI	$EVI = \frac{G \times (\rho NIR - \rho R)}{(1\rho NIR + C1 \times \rho R - c2 + \times \rho B)}$	(HUETE et al., 1997)
GDVI	$GDVI = \frac{\rho NIR^n - \rho R^n}{\rho NIR^n + \rho R^n}, \quad \text{para } n = 2$	(WU, 2014)
SI-1	$SI - 1 = \sqrt{\rho G \times \rho R}$	(DOUAOUI et al., 2006)
SI-2	$SI - 2 = \sqrt{\rho G^2 + \rho R^2 + \rho NIR^2}$	(DOUAOUI et al., 2006)
SI-3	$SI - 3 = \sqrt{\rho G^2 + \rho R^2}$	(DOUAOUI et al., 2006)
IB	$IB = \sqrt{\rho R^2 + \rho NIR^2}$	(KHAN et al., 2001)

ρ NIR: refletância banda infravermelho próximo; ρ R: refletância banda vermelha; ρ G: refletância banda verde; ρ B: refletância banda azul; L: 0,5; G: 2,5; C1: 6; C2: 7,5.

A segunda etapa foi a aplicação do algoritmo SEBAL, conforme metodologia proposta por Da Silva (2016), no qual foram processadas 15 etapas para obtenção da evapotranspiração real (mm/dia), como também obter dados da temperatura e albedo da superfície (Figura 6).

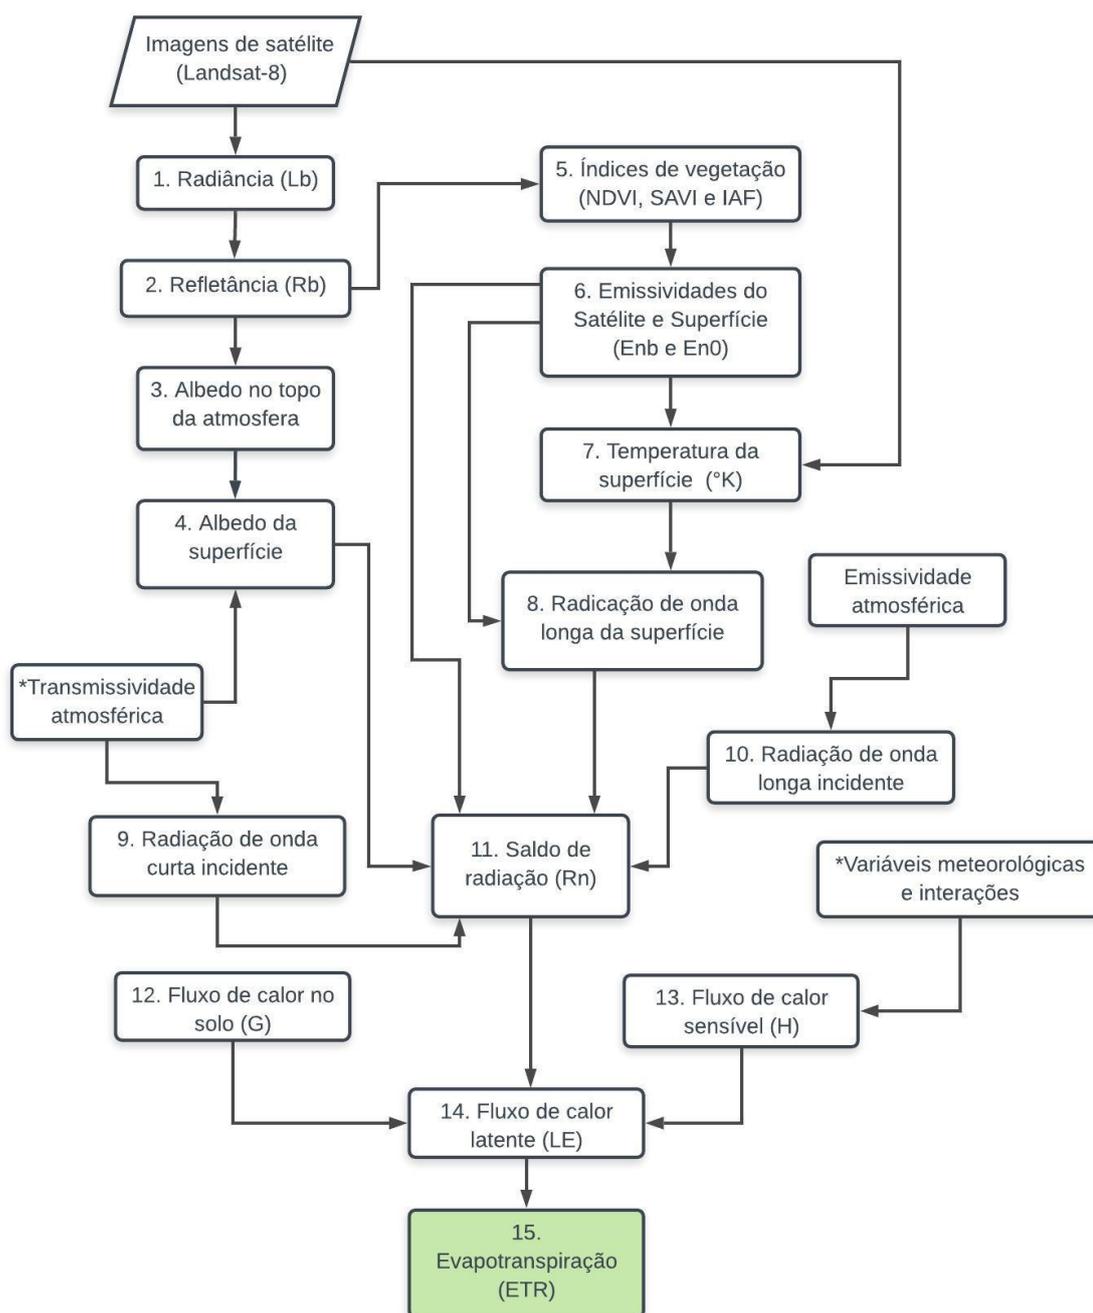


Figura 6. Diagrama representativo das etapas para obtenção da evapotranspiração real a partir do algoritmo SEBAL
 Fonte: Elaboração do Autor.

3.5.2. Processamento Sentinel-2

Realizou-se o processamento das imagens Sentinel-2 para os anos de 2016 a 2019. Essas imagens foram pré-processadas no pacote Semi-Automatic Classification Plugin (SCP), complemento disponibilizado para o software QGis, que calcula a refletância da superfície utilizando os parâmetros contidos nos metadados, o que habilitou o conjunto de bandas

espectrais do Sentinel-2 para os cálculos dos índices de vegetação e de salinidade, os quais foram NDVI, SAVI, EVI, GDVI, SI-1, SI-2, SI-3 e IB (Tabela 6).

3.6. Classificação Supervisionada

A etapa seguinte foi a aplicação da classificação supervisionada Máxima Verossimilhança (MaxVer) sobre dados do Sentinel-2. Este é considerado um dos melhores classificadores semiautomáticos na definição das diferentes classes de uso do solo. Para isso, de posse do conhecimento das áreas adquirido em campo, diversas amostras de assinaturas espectrais das diferentes coberturas da terra foram fornecidas ao algoritmo classificador, o qual diferenciou quatro classes: (1) corpos hídricos, (2) área agrícola, (3) solo exposto e (4) vegetação natural. Na classe 2 e 4, área agrícola e vegetação respectivamente, foram utilizados índices de vegetação para identificar as variações na vegetação existente, e na classe 3, solo exposto, foi utilizado os índices de salinidade, que identificam a alta refletância espectral de solos expostos. Para área agrícola, Moreira et al. (2016) consideraram que, mudanças abruptas nos índices de vegetação ao longo do tempo são decorrentes de alternâncias no uso da terra pelo manejo agrícola. O mesmo procedimento não foi adotado para a classe de vegetação nativa, por se tratar de áreas abandonadas pelo baixo potencial agrícola.

A avaliação de acurácia da classificação MaxVer, decorreu do cruzamento das informações da classificação pelo algoritmo com a verdade terrestre (fornecida pelo usuário com base nas observações de campo), obtendo a matriz de confusão para estimar o índice Kappa. Os pontos referentes à verdade terrestre foram observados durante a visita nas áreas, além de apoio de mapas de referência, tais como o Bing Maps e software Google Earth Pro.

A determinação da qualidade do classificador foi baseada no índice Kappa, de acordo com Landis e Koch (1977) (Tabela 4).

3.7. Coleta de solo para análise de condutividade elétrica do extrato saturado do solo

A amostragem do solo para análise da condutividade elétrica (CE), utilizada como referência na validação dos resultados, foi realizada em campo na estação seca, em setembro de 2019. Os pontos de coleta foram previamente estabelecidos em um esquema sistemático regular no software QGis 2.18.19, em pontos georreferenciados com distância fixada entre 50 m ao norte, sul, leste e oeste. Os pontos situados fora do perímetro das áreas, dentro de corpos

hídricos, sobre asfalto e construções foram removidos, e depois selecionados aleatoriamente 32 pontos em cada área (Figura 7).



Figura 7. Distribuição dos pontos de coleta de solo: Área 1 (32 pontos), área 2 (32 pontos) e área 3 (32 pontos).

Fonte: Elaboração do Autor.

Com auxílio de um aparelho de GPS (Sistema de Posicionamento Global) de navegação, e o croqui da distribuição dos pontos em cada área, as amostras foram adquiridas com um trado de mão a uma profundidade de 0 a 15 cm, eliminando-se a camada superficial do solo e resíduos orgânicos. Posteriormente, as amostras foram transferidas para sacolas plásticas de 1000 ml, devidamente secas e rotuladas, com 32 amostras por área, totalizando 96 amostras (Figura 8A, 8B e 8C).

O material coletado foi levado para o Laboratório de Mecânica do Solo e Aproveitamento de Resíduos da UFRPE para determinação da salinidade do extrato de saturação do solo, conforme metodologia de Richards (1954). A leitura das amostras foi realizada por um condutivímetro de bancada modelo SCHOTT-CG-853P, devidamente calibrado (Figura 8D).

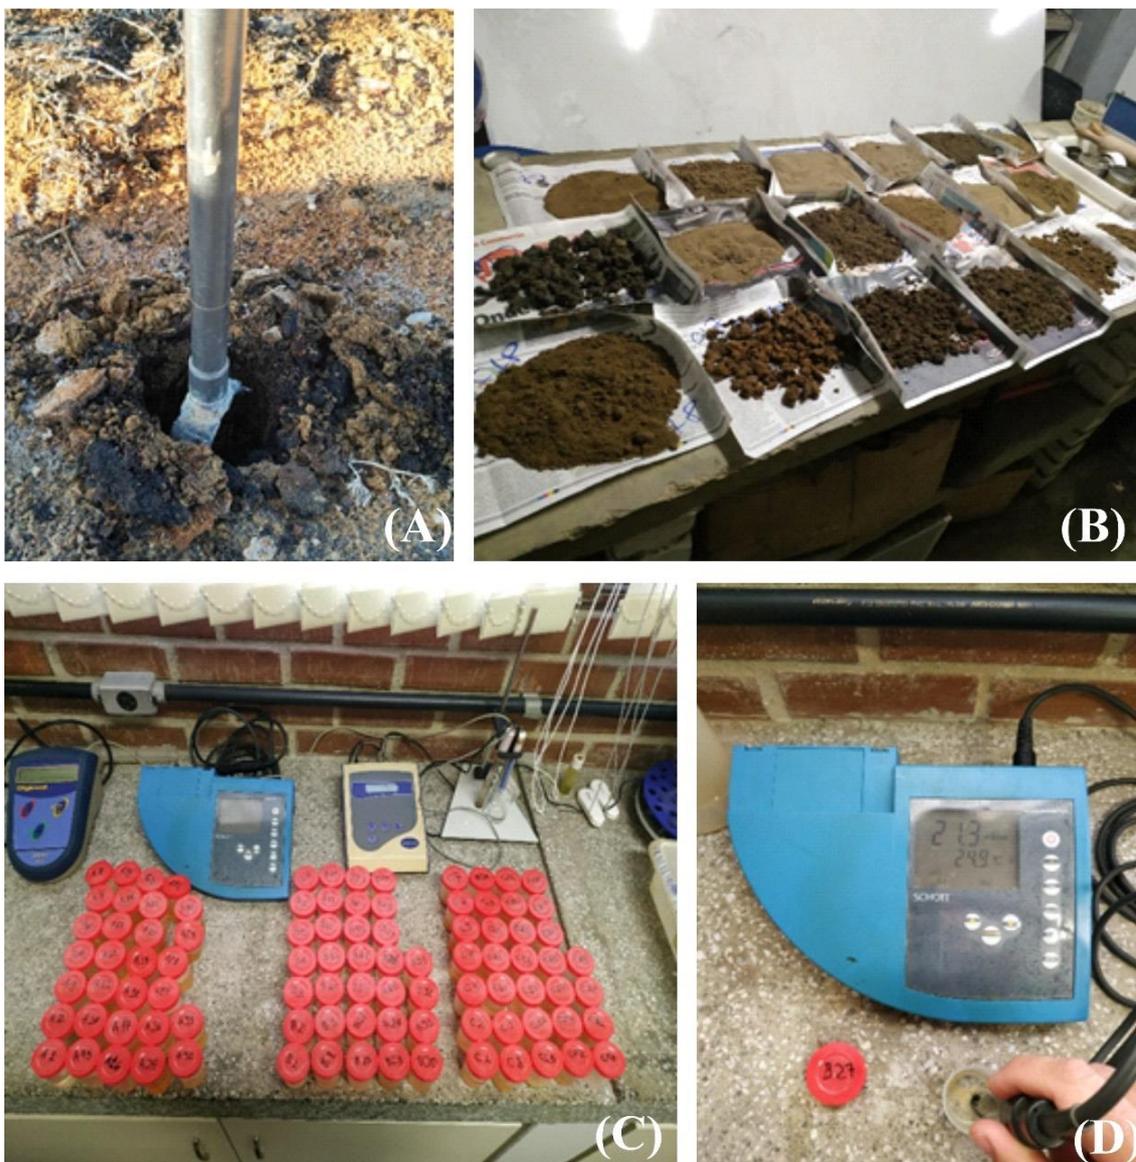


Figura 8. Trado de mão na coleta do solo (A); amostras em processo de secagem ao ar (B); extrato de saturação do solo (C); leitura da condutividade elétrica a 25°C (D).

De posse das leituras da condutividade elétrica (expressa em deciSiemens por metro - dS m^{-1} a 25°C), diferentes classes de salinidade foram consideradas de acordo com a Organização das Nações Unidas para a Alimentação e a Agricultura (FAO), as quais são: não-salino (0-2 dS/m); ligeiramente salino (2-4 dS/m); moderadamente salino (4-8 dS/m), fortemente salino (8-16 dS/m) e muito fortemente salino ($> 16 \text{ dS/m}$).

3.8. Dados meteorológicos

As informações meteorológicas do período entre 2014 e 2019 foram adquiridas na página eletrônica do Instituto Nacional de Meteorologia (INMET), referente a estação

automática (OMM 81991) situada no município de Petrolina-PE (9°23'18.02"S; 40°31'23.70"W; 373m). Usou-se esta estação devido a disponibilidade de dados meteorológicos mensais e a proximidade das áreas de estudo (29 km), em uma região relativamente plana.

Os dados meteorológicos da Tabela 7 foram coletados conforme o período de aquisição das imagens. As seguintes variáveis foram obtidas: Precipitação (mm); Temperatura do ar (Ta, °C); Umidade relativa do ar (UR, %); Pressão atmosférica do ar instantânea (hPa); Velocidade vento a 10 m de altura (m/s); Radiação Solar Global (kJ/m).

Tabela 7. Dados meteorológicos da estação automática INMET, para as datas de imageamento dos produtos Landsat-8 e Sentinel-2.

Data	Dj	Horário (UTC)	Ta (°C)	UR (%)	P (hPa)	Vento (m/s)	Radiação (kJ/m ²)	Precipitação (mm)
Landsat-8								
22/09/2014	265	12:48:30	32,8	40	972,0	4,6	21.215,0	0,0
24/08/2015	236	12:48:11	28,0	38	97,8	4,1	20.548,3	0,0
29/10/2016	303	12:48:21	31,2	35	972,5	4,4	20.651,8	0,0
16/10/2017	289	12:48:42	27,3	42	975,6	5,1	20.680,0	0,0
17/09/2018	260	12:48:02	30,1	42	972,4	4,7	18.976,1	0,0
20/09/2019	263	12:48:42	26,9	40	974,2	4,8	24.039,0	0,0
Sentinel-2								
13/07/2016	195	13:02:52	25,1	50	976,0	3,9	16.288,1	0,0
16/10/2017	289	13:02:51	27,0	38	975,6	5,1	20.680,0	0,0
16/09/2018	259	13:02:39	28,6	42	974,0	3,6	18.754,9	0,0
01/10/2019	244	13:02:49	25,7	46	975,1	3,9	17.888,9	0,0

em que: Dj é o dia juliano; UTC é Unidade de Tempo Central (horas: minutos: segundos); Ta é a temperatura de superfície; UR é a umidade relativa e P é a pressão atmosférica.

Fonte: INMET: Elaboração do autor.

3.9. Análise estatística

A extração de dados dos parâmetros foi realizada em dois níveis. Em nível de pixel foram observados os pixels com as mesmas coordenadas das amostras de CE, em nível de imagem, foi considerado todo o conjunto de pixels das áreas para cruzamento com os dados de camadas sobrepostas, separando por classes geradas pela classificação supervisionada. Assim, as informações foram tabuladas em planilha eletrônica Excel 2016.

Os dados de pixels individuais foram padronizados para aplicação da estatística multivariada por meio da Análise de Componentes Principais (ACP), condensando a maior quantidade das informações originais das variáveis e criação de um conjunto de principais componentes com perda mínima de informação. O uso de ACP justifica-se pelo fato da estatística clássica não conseguir explicar grandes conjuntos de variáveis e seus efeitos (MACCIOTTA et al., 2012), portanto, foi aplicada de forma a identificar quais componentes explicam a maior parte dos resultados.

Com base na matriz de correlação gerada, foram escolhidos os autovalores responsáveis pela maior variância acumulada, que geram os autovetores, e extração de resultados estatísticos para análise entre parâmetros calculados por imagens, dados meteorológicos e CE. Para isso, utilizou-se o software Minitab 18.1 e OringiLab 8.6.

O teste estatístico Kaiser foi adotado para avaliar a adequação do modelo e verificar a adequabilidade da análise fatorial (KAISER, 1958). Os resultados foram plotados em gráficos bidimensionais para melhor interpretação dos dados.

A partir da seleção dos índices de melhores respostas na ACP, mediu-se a correlação linear de Pearson, entre as variáveis selecionadas e a CE do solo. Observado o grau de correlação entre -1,0 e 1,0, o coeficiente de correlação (R^2) e o nível de significância.

Foram utilizadas as informações quantitativas e qualitativas das camadas por meio da estatística descritiva, tais como parâmetros de média, valores mínimos, valores máximos, desvio padrão e coeficiente de variação sobre os produtos gerados e dados meteorológicos.

4. RESULTADOS E DISCUSSÃO

4.1. Dados meteorológicos na caracterização das áreas

A Tabela 8 apresenta a variabilidade dos dados de precipitação pluviométrica mensal da estação meteorológica automática do INMET Petrolina-PE. Os maiores registros de chuva ocorreram nos anos 2014 e 2016, e os menores em 2015 e 2017. O período seco concentra-se entre os meses de maio e outubro, e as chuvas concentram-se entre dezembro e março, exceto em 2014 com chuvas de novembro a abril e com 25,4 mm/mês em julho.

Observou-se que não houve precipitação pluviométrica acumulada 15 dias antes do imageamento das cenas pelos sensores OLI, TIRS e MSI. Esses eventos chuvosos influenciam diretamente na umidade do solo e na dinâmica da vegetação, os quais interferem na interpretação dos dados de índices de vegetação.

O regime pluviométrico é o grande responsável pelo rápido incremento da biomassa vegetal, pois a vegetação da caatinga é bastante dinâmica e resiliente (RIBEIRO et al., 2016b), e tem seu ciclo fenológico fortemente influenciado pela precipitação (BARBOSA et al., 2006; BUSTAMANTE et al., 2012).

Tabela 8. Precipitação pluviométrica da estação meteorológica automática do INMET no município de Petrolina - PE no período de 2014 a 2019.

Meses	Precipitação dos anos estudados (mm)					
	2014	2015	2016	2017	2018	2019
JAN	29,20	12,40	291,60	0,00	20,60	10,00
FEV	35,20	35,60	25,80	79,80	111,20	68,40
MAR	55,20	37,20	12,60	10,00	29,60	62,20
ABR	178,00	77,20	2,60	7,80	0,00	30,40
MAI	3,80	0,60	0,60	2,60	0,00	21,20
JUN	1,20	2,40	0,80	2,40	2,80	7,80
JUL	25,40	2,60	0,80	0,60	0,00	1,80
AGO	2,20	0,00	0,60	0,00	0,80	4,20
SET	7,20	0,00	0,00	6,00	0,00	0,80
OUT	0,00	13,80	0,20	0,00	8,40	5,80
NOV	91,80	0,00	17,20	22,40	0,00	0,80
DEZ	49,20	3,20	11,20	13,80	48,80	33,80
Total (mm)	478,40	185,00	364,00	145,40	222,20	247,20

Fonte: INMET. Elaboração do autor.

A Figura 9 apresenta os dados mensais de chuva e de temperatura média do ar para o período entre de 2014 a 2019, sendo que em todos os anos, as menores temperaturas médias mensal foram para o período de junho a agosto, e máximas entre novembro e março. A precipitação acumulada para todos os anos ficou abaixo da média climatológica para a região (500 mm/ano) (PINHEIRO et al., 2015). Mas, o que destaca na Tabela 8 é a redução significativa da quantidade de chuvas (mm) nos anos pós 2014, com valores muito abaixo, o que pode aumentar consideravelmente a salinidade dos solos, pois em regiões áridas e semiáridas, o pouco volume de chuvas pode não ser suficiente para lixiviar os sais no perfil do solo (FERNANDES et al., 2016).

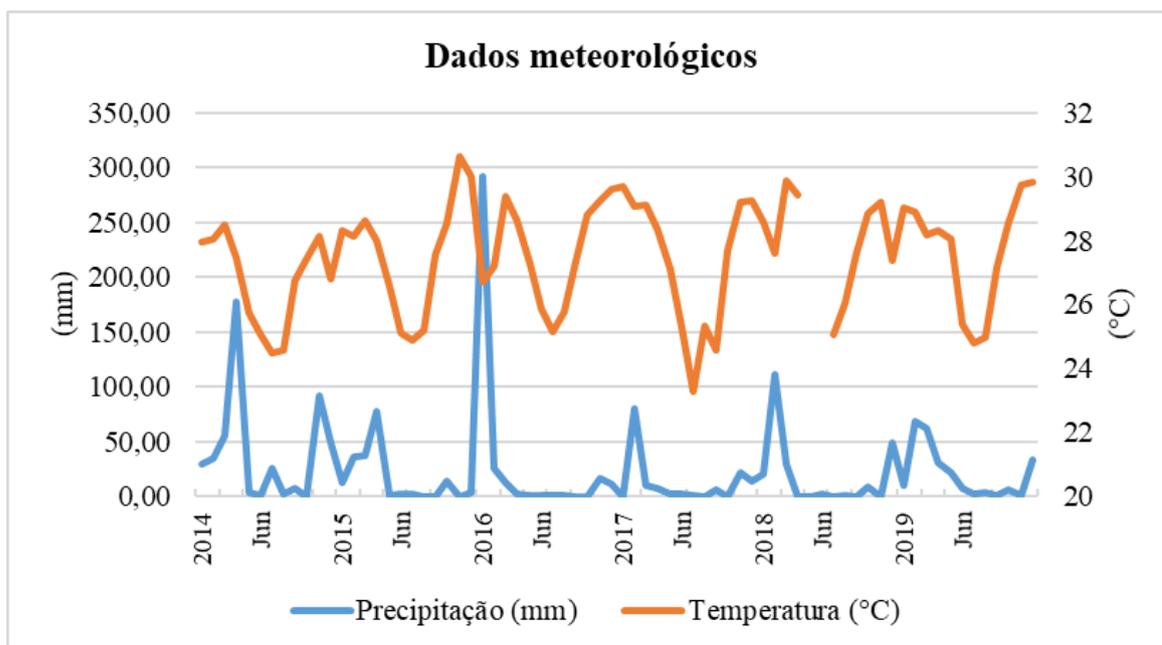


Figura 9. Variação mensal da precipitação pluviométrica e da temperatura do ar para o período de 2014 a 2019.

Para o período de coleta de solo no campo para análise da CE do solo (setembro de 2019), além de falta de chuvas, houve aumento progressivo da temperatura do ar, comum para o início da primavera. Contudo, Queiroz et al. (2016) afirmam que a concentração de sais no solo é uma propriedade que apresenta variabilidade espaço temporal, em função da granulometria do solo, manejo inadequado de irrigação, quantidade e distribuição das chuvas, e temperatura do ar.

4.2. Análise de Componentes Principais: Seleção dos melhores índices

Na Tabela 9 são apresentadas as componentes principais para as doze variáveis nas áreas de estudo para o ano de 2019. Pode-se verificar que os dados atendem o critério estabelecido por Kaiser (1958), onde as componentes principais CP1 e CP2 apresentaram autovalores superiores a 1, com variância total acumulada acima de 75% na CP2, sendo 78,1 %, 84,5 % e 91,6 %, para as áreas 1, 2 e 3, respectivamente, indicando um bom nível de adequação da análise multivariada (KAISER, 1958).

Tabela 9. Componentes principais das variáveis analisadas nas três áreas de estudo para o ano de 2019.

Variáveis	Área 1		Área 2		Área 3	
	CP1	CP2	CP1	CP2	CP1	CP2
¹ CE	-0,178	-0,090	-0,069	0,764	-0,292	-0,115
² ETR	0,210	-0,195	0,283	-0,295	0,309	-0,121
³ T.SUP	-0,278	-0,050	-0,262	0,271	-0,309	-0,013
⁴ A.SUP	0,114	0,492	-0,232	0,312	-0,184	0,462
⁵ NDVI	0,368	-0,076	0,328	0,099	0,334	-0,019
⁶ SAVI	0,369	0,058	0,330	0,121	0,329	0,125
⁷ EVI	0,369	0,021	0,329	0,131	0,330	0,094
⁸ GDVI	0,357	-0,058	0,318	0,048	0,335	-0,017
⁹ SI1	-0,204	0,520	-0,314	-0,013	-0,275	0,351
¹⁰ SI2	0,324	0,295	0,284	0,250	0,207	0,514
¹¹ SI3	-0,210	0,511	-0,315	-0,020	-0,280	0,336
¹² IB	0,329	0,279	0,297	0,227	0,226	0,482
Autovalor	7,1139	2,2577	8,8804	1,2558	8,7112	2,2856
Proporção	0,593	0,188	0,740	0,105	0,726	0,190
Acumulado	0,593	0,781	0,740	0,845	0,726	0,916

CP: componente principal; ICE: condutividade elétrica (dS/m); 2ETR: evapotranspiração real (mm); T.SUP: temperatura de superfície (°C); 4A.SUP: albedo da superfície; 5NDVI: índice de vegetação da diferença normalizada; 6SAVI: índice de vegetação ajustado ao solo; 7EVI: índice de vegetação melhorado; 8GDVI: índice de vegetação da diferença normalizada; 9SI1, 10SI2 e 11SI3: índices de salinidade; 12IB: índice de brilho.

As componentes 1 e 2 contém a maior proporção explicativa do conjunto de variáveis. A Figura 10 demonstra a porcentagem que as componentes carregam, formando uma constância após a terceira componente principal. A área A1 apresentou na terceira componente autovalor acima de 1, no entanto esta foi deixada de fora da análise por apresentar explicação da variância inferior a CP1 e CP2.

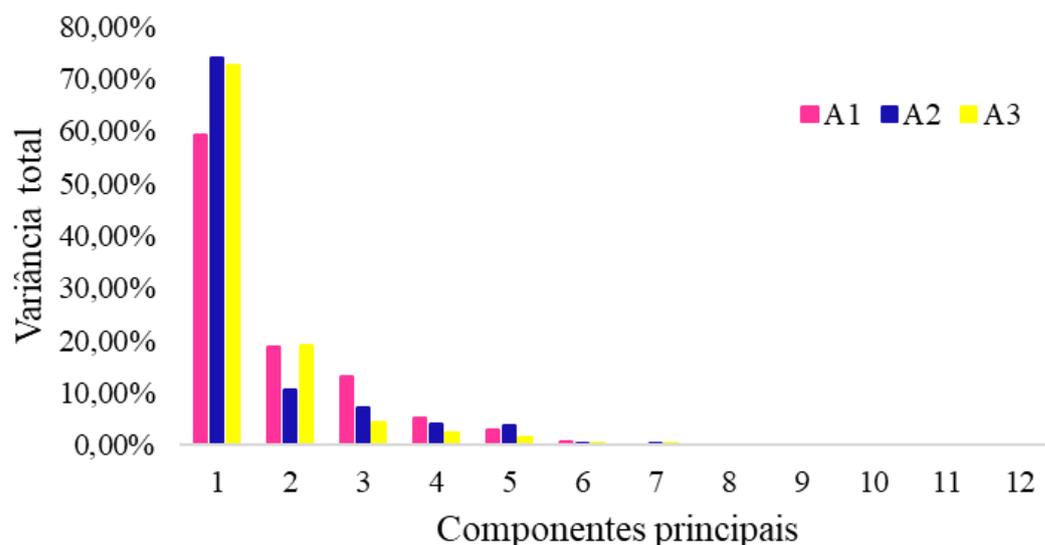


Figura 10. Componentes principais nas áreas 1, 2 e 3 de estudo para o ano de 2019.

A condutividade elétrica, temperatura de superfície, albedo de superfície e índices (SI-1 e SI-3) apresentaram relação entre si, formando o primeiro grupo de variáveis, o mesmo ocorreu entre as variáveis evapotranspiração e índices NDVI, SAVI, EVI, GDVI, SI-2 e IB, formando o segundo grupo. As associações observadas são baseadas na componente principal 1, com uma variância total de 59,3%, 74,0% e 72,6%, para as áreas 1, 2 e 3, respectivamente.

Estudos realizados por Da Silveira et al. (2018), no mapeamento de fitofisionomias do bioma Caatinga por meio de imagens Sentinel-2, no período de 2015 a 2016, verificaram correlações de atributos físico-químicos do solo de 69% da variância total acumulada até a terceira componente, o que respondeu satisfatoriamente as relações entre os atributos analisados. Neste presente estudo, as três áreas obtiveram variância superior a 59% somente na primeira componente.

Noroozi et al. (2012) em estudo de caso da salinidade no leste de Teerã no Irã, avaliou a correlação da CE do solo com bandas espectrais, índices de vegetação e salinidade a partir da ACP e verificaram variância total acumulada de 81% nas duas primeiras componentes. Já Khan et al. (2001) aplicaram classificação de ACP nas bandas de imagens do satélite IRS-1B para estudar salinidade, encontrando valores próximos a 99% no CP2.

Correlação inversa ocorreu entre os índices de vegetação (NDVI, SAVI, EVI e GDVI) com a CE do solo (Tabela 9), resposta também observada por (NOROOZI et al., 2012). Isso se justifica, visto que estes índices foram desenvolvidos para identificar a vegetação sadia existente na superfície, o que tem relação direta com níveis baixos de salinidade do solo. Em solos expostos, degradados e salinos, o crescimento da vegetação é comumente inibido

(MOREIRA et al., 2015), quando as plantas estão sob estresse salino, sua atividade fotossintética diminui, ocorre aumento na refletância no visível e diminuição na banda infravermelho próximo (MULLA, 2013).

Na Figura 11 são apresentados os coeficientes de cada variável das componentes principais para o ano de 2019.

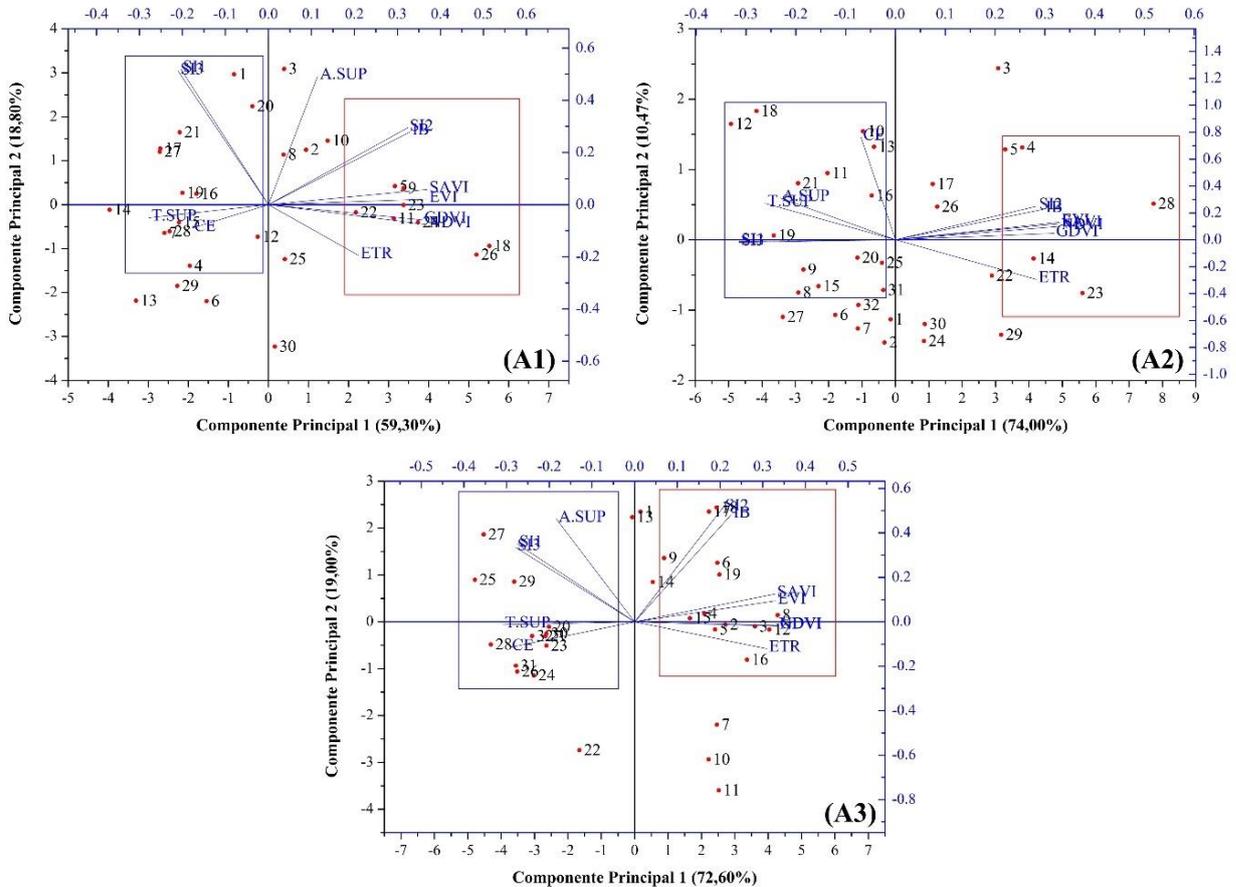


Figura 11. Componentes principais dos índices indicadores, das variáveis biofísicas calculadas e a condutividade elétrica do solo para as áreas A1, A2 e A3.

A Figura 11 apresenta a distribuição e as cargas fatoriais dentro das componentes principais. Em que os maiores valores dos coeficientes pertencem aos índices de vegetação, que dessa forma, possuem maior influência na CP1 do que as demais variáveis.

A Figura também apresenta o comportamento dos pontos coletados no campo em função dos parâmetros. O grupo 1 (polígono azul) demonstra a forte relação entre a CE, T.SUP, SI-1 e SI-3 dentro das componentes principais, com explicação acima de 78%. Esse comportamento indica relação entre variáveis, isto é, quanto maior a temperatura da superfície, maior será a condutividade elétrica, maior albedo e índices SI-1 e SI-3.

O problema de salinização secundária em regiões tropicais e semiáridas, principalmente em perímetros irrigados, vem se agravando rapidamente, devido a condições climáticas adversas como baixa precipitação, intensa evapotranspiração e temperaturas elevadas (SILVEIRA et al., 2016).

Salienta-se, ainda, que a Figura 11 demonstra que entre os índices diretos, o SI-1 e SI-3 apresentaram relação direta com a CE, o que não ocorreu para os índices SI-2 e IB. Douaoui et al. (2006), determinando a salinidade por meio de índices espectrais com imagens SPOT, concluíram que o SI-1 apresentou a melhor resposta, com um coeficiente de determinação de 50%, seguido pelo índice SI-3 com 49%, o que corrobora com os resultados dos índices de salinidade observados na ACP. Respostas semelhantes também foram observados por Ibrahim (2016) e Moreira et al. (2016) que verificaram melhor correlação para o índice SI-1.

Gorji et al. (2017), estudando salinidade na região do Lago Tuz – Turquia, aplicaram a regressão linear entre dados de CE coletadas em campo e índices de salinidade SI-2, SI-3, SI-4 e SI-5, que correspondem nessa ordem aos índices SI-1, SI-2, SI-3 e IB para o presente estudo, e verificaram o coeficiente de correlação (R^2) de 0,90, 0,89, 0,87 e 0,84, respectivamente.

Para as três áreas estudadas, os índices SI-2 e IB exibiram respostas não previstas, por realçarem as características da vegetação em detrimento de solos expostos. Essas respostas podem ser atribuídas ao fato desses índices utilizarem a banda do infravermelho próximo (NIR) em sua formulação, o que pode mascarar os resultados. Segundo Boonstra et al. (2002), a refletância do solo exposto e da superfície do sal é maior do que a terra cultivada, exceto na faixa do infravermelho próximo.

Bouaziz et al. (2011), aplicando índices de bandas em imagens do satélite MODIS no semiárido nordestino, verificaram que o índice de intensidade (IB) possui baixa correlação com a CE, não mostrando potencial para discriminar solos salinos.

A realização do cálculo de bandas do NIR elevado ao quadrado nesses índices, destaca, ainda mais, as características da vegetação existente na área (halófitas rasteiras), pois sabe-se que a vegetação possui maior refletância nessa região espectral e menor absorção do que o solo, devido as características da estrutura interna das folhas (PONZONI et al., 2012).

Entretanto, Taghadosi & Hasanlou (2017), em estudos de monitoramento de tendências da salinidade no distrito de Salt Lake em Bakhtegan-Irã, a partir de imagens TM Landsat-5 e 8, verificaram que os índices SI-1 e SI-3 (equivalentes a SI-2 e SI-1), obtiveram melhores correlações e foram selecionados como melhores na identificação de solos salinos. Já Noroozi et al. (2012) obtiveram melhores correlações para o SI-3 e SI-2 em imagens Landsat.

Com exceção da área 1, o albedo da superfície demonstrou relação direta com a temperatura da superfície e condutividade elétrica do solo. O albedo é um parâmetro utilizado no estudo de impactos ambientais, quando avaliado sazonalmente e a longo prazo, pode indicar redução da biomassa vegetal e desertificação (DA SILVA et al., 2005; BEZERRA et al., 2014), o que corresponde com o aumento da CE e temperatura da superfície.

Resultados parecidos foram observados por Bezerra et al. (2014) em estudo de parâmetros biofísicos no semiárido no Rio Grande do Norte, o qual observaram para época de estiagem na caatinga, maiores valores de temperatura da superfície acompanhada pelo aumento do albedo e redução do NDVI.

O grupo 2 (polígono vermelho, Figura 11) reúne o conjunto de variáveis que possuem maior grau de similaridade entre índices de vegetação, índices de salinidade (SI-2 e IB) e evapotranspiração, e demonstra uma relação inversa com o grupo 1.

Os índices de vegetação NDVI, SAVI, EVI e GDVI foram muito semelhantes na análise multivariada, com fatores de peso semelhantes na CP1 nas três áreas (Tabela 9). No entanto, para selecionar os melhores índices para criação de cartas temáticas, cabe a decisão do operador em decidir, levando em consideração as condições do ambiente, tipo de cobertura e efeito prático visual da carta para interpretação dos dados, principalmente em investigações multitemporais.

Em relação a CE observada, a disposição dos índices de vegetação no gráfico, de forma inversa, revela a eficiência destes em identificar indiretamente áreas potencialmente salinizadas. Esta observação concorda com o verificado por Bouaziz et al. (2011) e Gorji (2017), que afirmam que áreas onde a vegetação sofre mais estresse salino, a refletância aumentará no vermelho e infravermelho próximo.

Apesar de serem bons indicadores indiretos, esses índices sozinhos apontam a existência ou não de vegetação sobre a superfície, que, para o momento analisado, pode ser decorrente a diversos fatores, como a ação humana, degradação do solo e inclusive excessos de sais no solo (WU et al., 2014).

Contudo, o conhecimento prévio a respeito da área de estudo permite inferir com maior precisão as causas da degradação, mas ainda assim, é preciso lançar mão em outros parâmetros e combiná-los no espaço e no tempo para evitar interpretações equivocadas. Assim, a análise conjunta entre índices de vegetação e albedo revela que quanto mais próximo de 1 são os índices, menores são os valores do albedo (DA SILVA et al., 2005), pois, mais energia estará

disponível para os processos bio-físico-químicos da superfície (MACHADO et al., 2014), e menos energia será refletida para atmosfera.

4.3. Avaliação do grau de salinidade nas áreas de estudo

A classificação dos níveis de salinidade e o número de pontos que compõem as classes constam na Figura 12, e a Figura 13 apresenta a distribuição da salinidade do solo nas áreas selecionadas a partir da Interpolação de Ponderação por Distância Inversa (IDW) para cada ponto amostrado.

De acordo com a Figura 12, observa-se que os valores de CE variaram de não salino (0-2 dS/m) para muito fortemente salino (> 16 dS/m). Ressalta-se, que dois pontos amostrados na área A1 foram removidos, devido a solução extraída não ser suficiente para a leitura da CE. No geral, a classe muito fortemente salino foi dominante na soma das três áreas (43,62 %), seguida pela classe não salino (30,85%) e ligeiramente salino (10,64%). No total, 58,5% dos pontos amostrados foram considerados salinos com CE superior a 4 dS/m.

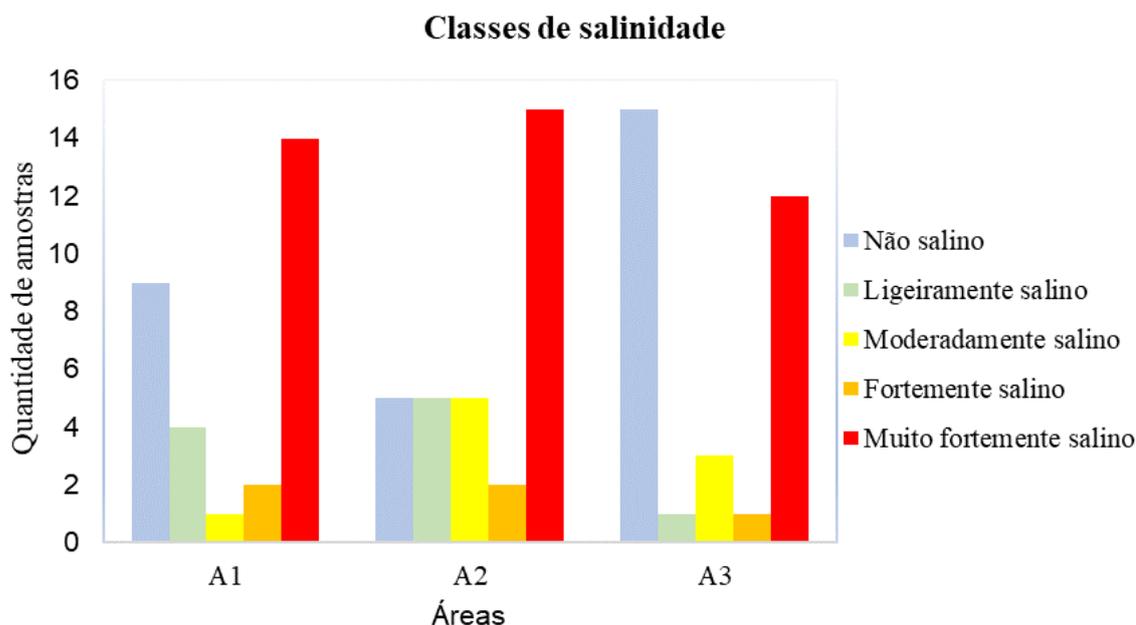


Figura 12. Classes de salinidade identificadas nas áreas estudadas.

Resultados semelhantes foram observados por Barreto (2019), no estudo da salinidade relacionando amostras do solo com índices espectrais obtidos por diferentes técnicas de Sensoriamento Remoto, a partir de imagens Sentinel-2, em que verificaram que 50% dos pontos acima de 4 dS/m e os demais 50% com salinidade inferior a 4dS/m.

Allbed et al. (2014), na análise da salinidade em perímetros irrigados, encontraram valores elevados de condutividade elétrica em três áreas dentro do Oásis na Península Arábica, onde a classe fortemente salino obteve maiores percentuais.

As altas concentrações observadas demonstram a situação crítica atual. Pois, segundo Aguiar Netto et al. (2007), grandes níveis de salinidade prejudicam a estrutura, com dispersão das partículas, impermeabilização e adensamento do solo. O produto dessa acumulação acarreta na redução da produtividade do solo, dificultando o desenvolvimento das plantas (MOREIRA et al., 2016), afetando as atividades fisiológicas das culturas, devido ao aumento da pressão osmótica, déficit hídrico, toxicidade de íons e desequilíbrio nutricional (DIAS et al., 2016).

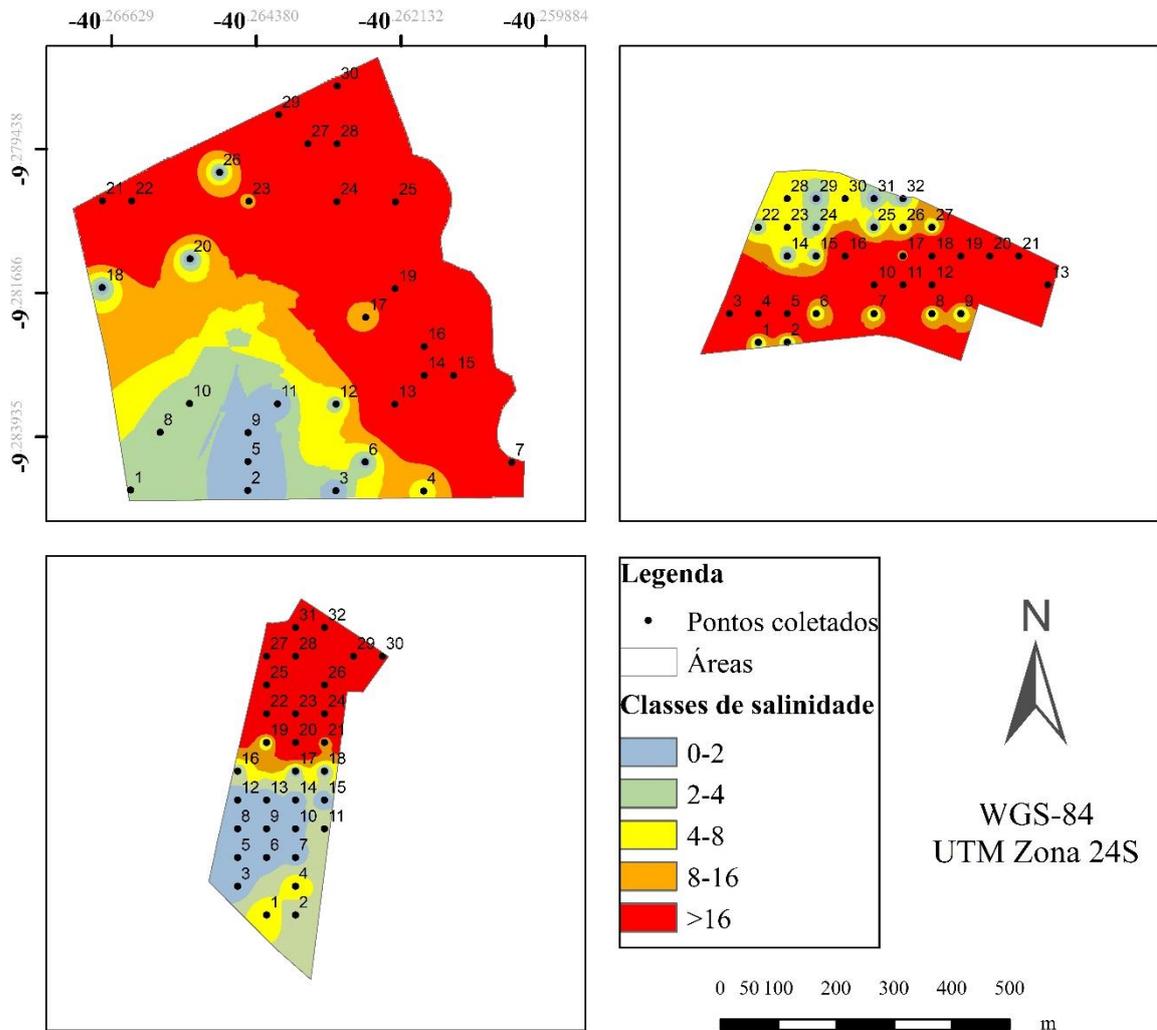


Figura 13. Interpolação IDW da distribuição espacial da salinidade do solo nas áreas de estudo (A1, A2 e A3).

Segundo Wang et al. (2002), a amostragem do solo para avaliação da salinidade requer interpolação entre os pontos de amostragem para criar uma avaliação espacial da distribuição

aparente da salinidade. Dessa forma, o produto da interpolação dos dados coletados em campo (Figura 13) produziu uma carta temática de distribuição aparente dos níveis de sais dentro das áreas. No entanto, a interpolação superestimou os dados, o que acarreta em prejuízo na identificação precisa da espacialização da salinidade sobre as áreas, fato também observado por Gardiman et al. (2016) na interpolação de dados de precipitação pluviométrica.

Observa-se na Figura 13 a predominância de manchas que indicam níveis fortes de salinidade (cor vermelha) na porção superior das áreas A1 e A3, e mais centralizada na porção sul em A2. Essas manchas indicam os níveis de salinidade distribuídos nas áreas, devido aos valores de condutividade elétrica do solo (JAYALAKSHMI & VELAPPAN, 2015).

Ressalta-se ainda que em toda a porção leste e nordeste da área A1 existe um trecho de rio que se encontra assoreado e altamente salinizado, o que influenciou fortemente na salinidade em grande parte próximas ao corpo hídrico.

4.4. Classificação Supervisionada para avaliação da salinidade sobre máscaras de diferentes classes de uso do solo

Como estratégia para caracterizar a área de estudo na avaliação do efeito da salinidade sobre o uso e ocupação do solo, foi aplicada a classificação supervisionada máxima verossimilhança (MaxVer), que fornece melhor desempenho frente a outras abordagens de classificação (TAGHADOSI & HASANLOU, 2017). Foram estabelecidas quatro macro classes em função dos temas de interesse: (1) corpo hídrico, (2) área agrícola, (3) solo exposto e (4) vegetação natural.

A Tabela 10 mostra o desempenho do classificador. Com base na matriz de erro, o índice Kappa apresentou valor muito próximo a 1, indicando alta eficiência da aplicação do algoritmo semiautomático na determinação das classes, sendo classificado como excelente (LANDIS & KOCH, 1977).

Tabela 10. Matriz de confusão, erros de omissão, erros de inclusão e índice Kappa.

Classes	Dados de referência					EO (%)
	Corpos hídricos	Agrícola	Solo exposto	Vegetação	Total	
Corpos hídricos	69	0	0	0	69	0
Agrícola	1	2218	0	0	2219	0,04
Solo exposto	17	3	687	39	746	7,90
Vegetação	46	33	8	581	668	13,02
Total	133	2254	695	620	3702	EG (%)
EI (%)	48,12	1,59	1,15	6,29	-	96,02
Kappa (%)	51,8	98,4	98,8	93,7	0,9298	

EI: erro de inclusão; EO: erro de omissão.

Fonte: Elaboração do autor.

A classe vegetação natural apresentou maior erro e omissão (13,02 %), cedendo mais pixels para a classe corpos hídricos. Os maiores erros de inclusão foram verificados na classe corpos hídricos, que tiveram muitos pixels de vegetação incluídos na sua classe. De modo geral, os erros foram considerados baixos, o que se verifica pela exatidão global (96%).

O classificador Maxver quantificou satisfatoriamente as classes, o número de pixels e a área (m²) para o ano de 2019. O cruzamento de informações dos pixels da classificação com os pixels dos índices NDVI, SAVI, EVI, GDVI, SI-1 e SI-3 permitiu analisar as mudanças ocorridas no uso e ocupação do solo por meio da combinação entre imagens Sentinel-2 e Landsat-8, entre 2014 e 2019.

A Figura 14 apresenta a carta temática do classificador MaxVer para as quatro classes de uso do solo e suas respectivas áreas

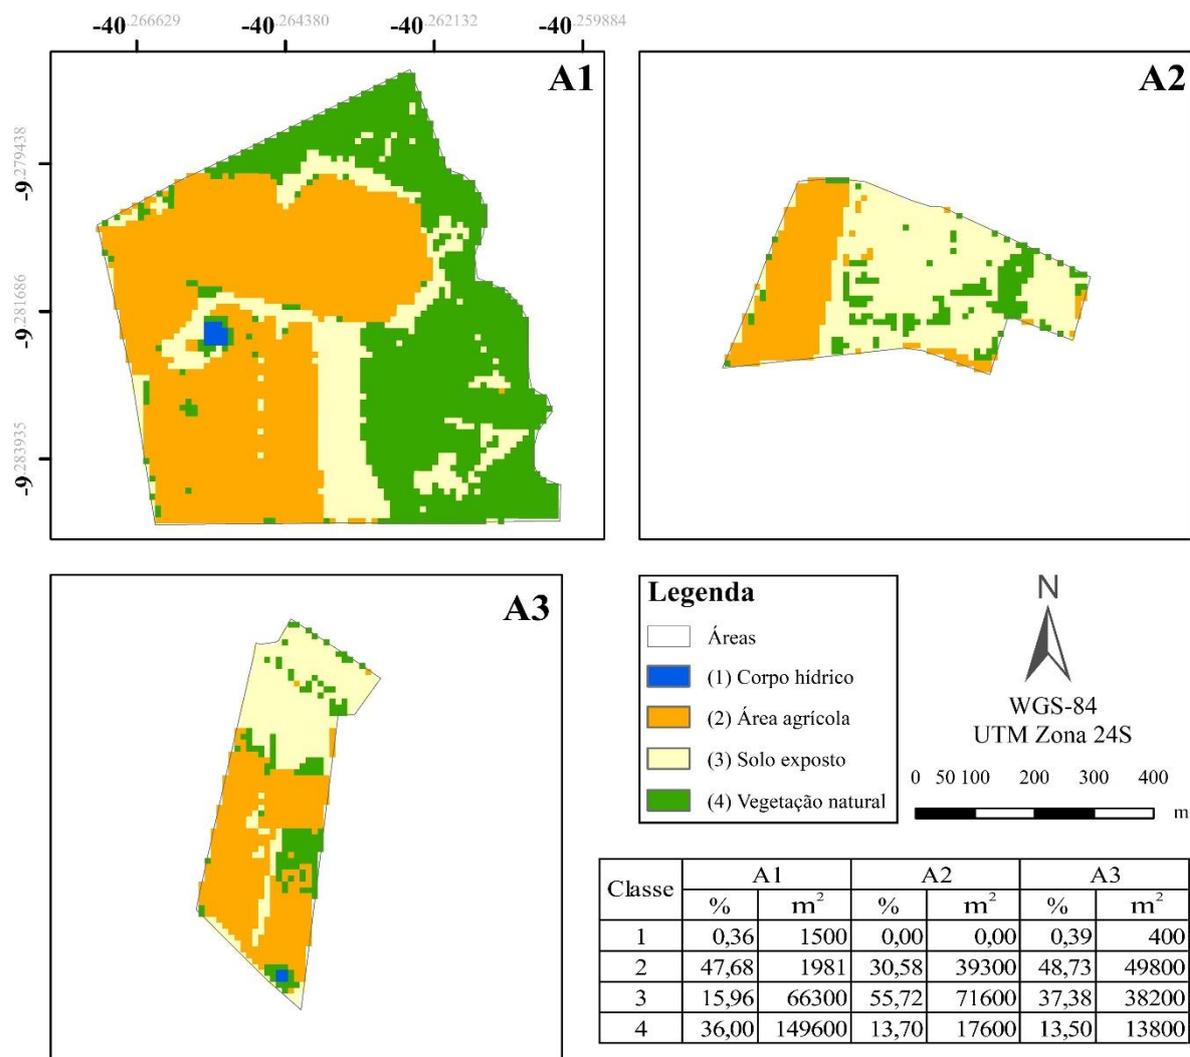


Figura 14. Classificação Supervisionada MAXVER para 4 classes de uso do solo e suas respectivas áreas em imagens Sentinel-2.

A partir da Figura 14 verifica-se as classes mais representativas para cada área. A área agrícola (classe 2) foi a mais dominante para A1 e A3, já em A2, foi solo exposto (classe 3). A mancha fortemente salinizada (Figura 13) ao norte e nordeste está relacionada com a classe vegetação para a área 1 (A1), solo exposto mais vegetação na área 2 (A2) e solo exposto na área 3 (A3). Isto indica que não existe um padrão bem definido quando se relaciona a classificação supervisionada com a carta temática de condutividade elétrica.

Um fator que evidencia a degradação nos solos dentro das áreas estudadas é o baixo percentual de ocupação por plantios, sendo 47,68 %, 30,58 % e 48,73 %, para A1, A2 e A3 respectivamente. Esse o baixo percentual de aproveitamento da ocupação do solo diferencia-se na realidade local, em que, em condições normais, aproveita-se toda a extensão do solo dentro dos lotes, que apresentam em média tamanhos entre 10 a 20 ha. Esse cenário não é exclusivo

do perímetro de Irrigação da Maniçoba, visto que aproximadamente 30% das áreas agrícolas em perímetros irrigados no semiárido nordestino se encontram com problemas de excesso de sais nos solos (LOPES et al., 2008).

Em perímetros irrigados, a ocorrência de salinização secundária é mais constante quando há intensa atividade agrícola com o uso da irrigação (DE OLIVEIRA, 1997). A redução da capacidade produtiva do solo nessas áreas é decorrente do manejo inadequado da irrigação, da baixa qualidade da água e má drenagem dos solos (LEITE et al, 2010), além do histórico de irrigação por métodos defasados como irrigação por sulco, ainda empregado em pequenos lotes.

4.5. Níveis de sais distribuídos dentro das classes de uso do solo

A Tabela 11 apresenta os percentuais e quantidade de pontos dos níveis de sais coletados em campo (representado nos pixels) pertencentes as classes de uso do solo (definidas pela classificação MaxVer) para o ano de 2019.

Verifica-se que o solo exposto (classe 3) representa a classe com maiores de níveis de salinidade, enquanto a classe área agrícola (classe 2) demonstrou o oposto. A vegetação natural (classe 4), contém seus pontos distribuídos nos maiores níveis de sais.

A distribuição dos níveis de sais em diferentes coberturas de solo corrobora com os obtidos por Douaoui et al. (2006), que em áreas de solos exposto exibiram maiores valores de CE (dS/m), seguida por áreas de vegetação halófitas e vegetação local, e menores salinidade em áreas agrícolas. Castro & dos Santos (2019), em pesquisa realizada na região do vale do São Francisco, observaram maiores valores de CE para áreas de sequeiro e solo exposto, e menores valores em áreas agrícolas e vegetação da caatinga conservada.

Tabela 11. Níveis de salinidade nas classes de uso do solo

Classes	(0-2 dS/m)		(2-4 dS/m)		(4-8 dS/m)		(8-16 dS/m)		(> 16 dS/m)	
	N	%	N	%	N	%	N	%	N	%
2	23	58,97	3	50,00	3	42,86	1	25,00	6	15,79
3	13	33,33	1	16,67	2	28,57	1	25,00	22	57,89
4	3	7,69	2	33,33	2	28,57	2	50,00	10	26,32
Total	39	100,00	6	100,00	7	100,00	4	100,00	38	100,00

N: número de amostras coletadas dentro de classes de uso do solo; (0-2 dS/m) = não salino; (2-4 dS/m): ligeiramente salino; (4-8 dS/m): salino; (8-16 dS/m) fortemente salino; (> 16 dS/m): muito fortemente salino; classe 2: área agrícola; classe 3: solo exposto; classe 4: vegetação natural.

Fonte: Elaboração do autor.

Como visto na Tabela 11, grande número dos pixels de solo exposto contém maiores percentuais de níveis salinos, no entanto, a classificação não permite diferenciar solos salinos de não salinos, visto que os valores de cada pixel é um produto da mistura espectral dos diferentes alvos contidos em 100 m² de superfície (para imagens Sentinel-2). Além disso, a salinidade é um fenômeno dinâmico com alta variabilidade espacial e temporal (QUEIROZ et al., 2016; METTERNICHT & ZINCK, 2008), variando sua composição conforme os diferentes materiais de origem, o que afeta na refletância (MOREIRA et al., 2016).

Outro fator limitante que pode originar interpretação imprecisa é a ocorrência de vegetação com baixa atividade fotossintética (decíduas), muito comum na caatinga, o que aumenta a refletância na região do visível e reduz no infravermelho próximo, apresentando nível de brilho semelhante ao solo (WEISS et al., 2001).

Diante do exposto, uma alternativa para diferenciação entre solos salinos, não salinos e vegetação decídua, requer o uso de imagens de sensores hiperespectrais que oferecem grande número de bandas espectrais, que operam em intervalos menores nas regiões do visível, infravermelho próximo e infravermelho de ondas curtas, sendo capazes de detalhar com maior precisão as assinaturas espectrais inerentes de cada alvo. Contudo, o acesso a esses dados envolve altos custos e pouca disponibilidade, o que dificulta o desenvolvimento de pesquisas.

De acordo com Allbed et al. (2013), o desenvolvimento de sensores hiperespectrais aerotransportados superou algumas das limitações encontradas em imagens de satélite multiespectrais, já que oferecem maiores resoluções espectrais e espaciais, o que os tornam úteis no monitoramento da salinidade do solo, tanto local quanto regional.

Outra classe que mostrou maior ocupação com os altos níveis de sais amostrados foi vegetação natural, entretanto não foi possível diferenciar entre espécies tolerantes e não tolerantes através das imagens. A resolução espectral do sensor MSI (13 bandas) limita essa possibilidade, mas o uso de sensores hiperespectrais possibilitaria a identificação das assinaturas espectrais de halófitas, o que torna possível mapear indiretamente as áreas afetadas por sais (ALLBED et al., 2013)

Em áreas agrícolas, as baixas concentrações salinas observadas e ausência de crostas, é resultado da interferência dos produtores no manejo constante da água e solo, correção do PH, aplicação de matéria orgânica, drenagem do excesso de água, cobertura do solo e tratamentos culturais.

Muitos autores como Allbed & Kumar (2013), Wu (2014) e Scudiero et al. (2015) afirmam que a salinidade secundária é uma das principais causas de degradação, principalmente em regiões semiáridas com condições que naturalmente favorecem o acúmulo de sais, como evapotranspiração elevada, baixa precipitação, lençol freático raso, altas temperaturas e solos com baixa drenagem.

4.6. Seleção dos índices de vegetação e de salinidade para elaboração de cartas temáticas

Os índices utilizados nesse estudo foram escolhidos com base nos trabalhos de (DOUAOUI et al., 2006; ALLBED & KUMAR, 2013; WU et al., 2014; AZABDAFTARI & SUNARB, 2016; SATIR & BERBEROGLU, 2016; GORJI et al., 2017; TAGHADOSI & HASANLOU 2017). A seleção dos melhores índices para elaboração das cartas temáticas considerou inicialmente as correlações diretas e indiretas observadas nos pixels de referência entre as medidas da CE, temperatura da superfície, albedo e evapotranspiração pela análise multivariada. Diante dos resultados (Tabela 9), eliminou-se os índices SI-2 e IB, contudo, não foi possível identificar os melhores índices de vegetação, devido à similaridade entre eles.

Adotando o critério proposto por Taghadosi & Hasanlou (2017), a escolha dos melhores índices indiretos deu-se a partir da análise do desvio padrão da média, que indica os valores dos índices que estão mais próximos da média. Desse modo, quanto maior o desvio padrão, significa que os valores dos pixels se espalham por uma faixa mais ampla de valores e identificam melhor as mudanças ocorridas na refletância da vegetação, e, a partir correlação de Pearson, que demonstra quão forte é a relação entre índices e CE (Tabela 12) (BOUAZIZ et al., 2011).

Tabela 12. Correlação de Pearson e desvio padrão entre a CE e os índices de vegetação

Área		Índices de vegetação			
		NDVI	SAVI	EVI	GDVI
A1	EC (dS/m)	-0,460*	-0.424*	-0.419*	-0.515*
A2	EC (dS/m)	-0.148 ^{ns}	-0.131 ^{ns}	-0.125 ^{ns}	-0.184 ^{ns}
A3	EC (dS/m)	-0.813*	-0.826*	-0.822*	-0.827*
A1+A2+A3	Desvio padrão	0.1542	0.0740	0.1242	0.1657

Significância: *p < 0,05; ns = não significativo.

A Tabela 12 mostra as relações entre os índices indiretos e a condutividade elétrica, bem como o desvio padrão da média. Para A1, a análise de correlação demonstra que houve relação negativa moderada entre CE e GDVI ($p < 0,05$). No entanto, os outros índices apresentaram correlação fraca. Para A2, todas as correlações não foram significativas. A análise da área A3 demonstrou correlação forte negativa para todas as variáveis ($p < 0,05$), não diferindo estatisticamente, mas o GDVI e SAVI demonstraram os maiores resultados.

Resultados semelhantes foram observados em WU et al. (2014), que correlacionaram índices de vegetação e salinidade com leituras de CE do solo em assentamentos irrigados e não irrigados em Dujaila – Iraque Central, verificaram melhores resultados para GDVI, seguido pelo NDVI, SAVI e EVI. Do mesmo modo, Bouaziz et al. (2011) constataram que os índices de vegetação NDVI, SAVI e EVI exibiram baixa correlação com a CE, devido à densidade insuficiente da cobertura vegetal, bem como ocorrido na área A2 (56% de solo exposto).

Fan et al. (2012) descobriram que os valores de NDVI tinham uma relação negativa significativa com a salinidade do solo em pixels de vegetação, enquanto, a relação com solo exposto não está clara. Da mesma forma, Moreira et al (2016) com a aplicação dos índices de salinidade NDSI e COSRI, que incorporam em suas formulações a banda vermelho e infravermelho próximo (assemelhando-se com o NDVI), demonstraram correlação inversa com dados de condutividade elétrica.

Em vista dos resultados, a área A3 obteve maior coeficiente de correlação, seguida pela A1 e A2, esta última sem resultados. Entre todos índices, o maior desvio padrão foi observado no GDVI e NDVI, assemelhando-se aos resultados de Taghadosi & Hasanlou (2017), o que segundo esses autores, os índices possuem maior sensibilidade na detecção da biomassa vegetal em um intervalo maior de níveis de cinza nas imagens.

Com base nos critérios adotados, os maiores desvios padrões e as melhores correlações superiores à 95% de significância foram observados no GDVI e NDVI. Entretanto, pelo fato da formulação desses índices serem similares, o que não oferece diferenças nas cartas temáticas, e pelo fato do SAVI ser eficiente em estudos de regiões semiáridas e não diferir de forma expressiva nos resultados estatísticos, optou-se em substituir o NDVI pelo SAVI. Desse modo, os indicadores de salinidade selecionados foram GDVI, SAVI, SI-1 e SI-3.

4.7. Análise da variabilidade espaço-temporal dos parâmetros indicadores de salinidade

4.7.1. GDVI e SAVI

As Figuras 15 e 16 apresentam as cartas temáticas produzidas a partir dos índices GDVI e SAVI aplicados sobre as áreas de estudo nos dias 22/09/2014 (A), 24/08/2015 (B), 13/07/2016 (C), 16/10/2017 (D), 16/09/2018 (E) e 01/10/2019 (F).

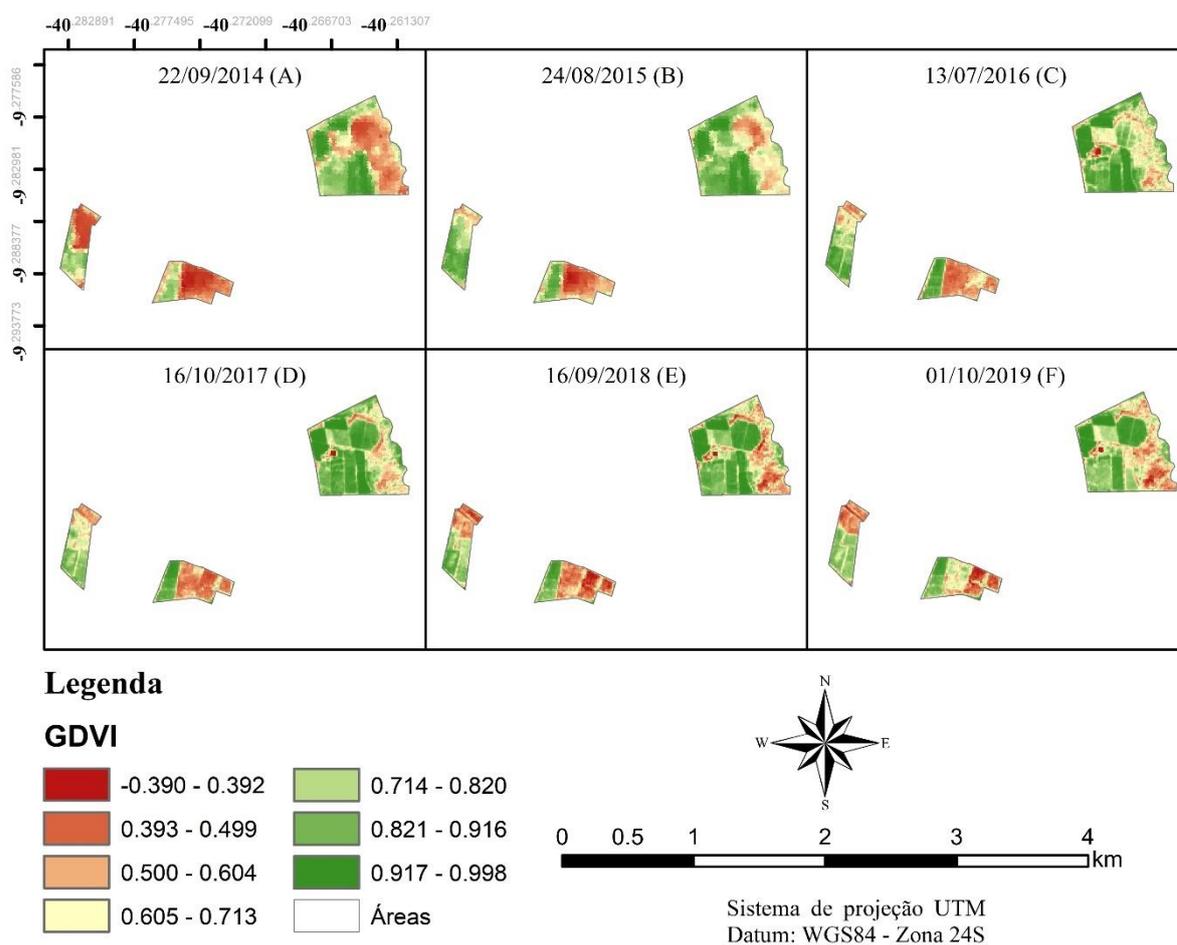


Figura 15. Carta temática do índice de vegetação da diferença generalizada – GDVI (Landsat-8 e Sentinel-2) de áreas localizadas no perímetro irrigado Maniçoba, município de Juazeiro – BA no período entre 2014 e 2019.

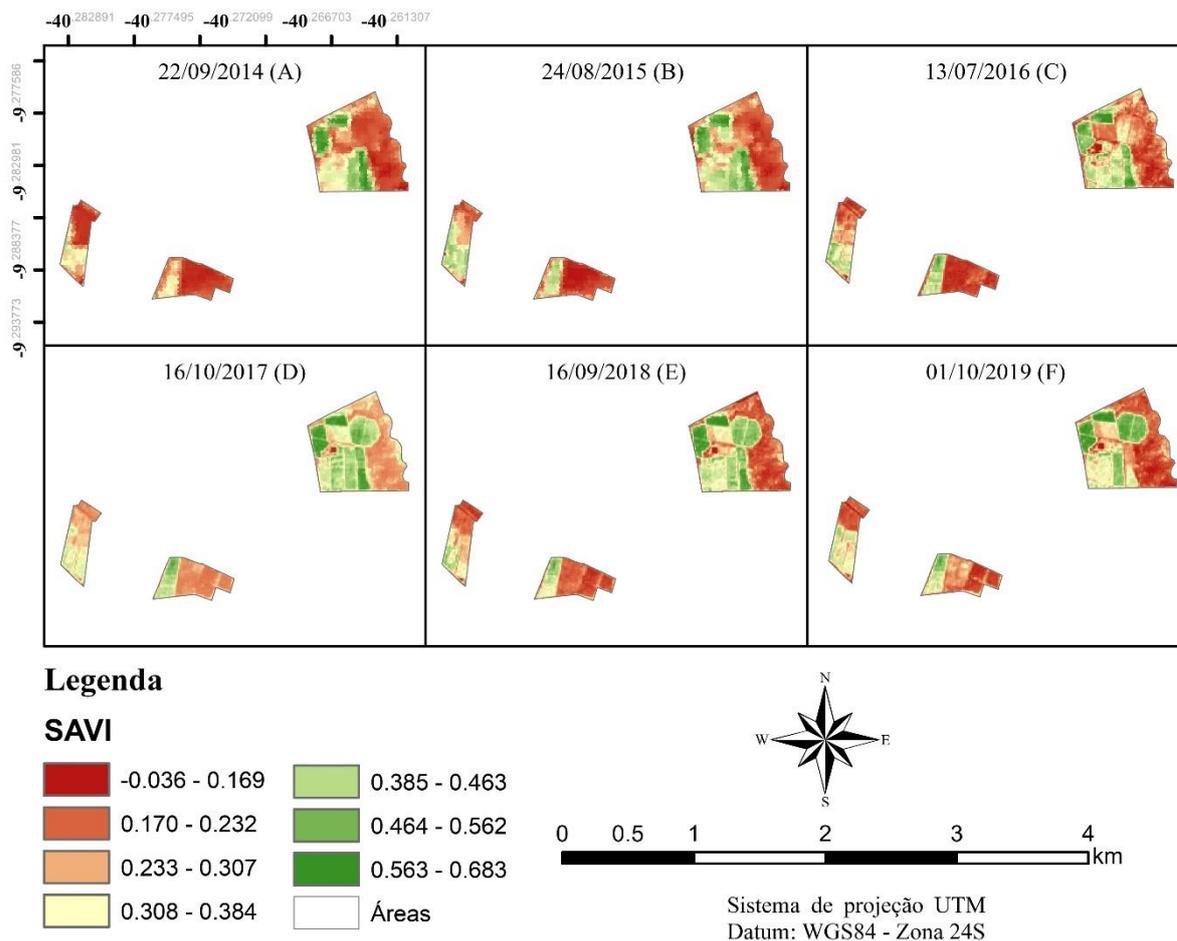


Figura 16. Carta temática do índice de vegetação ajustado ao solo – SAVI (Landsat-8 e Sentinel-2) de áreas localizadas no perímetro irrigado Maniçoba, município de Juazeiro – BA no período entre 2014 e 2019.

Com aplicação dos índices, observa-se a dinâmica das mudanças ocorridas na superfície ao longo dos anos, de modo que ocorreram ganhos e perdas da intensidade nos valores dos pixels nas três áreas, observando maiores valores em áreas agrícolas (em tons de verde) no intervalo de 0,821 a 0,998 para GDVI e 0,464 a 0,683 para SAVI.

De forma similar, a vegetação natural é exibida em tons de verde mais claro e apresenta menor intensidade de refletância no intervalo aproximado entre 0,605 a 0,820 para GDVI e 0,307 a 0,463 para SAVI, pois, no período seco, a vegetação nativa possui menor biomassa. Para o solo exposto, valores abaixo de 0,500 e 0,307, respectivamente para GDVI e SAVI (tons de vermelho), variaram ao longo do tempo em função das alternâncias observadas em área agrícola e vegetação natural.

Em estudos de monitoramento da vegetação no semiárido nordestino, município de Arcoverde - Pernambuco, Silva et al. (2019b), aplicando diferentes índices de vegetação em

imagens Landsat, verificaram respostas muito semelhantes na determinação dos valores do SAVI e NDVI na caracterização dos alvos da superfície.

Valores próximos foram verificados por Taghadosi & Hasanlou (2017), em que valores elevados nos índices de vegetação GDVI e EVI foram atribuídos a baixa salinidade, e os valores baixos, relacionados a solo exposto, foram associados a salinidade.

Em estudos de Da Silva et al. (2005) determinando o balanço de radiação à superfície e, Bezerra et al. (2014) avaliando parâmetros biofísicos, ambos no bioma caatinga no semiárido, obtiveram padrão similar nos intervalos de intensidade dos índices de vegetação na interpretação dos alvos, de acordo com o presente estudo.

Nas áreas agrícolas, onde há intensa atividade humana no manejo das culturas, o acréscimo dos valores de GDVI e SAVI nos primeiros anos (Figuras 15A, B e C; 16A, B e C) advém das culturas da manga (*Mangifera indica*) e coco-anão (*Cocos nucifera* L.) implantados anteriormente ao imageamento das imagens, os quais se desenvolveram aumentando o volume de copa, e conseqüentemente, maior atividade fotossintética. Todavia, houve redução na refletância desses pixels para os anos seguintes (Figuras 15D, E e F; 16D, E e F), decorrente da diminuição do crescimento das plantas, efeito atrelado ao acúmulo gradual de sais no solo.

Em estudo temporal da salinidade do solo no perímetro irrigado no município de Morada Nova - Ceará, Moreira et al. (2016) verificaram o decréscimo dos valores de índices de vegetação ao longo da série temporal e atribuíram essa resposta aos efeitos graduais da salinização nas áreas estudadas.

De modo geral, a vegetação natural variou mais espacialmente na porção leste da área A1, porção central na área A2 e norte na A3, partindo de 22/09/2014 (Figuras 15A e 16A) até 01/10/2019 (Figuras 15F e 16F). Tal fato fica mais evidente na carta GDVI, que devido a sua formulação matemática possui intervalos maiores nos níveis de cinza, intensificando a refletância da banda vermelha e infravermelho próximo, de forma que destaca melhor a vegetação distribuída na superfície. Por ser uma variação do NDVI, o GDVI eleva ao quadrado as bandas espectrais do vermelho e infravermelho próximo, o que o torna relevante na caracterização de regiões semiáridas (WU, 2014).

Em comparação com o SAVI, o GDVI diferenciou mais detalhadamente a vegetação frente ao solo exposto, realçando a vegetação fotossinteticamente ativa espalhada por todas as áreas, mas diante da baixa resolução espectral das imagens, não foi capaz de diferenciar espécies tolerantes de não tolerantes.

Wu (2014) constatou que quando o valor de n usado em sua fórmula é igual a 2, o GDVI é melhor correlacionado com o IAF (índice de área foliar), sendo mais sensível em vegetações de pequeno porte como pastagens, bosques e plantas rasteiras do que os outros índices comumente adotados. Taghadosi & Hasanlou (2017) identificaram que dentre diversos índices utilizados em sua pesquisa, o GDVI teve melhor desempenho como parâmetro indireto de salinidade do que os índices NDVI, EVI e SAVI.

O SAVI por sua vez, mostrou-se menos sensível na identificação de diferentes coberturas vegetais, seus maiores valores representaram bem as culturas agrícolas, mas subestimou os valores de áreas com menor densidade vegetal e vegetação nativa. Por amenizar os efeitos do solo “background” com o fator de ajuste do solo ($L=0,5$), o SAVI representa as condições próximas as reais (RIBEIRO et al., 2016), o que explica seu intervalo menor do que o GDVI. Esse comportamento condiz com achados de Polônio (2015), que encontrou valores mais baixos de SAVI em culturas em fase de crescimento e maiores na vegetação desenvolvida.

A chuva não influenciou nos resultados, visto que no período anterior ao imageamento das cenas (três meses antes) não houve registros de chuvas significativos na região, o que pode ser verificado nas Tabelas 8 e 7. Os dados observados pela estação meteorológica automática mostraram que as precipitações pluviométricas ficaram abaixo da média climatológica, o que impacta diretamente na resposta da Caatinga, que tem como característica marcante a queda de folhas como principal estratégia frente ao déficit hídrico (BEZERRA et al., 2014; SILVA et al., 2019a), impactando também nas respostas dos índices (RODRIGUES et al., 2016).

A Figura 17 representa a média dos valores de GDVI e SAVI, em escala temporal, dentro do período estudado, reunindo dados das três áreas, sobre as variações de pixels classificados como área agrícola e vegetação natural.

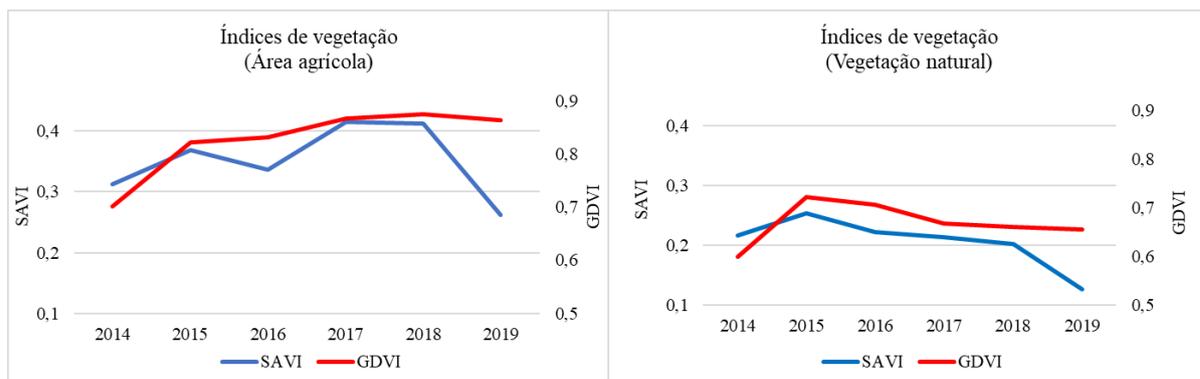


Figura 17. Valores médios de GDVI e SAVI em áreas agrícolas (A) e vegetação natural (B), no período de 2014 a 2019.

Os valores dos índices comportaram-se de forma diferente entre classes, com crescimento ao longo do tempo para áreas agrícolas (Figura 18A) e diminuição para vegetação natural (Figura 18B), esta última, a partir de 2015. Observou-se também uma pequena redução dos valores de pixels de áreas agrícola entre 2018 e 2019, embora não seja possível determinar se essa redução continuará nos próximos anos.

Nesse sentido, a queda nos valores dos índices representa a perda da biomassa verde, que decorre de processos de degradação local, pois entende-se que, quando há acúmulo de sais, a vegetação terá dificuldades em se desenvolver satisfatoriamente. O acúmulo de sais no solo gera aumento da pressão osmótica, a qual poderá atingir um nível em que as plantas não terão força o suficiente para absorver a água do solo, mesmo estando úmido (DIAS et al., 2016).

A estatística extraída das cartas temáticas consta nas Tabelas 13 e 14, onde valores mínimos e máximos correspondem as distintas feições contidas nas cenas, sendo -0,44364 e 0,99809 para GDVI em 2016, -0.06139 e 0.68314 para SAVI em 2016 e 2017, respectivamente.

Tabela 13. Valores dos parâmetros estatísticos obtidos na análise do GDVI para as datas do imageamento.

Datas das imagens	Índice de Vegetação da Diferença Generalizada – GDVI				
	Médio	DP	CV%	Mín.	Máx.
22/09/2014	0,63093	0,19057	30,20	0,30307	0,97610
24/08/2015	0,75250	0,16058	21,34	0,35655	0,98916
13/07/2016	0,73027	0,18775	25,71	-0,44364	0,99175
16/10/2017	0,72061	0,20914	29,02	-0,38983	0,99809
16/09/2018	0,73319	0,18527	25,27	-0,14062	0,99199
01/10/2019	0,72819	0,16220	22,27	0,06879	0,98414

DP: desvio padrão; CV: coeficiente de variação; Mín: valores mínimos; Máx: valores máximos.

Tabela 14. Valores dos parâmetros estatísticos obtidos na análise do SAVI para as datas do imageamento.

Datas das imagens	Índice de Vegetação Ajustado ao Solo – SAVI				
	Médio	DP	CV%	Mín.	Máx.
22/09/2014	0,26385	0,12382	46,93	0,10185	0,62634
24/08/2015	0,31065	0,11507	37,04	0,14625	0,60493
13/07/2016	0,27195	0,10694	39,32	-0,06139	0,58149
16/10/2017	0,30527	0,14784	48,43	-0,03644	0,68314
16/09/2018	0,30269	0,13593	44,91	-0,01517	0,62631
01/10/2019	0,18967	0,08017	42,27	0,00632	0,39037

DP: desvio padrão; CV: coeficiente de variação; Mín: valores mínimos; Máx: valores máximos.

Os valores negativos representam corpos hídricos, os médios significam a transição entre solo exposto e vegetação seca ou de baixo porte, e os máximos representam alta densidade vegetal. Os resultados aqui apresentados corroboram com os achados por Silva et al. (2019b), em estudos dos índices na região semiárida no período seco.

Os valores médios mantiveram-se semelhantes para todas as datas no GDVI e para SAVI reduziam em 2019. De forma geral, a redução dos valores médios revela, decréscimo nos valores de níveis de cinza contidos nos pixels de vegetação, significando a perda da produtividade, já que a maioria das plantas cultivadas são glicófitas (WILLADINO & CAMARA, 2010) e o aumento da salinidade no solo em terras agrícolas reduz linearmente a biomassa vegetal (ZHANG et al., 2015), principalmente a mangueira que é uma espécie sensível a condições de salinidade (MAAS, 1986).

Os valores de coeficiente de variação (CV%) mostraram variabilidade moderada mínimo e máximo de 21,34% e 30,20% para GDVI e 37,04% e 48,43% para SAVI. Essa heterogeneidade é verificada nas Figuras 15 e 16, não obstante, os valores diminuíram para 2019, o que remete a definição do uso do solo com o tempo. Porém, a salinidade é um fenômeno dinâmico, espacialmente e temporalmente (QUEIROZ et al., 2016), e sua influência tende a continuar alterando a cobertura do solo com o decorrer dos anos.

4.7.2. SI-1 e SI-3

As Figuras 18 e 19 apresentam as cartas temáticas construídas a partir dos índices de SI-1 e SI-3 sobre as áreas estudadas no período considerado.

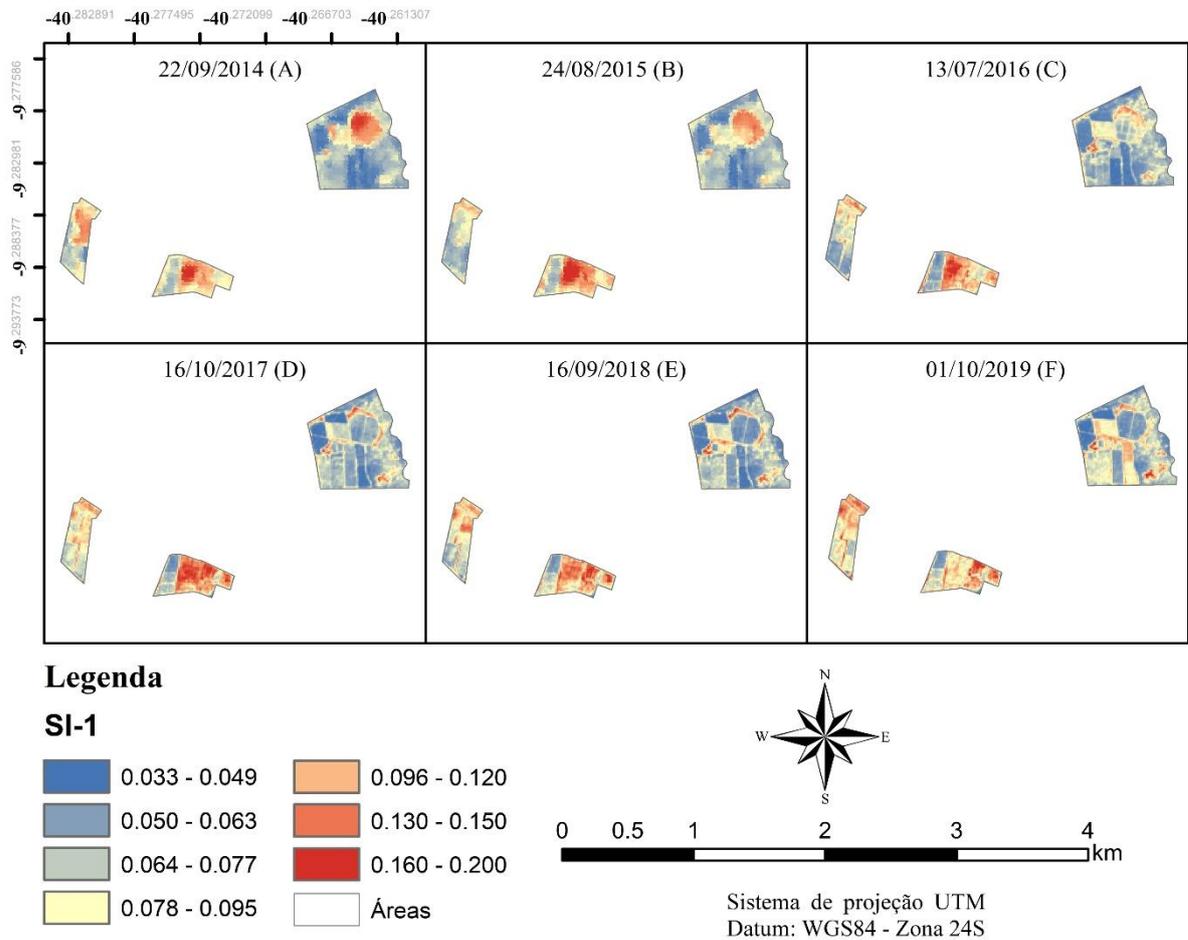


Figura 18. Carta temática do índice de salinidade SI-1 (Landsat-8 e Sentinel-2) de áreas localizadas no perímetro irrigado Maniçoba, município de Juazeiro – BA, no período entre 2014 e 2019.

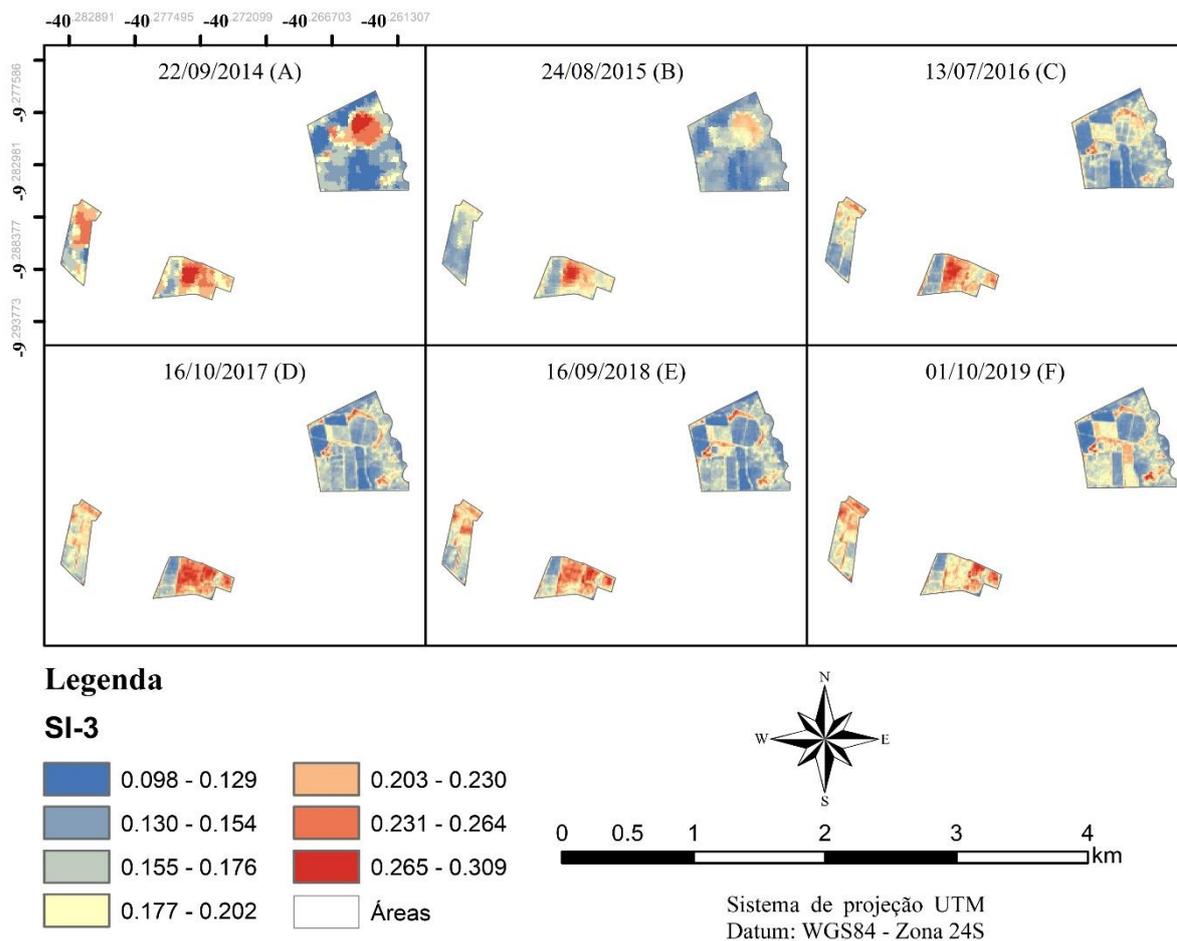


Figura 19. Carta temática do índice de salinidade SI-3 (Landsat-8 e Sentinel-2) de áreas localizadas no perímetro irrigado Maniçoba, município de Juazeiro – BA, no período entre 2014 e 2019.

Observa-se que os parâmetros SI-1 e SI-3 foram eficientes na identificação de áreas de solo exposto (tons de vermelho), realçado pelo aumento na intensidade do brilho nos pixels, que quanto maior (intervalo de 0,096 a 0,200 para SI-1 e 0,0203 a 0,309 para SI-3) indicam ausência de biomassa, enquanto os valores de intensidade mais baixa (tons de azul) exibem intervalo entre 0,033 e 0,095 para SI-1 e intervalos entre 0,098 a 0,202 para SI-3, este último característico de áreas vegetadas.

Como observado nas cartas, os índices funcionam satisfatoriamente no registro de mudanças sobre a superfície por reduzir as incertezas causadas pela mistura de assinaturas espectrais da vegetação seca e solo exposto, além de acentuar pixels que ao longo dos anos passam a refletir mais ou menos determinados comprimentos de onda, como consequência das atividades e impactos sobre os alvos da superfície. Portanto, estes índices atingem maiores valores à medida em que o solo perde umidade, o que gera aumento da refletância das bandas

espectrais contidas em suas fórmulas, e, por conseguinte, crostas salinas serão mais facilmente encontradas na superfície (METTERNICHT & ZINCK, 2003; DOUAOUI et al., 2006).

Diferentemente dos índices de vegetação, o SI-1 e SI-3 mostram melhores resultados onde a influência da vegetação é mínima, e não exista obstáculos na trajetória entre radiação refletida e sensor. Nessas condições, durante o processo de coleta de amostras de solo para análise da condutividade elétrica foram observadas crostas de sais espalhadas sobre o solo. Essas crostas que exibem alto brilho sob incidência de luz, refletindo fortemente nas bandas do visível (vermelho, verde e azul) e no infravermelho próximo (SCHMID et al., 2008).

Ainda sobre as Figuras 18 e 19, os índices não diferiram na composição apresentada nas cartas temáticas, tal fato se deve a formulação matemática utilizar as mesmas bandas espectrais (verde e vermelho) nos cálculos de bandas, porém em operações matemáticas diferentes (equação 5 e 7). Douaoui et al. (2006) e Thagadosi & Hasanlou (2017), utilizaram os dois índices em suas pesquisas, obtendo melhores correlações no SI-3 em comparação com o SI-1.

Quando se deseja analisar de forma direta a salinidade do solo através de Sensoriamento Remoto, tal abordagem pode ser complicada e muitas vezes confusa, pois há diversos fatores que podem influenciar a refletância espectral do solo, como por exemplo: a umidade, matéria orgânica, presença de espécies halófitas, rugosidade do terreno, textura do solo, entre diversos outros (METTERNICHT & ZINCK, 2003; ALLBED et al., 2013).

Assim, a busca pelo conhecimento e por recursos tecnológicos para a compreensão das interações da radiação eletromagnética dos diferentes alvos, ajuda na decisão e escolha dos indicadores como SI-1, SI-3 e outros disponíveis na literatura. Nesse sentido, além dos índices diretos e indiretos adotados nesse estudo, foram consideradas informações de temperatura da superfície, albedo, evapotranspiração, análises da condutividade elétrica do extrato de saturação do solo e dados meteorológicos.

Diversos autores como Allbed & Kumar (2014), Scudieiro et al. (2015); Gorji et al. (2017) e Taghadosi & Hasanlou (2017), também utilizaram os mesmos índices de salinidade (SI-1, SI-2, SI-3 e IB) e de vegetação, em paralelo com parâmetros biofísicos, condutividade elétrica, uso de diferentes sensores orbitais, uso de geoestatística, estatística descritiva, regressões e multivariada, tudo como estratégia para predição da salinidade em regiões semiáridas.

A Figura 21 apresenta os valores médios de SI-1 e SI-3 em escala temporal dentro do período de estudo, considerado apenas os pixels de solo exposto de todas as áreas.

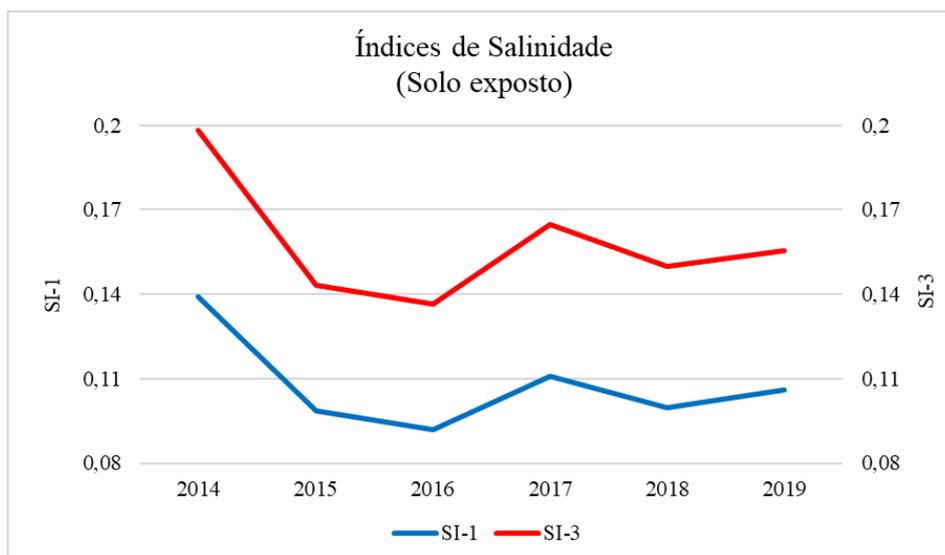


Figura 20. Valores médios de SI-1 e SI-3 em solo exposto no período de 2014 a 2019.

De modo geral, verifica-se um decréscimo considerável nos valores dos índices entre 2014 e 2016, e posterior aumento para os anos seguintes. Essa redução verificada nos primeiros anos pode ser atribuída ao crescimento de cultivares previamente implantados nas áreas agrícolas, mas que também pode ser consequência de um ano com maiores registros de chuva, como em 2014 (Tabela 8), fator determinante nas alterações da paisagem ao estimular a regeneração da vegetação nativa ou até mesmo mudar a forma de como os sais se distribuem na superfície.

Essa variabilidade é esperada em lugares onde existe constante interferência humana, variações sazonais de vegetação, condições climáticas e acúmulos de sais, além da textura e estrutura dos solos (SHMID et al., 2008). Todos esses fatores atuam nas mudanças na superfície do solo e modificam a energia refletida na superfície para aquisição de dados pelos sensores. Segundo Metternicht & Zinck (2003), solos salinos possuem respostas espectrais mais altas nas regiões visível e infravermelho do espectro do que solos não salinos, e solos fortemente salinos-sódicos apresentam maior resposta espectral do que solos salinos-sódicos moderados.

As Tabelas 15 e 16 apresentam a estatística descritiva dos índices SI-1 e SI-3, para o período de estudo. Nas quais os valores mínimos e máximos 0,018100 e 0,215150 para SI-1, (respectivamente nos dias 16/09/2108 e 22/09/2014), e 0,02844 e 0,30891 para SI-3, (dia 13/07/2016 e 22/09/2014), variaram em concordância com a Figura 20. Os valores mínimos referem-se a corpos hídricos e sombras de nuvens, e os valores máximos pertencem a solo exposto desprovido de vegetação.

Tabela 15. Valores dos parâmetros estatísticos obtidos na análise do SI-1.

Datas das imagens	Índice de salinidade SI-1				
	Médio	DP	CV	Mín.	Máx.
22/09/2014	0,124380	0,032800	26,37	0,066580	0,215150
24/08/2015	0,081778	0,029174	35,67	0,033070	0,198890
13/07/2016	0,070229	0,028719	40,89	0,019790	0,170740
16/10/2017	0,079368	0,033873	42,68	0,018560	0,180290
16/09/2018	0,075326	0,026654	35,39	0,018100	0,162930
01/10/2019	0,083634	0,021122	25,26	0,039710	0,162990

DP: desvio padrão; CV: coeficiente de variação; Mín: valores mínimos; Máx: valores máximos.

Tabela 16. Valores dos parâmetros estatísticos obtidos na análise do SI-3.

Datas das imagens	Índice de salinidade SI-3				
	Médio	DP	CV	Mín.	Máx.
22/09/2014	0,14258	0,05727	40,16	0,04823	0,30891
24/08/2015	0,11833	0,04337	36,65	0,04678	0,29215
13/07/2016	0,10301	0,04356	42,28	0,02844	0,25544
16/10/2017	0,11681	0,05108	43,73	0,02912	0,26743
16/09/2018	0,11127	0,04130	37,11	0,02849	0,24468
01/10/2019	0,12117	0,03184	26,27	0,05628	0,24229

DP: desvio padrão; CV: coeficiente de variação; Mín: valores mínimos; Máx: valores máximos.

Valores médios mínimos e máximos (0,070229 e 0,124380) ocorreram, respectivamente em 13/07/2016 e 22/09/2014 para SI-1, e mínimos e máximos (0,10301 e 0,14258) para SI-3 na mesma data. O desvio padrão divergiu mais para as médias do SI-1 do que em SI-3, e o coeficiente de variação inicialmente elevados, para um e outro, reduziu ao longo do tempo, com menores variações no ano de 2019.

Por sim, ambos os índices se comportaram de forma similar nos valores apresentados, tanto em valores estatísticos, quando nos resultados observados nas Figuras 18, 19 e 20.

5. CONCLUSÕES

Solos salinos estão distribuídos por todas as áreas, variando significativamente em solos expostos e vegetação natural. Essa variação é causada provavelmente por condições climáticas, fatores ambientais e interferência humana.

Os índices mostraram-se eficientes em diferenciar as refletâncias dos alvos na superfície, suas variações quantitativas e qualitativas ao longo do tempo, permitiu inferir sobre os processos decorrentes de degradação, atribuídos a salinização do solo, o que foi condizente com a realidade observada em loco.

A aplicação da análise multivariada pelo método de Componentes Principais (ACP) identificou os conjuntos de parâmetros ambientais que mais se relacionam com o albedo, a temperatura da superfície, a evapotranspiração real e com a condutividade elétrica do solo observada em campo.

Os índices de vegetação GDVI e SAVI caracterizaram espaço-temporalmente as variações da vegetação natural e área agrícola. No entanto, o GDVI diferenciou de forma mais precisa a vegetação de menor porte como rasteiras, forrageiras e arbustos, do solo exposto, o que sugere que este seja melhor indicado para estudos no semiárido.

Os índices de salinidade SI-1 e SI3 também foram eficazes na identificação de solo exposto e sua expansão ao longo do tempo, tanto em tamanho de área como em aumento da refletância, o que corrobora com o prognóstico de salinidade e distribuição dos sais nas áreas estudadas.

A salinidade é um fenômeno difícil de se identificar diretamente através de imagens orbitais, devido a sua alta variabilidade na distribuição sobre os solos, profundidade no perfil do solo, níveis de concentração e tipos de sais, como também, elementos sob superfície como a umidade do solo, matéria orgânica e ocorrência de vegetação tolerante. Diferentemente de estudos realizados por outros autores com sensores de menor resolução espacial e temporal como os satélites da família Landsat, os índices de salinidade extraídos das imagens do satélite Sentinel-2, mostraram baixos coeficientes de correlação na regressão linear com dados da condutividade elétrica do solo.

Mesmo com um banco de dados considerado pequeno para análises temporais, o satélite Sentinel-2, em conjunto com dados do Landsat-8, identificaram a variação na refletância dos pixels nas áreas de estudo, bem como o aumento na distribuição de solos expostos em áreas agrícolas, com maior intensidade sobre a vegetação natural, onde não há o controle e manejo da água e solo, o que indica que essas áreas estão em processo de degradação devido aos altos níveis salinos verificados.

6. CONSIDERAÇÕES E SUGESTÕES

Os perímetros irrigados da região do vale do São Francisco são uma das principais fontes de renda para a população e para arrecadação pelo Estado, seus impactos na economia ultrapassam as fronteiras do campo, levando alimentos, riquezas e desenvolvimento em nível nacional. A região é considerada referência nacional na fruticultura irrigada, no entanto a salinização dos solos, além de ser um grave problema ambiental, prejudica o desenvolvimento dessas atividades trazendo perdas financeiras e impactos ambientais negativos, visto que é prática comum dos produtores abandonar áreas que tiveram seus solos exauridos pela perda da capacidade produtiva, muitas vezes, devido a salinização dos solos.

Assim, além das pesquisas tradicionalmente desenvolvidas em nível local como, por exemplo, a caracterização dos solos, análise dos impactos dessas atividades no meio ambiente e estudos sobre qualidade da água para irrigação, que requerem tempo e altos investimentos com transporte, equipamentos de trabalho e mão de obra qualificada, muitas vezes faltam incentivos de financiamento público privado para impulsionar essas ações, o que acaba ficando a cargo apenas de pesquisas de pós-graduação em nível de mestrado e de doutorado.

Contudo, o sensoriamento remoto é uma ciência comprovadamente capaz de monitorar e diagnosticar diversos problemas ambientais, principalmente os que prejudicam a agricultura de exportação e de subsistência em diversas escalas, produzindo dados confiáveis, de forma rápida e muitas vezes de baixo investimento, que darão suporte para um melhor planejamento dos órgãos ambientais responsáveis e produtores nas medidas de controle, prevenção e mitigação das terras já comprometidas. Por essa e outras razões, recomenda-se levar adiante essa pesquisa, ampliando seus horizontes, produzindo dados através de imagens e informações disponíveis do passado para melhor compreender as origens e ter maior segurança nos resultados.

Além disso, existem diversas metodologias que podem ser incorporadas nesse estudo na busca de melhorar os resultados, como também o uso de equipamentos de rápida coleta de dados da salinidade dos solos para ampliar o banco de dados e diagnosticar grandes extensões de terras.

Um dos principais problemas verificados, mas que também revela a importância do presente estudo, foi a baixa disponibilidade de trabalhos nacionais voltados exatamente para a salinidade dos solos, principalmente nessa região de grande importância como o perímetro irrigado da Maniçoba e tantos outros projetos de irrigação do Vale do São Francisco.

Como verificado, o uso dos dados do satélite Sentinel-2 mostrou-se eficiente e possui potencial para continuidade dessa e em outras linhas de pesquisa. A inclusão de imagens obtidas por sensores hiperespectrais nesse tipo de estudo, pode auxiliar na caracterização das assinaturas espectrais dos diferentes alvos da superfície. Ainda nesse sentido, satélites com maior resolução espacial ou o uso de VANTs poderão preencher as lacunas deixadas pelos dados processados pelos sensores multiespectrais convencionais, como o caso das famílias de satélites Landsat, Sentinel-2, entre outros disponíveis no mercado.

7. REFERÊNCIAS BIBLIOGRÁFICAS

AGUIAR NETTO, A. O.; GOMES, C. C. S.; LINS, C. C. V.; BARROS, A. C.; CAMPECHE, L. F. S. M.; BLANCO, F. F. Características químicas e salino-sodicidade dos solos do Perímetro Irrigado California, SE, Brasil. **Ciência Rural**, v.37, p.1640-1645, 2007.

ALLBED, A.; KUMAR, L.; ALDAKHEEL, Y. Y. Assessing soil salinity using soil salinity and vegetation indices derived from IKONOS high-spatial resolution imageries: Applications in a date palm dominated region. **Geoderma**, v. 230, p. 1-8, 2014.

ALLBED, A.; KUMAR, L. Soil salinity Mapping and Monitoring in Arid and Semi-Arid Regions Using Remote Sensing Technology: A Review. **Advances in Remote Sensing**, v. 2, p. 373-385, 2013.

ALLEN, R. G.; BASTIAANSSEN, W.; WATERS, R.; TASUMI, M.; TREZZA, R. Surface Energy Balance Algorithm for Land (SEBAL). **Advanced Training and Users Manual**. Idaho implementation, version, v. 1, p. 98, 2002.

ALVARENGA, A. S.; MORAES, M. F. **Processamento digital de imagens LANDSAT-8 para obtenção dos índices de vegetação NDVI e SAVI visando a caracterização da cobertura vegetal no município de Nova Lima - MG**. Disponível em: <<http://mundogeo.com/blog/2014/06/10/processamento-digital-de-imagens-landsat-8-para-obtencao-dos-indices-de-vegetacao-ndvi-e-savi-visando-a-caracterizacao-da-cobertura-vegetal-no-municipio-de-nova-lima-mg/>>. Acesso em: 18 de maio de 2019.

ARAUJO, W. O. COELHO, C. J. **Análise de Componentes Principais (PCA)**. University Center of Anápolis, Anápolis, 2009.

ASCHBACHER, J.; MILAGRO-PÉREZ, M. P. The European Earth monitoring (GMES) programme: Status and perspectives. **Remote Sensing of Environment**, v. 120, p. 3-8, 2012.

AZABDAFTARI, A.; SUNARB, F. Soil salinity mapping using multitemporal landsat data. The International Archives of the Photogrammetry, **Remote Sensing and Spatial Information Sciences**, v. 41, p. B7, 2016.

BARBOSA, H. A.; HUETE, A. R.; BAETHGEN, W. E. A 20-year study of NDVI variability over the northeast region of Brazil. **Journal of Arid Environments**, v. 67, n. 2, p. 288–307, 2006.

BARRETO, A. C. **Modelagem da salinidade do solo com a utilização de técnicas de sensoriamento remoto**. Tese (Doutorado em Manejo do Solo e Água) – Universidade Federal do Semiárido, Embrapa Solos (ALICE), 2019.

BARROS, M. D. F. C.; BEBÉ, F. V.; DOS SANTOS, T. O.; CAMPOS, M. C. C. Influência da aplicação de gesso para correção de um solo salino-sódico cultivado com feijão caupi. **Revista de Biologia e Ciências da Terra**, v. 9, n. 1, p. 77-82, 2009.

BEZERRA, J. M.; MOURA, G. B. A.; SILVA, B. B.; LOPES, P. M. O.; SILVA, E. F. F. Parâmetros biofísicos obtidos por sensoriamento remoto em região semiárida do estado do Rio Grande do Norte, Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.18, n.1, p.73-84, 2014.

BIAS, E. DE S.; BRITES, R. S.; ROSA, A. N. de C. S. Imagens de Alta Resolução Espacial. In: MENESES, P. R.; DE ALMEIDA, T. **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. cap. 15, p. 239-263, 2012.

BOONSTRA, J; RITZEMA, H. P.; WOLTERS, W.; OOSTERBAAN, R. J.; RES, L.; VAN LIESHOUT, A. M. **A methodology for identification of waterlogging and soil salinity conditions using remote sensing**. CSSRI/Alterra-ILRI, 2002.

BORENGASSER, M.; HUNGATE, W. S.; WATKINS, R. **Hyperspectral Remote Sensing: Principles and Applications**. Taylor & Francis Group. p. 119, 2008.

BOUAZIZ, M.; MATSCHULLAT, J.; GLOAGUEN, R. Improved remote sensing detection of soil salinity from a semi-arid climate in Northeast Brazil. **Comptes Rendus Geoscience**, v. 343, n. 11-12, p. 795-803, 2011.

BUSTAMANTE, M. M.; NOBRE, C. A.; SMERALDI, R.; AGUIAR, A. P.; BARIONI, L. G.; FERREIRA, L. G.; OMETTO, J. P. Estimating greenhouse gas emissions from cattle raising in Brazil. **Climatic Change**, v. 115, n. 3-4, p. 559-577, 2012.

CASTRO, F.; DOS SANTOS, A. M. SALINIDADE DO SOLO E RISCO DE DESERTIFICAÇÃO NA REGIÃO SEMIÁRIDA. **Mercator**, v. 19, 2019.

CHAVEZ JR, P. S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote sensing of environment**, v. 24, n. 3, p. 459-479, 1988.

COELHO, A. L. N.; CORREA, W. S. C. Temperatura de superfície celsius do sensor TIRS/Landsat-8: metodologia e aplicações. **Rev. Geografia Acadêmica**. v.7, n.1, p.31-45, 2013.

Companhia de Desenvolvimento dos Vales do São Francisco e do Parnaíba - CODEVASF. Disponível em <<https://www.codevasf.gov.br/linhas-de-negocio/irrigacao/projetos-publicos-de-irrigacao/elenco-de-projetos/em-producao/manicoba>>. Acesso em: 20 de maio de 2019.

CONGEDO, L. **Semi-Automatic Classification Plugin Documentation. Release 6.4.0.2**. Disponível em: <https://fromgistors.blogspot.com/p/user-manual.html>. Acesso em: 15 de julho de 2020.

CUNHA, T. J. F.; DA SILVA, F. H. B. B.; SILVA, M. S. L. DA; PETRERE, V. G.; SÁ, I. B.; OLIVEIRA NETO, M. B. DE; CAVALCANTE, A. C. Solos do Submédio do Vale do São Francisco: potencialidades e limitações para uso agrícola. **Embrapa Semiárido**, Petrolina, p. 11, 2008.

DA SILVA, B. B. **Balanco de Radiação e Energia com Imagens TM – Landsat**. Recife, 2016.

DA SILVA, B. B.; LOPES, G. M.; AZEVEDO, P. V. Determinação do albedo de áreas irrigadas com base em imagens Landsat 5 TM. **Revista Brasileira de Agrometeorologia**, v.13, n.2, p.201-211. 2005.

DA SILVEIRA, H. L. F.; GALVÃO, L. S.; SANCHES, I. D. A.; DE SÁ, I. B.; TAURA, T. A. Use of MSI/Sentinel-2 and airborne LiDAR data for mapping vegetation and studying the relationships with soil attributes in the Brazilian semi-arid region. **International Journal of Applied Earth Observation and Geoinformation**, v. 73, p. 179-190, 2018.

DEMARCHI, J. C.; PIROLI, E. L.; ZIMBACK, C. R. L. Análise temporal do uso do solo e comparação entre os índices de vegetação NDVI e SAVI no município de Santa Cruz do Rio Pardo - SP usando imagens Landsat- 5. **Raega-O Espaço Geográfico Análise**, UFPR, v. 21, p. 234-271, 2011.

DE OLIVEIRA, M. Gênese, classificação e extensão de solos afetados por sais. In: GHEYI, H.R.; QUEIROZ, J. E.; MEDEIROS, J. M. **Manejo e controle da salinidade na agricultura irrigada**. Campina Grande: UFPB/SBEA, p. 1-37, 1997.

DEVRIES, B.; VERBESSELT, J.; KOOISTRA, L.; HEROLD, M. Robust monitoring of small-scale forest disturbances in a tropical montane forest using Landsat time series. **Remote Sensing of Environment**, v. 161, p. 107-121, 2015.

DIAS, N. DA S.; BLANCO, F. F.; DE SOUZA, E. R.; FERREIRA, J. F. DA S.; NETO, O. N. DE SOUSA.; DE QUEIROZ, I. S. R. Efeitos dos sais na planta e tolerância das culturas à salinidade. In: GHEYI, H. R.; DIAS, N. D.; DE LACERDA, C. F.; FILHO, E. G. **Manejo da Salinidade na Agricultura: Estudos Básicos Aplicados**. INCTSAL, cap. 11, p. 152, Fortaleza 2016.

Distrito de Irrigação de Maniçoba - DIM. Disponível em: <<http://www.dim.org.br/about-page.php>>. Acesso em: 20 de maio de 2019.

DOUAOUI, A. E. K.; NICOLAS, H.; WALTER, C. Detecting salinity hazards within a semiarid context by means of combining soil and remote-sensing data. **Geoderma**, v. 134, n. 1-2, p. 217-230, 2006.

DOURADO, C. S. **Áreas de risco de desertificação: Cenários atuais e futuros frente às mudanças climáticas**. Tese (Doutorado em Engenharia Agrícola) – Universidade Estadual de Campinas – UNICAMP, 2017.

DUBOVYK, O.; MENZ, G.; CONRAD, C.; KAN, E.; MACHWITZ, M.; KHAMZINA, A. Spatio-temporal analyses of cropland degradation in the irrigated lowlands of Uzbekistan using remote-sensing and logistic regression modeling. **Environmental monitoring and assessment**, v. 185, n. 6, p. 4775-4790, 2013.

EMBRAPA MONITORAMENTO POR SATÉLITE (2013). Disponível em: <<https://www.cnpm.embrapa.br>>. Acesso em: 15 de outubro de 2019.

ENGESAT. LANDSAT 7 ETM +. Disponível em: <<http://www.engesat.com.br/imagem-de-satelite/landsat-7-etm/>>. Acesso em: 20 de setembro de 2018.

EUROPEAN SPACE AGENCY - ESA. Disponível em: <<https://sentinel.esa.int/web/sentinel/missions/sentinel-2>>. Acesso em: 10 de outubro de 2019.

FAN, X.; PEDROLI, B.; LIU, G.; LIU, Q.; LIU, H.; SHU, L. Soil salinity development in the yellow river delta in relation to groundwater dynamics. **Land Degradation & Development**, v. 23, n. 2, p. 175-189, 2012.

FERNANDES, P. D.; BRITO, M. E. B.; GHEYI, H. R.; De ANDRADE, A. P.; MEDEIROS, S. S. Halofitismo e agricultura biossalina. In: GHEYI, H. R.; DIAS, N. DA S.; LACERDA, C. F. DE;

GOMES FILHO. **Manejo da salinidade na agricultura: Estudos básicos e aplicados**. INCTSal, ed. 2, cap. 15, p. 209-242, Fortaleza 2016.

FERREIRA, P. A.; SILVA, J. B. L.; RUIZ, H. A. Aspectos físicos e químicos de solos em regiões áridas e semiáridas. In: GHEYI, H. R.; DIAS, N. DA S.; LACERDA, C. F. DE; GOMES FILHO. **Manejo da salinidade na agricultura: Estudos básicos e aplicados**. INCTSal, ed. 2, cap. 3, p. 17-34, Fortaleza 2016.

FRANÇA, M. M.; FILHO, E. I. F.; XAVIER, B. T. L. Análise do uso da terra no município de Viçosa-MG mediado por classificações supervisionadas com redes neurais artificiais e Maxver. **Revista Brasileira de Geografia Física**, v. 2, n. 3, p. 92-109, 2010.

FREIRE, M. B. G. S.; PESSOA, L. G. M.; GHEYI, H. R. Métodos de análises químicas para solos afetados por sais. In: GHEYI, H. R.; DIAS, N. DA S.; LACERDA, C. F. DE; GOMES FILHO. **Manejo da salinidade na agricultura: Estudos básicos e aplicados**. INCTSal, ed. 2, cap.4, p. 123-148, Fortaleza 2016.

FUSHITA, A. T.; REIS, R. R.; FARESIN, L.; SANTOS, J. E. Desempenho da classificação supervisionada em diferentes programas: comparação por meio do uso da terra e do índice de naturalidade da paisagem. In: **Simpósio Brasileiro de Sensoriamento Remoto. Foz do Iguaçu, PR. Anais...** São José dos Campos: INPE, p. 6465, 2013.

GARDIMAN, B. S.; MAGALHÃES, I. A. L.; DE FREITAS, C. A. A.; CECÍLIO, R. A. Análise de técnicas de interpolação para espacialização da precipitação pluvial na bacia do rio Itapemirim (ES) Analysis of interpolation techniques for spatial rainfall distribution in river basin Itapemirim (ES). **Ambiência**, v. 8, n. 1, p. 61-71, 2012.

GORJI, T.; SERTEL, E.; TANIK, A. Monitoring soil salinity via remote sensing technology under data scarce conditions: A case study from Turkey. **Ecological indicators**, v. 74, p. 384-391, 2017.

HARDLE, W.; SIMAR, L. **Applied multivariate statistical analysis**. Springer, ed. 2, p. 215-247, Berlin: 2007.

HOLANDA, J. S.; AMORIM, J. R. A.; NETO, M. F.; DE HOLANDA, A. C.; SÁ, S. V. S. Qualidade da Água para Irrigação. In: GHEYI, H. R.; DIAS, N. DA S.; LACERDA, C. F. DE; GOMES FILHO.

Manejo da salinidade na agricultura: Estudos básicos e aplicados. INCTSal, ed. 2, cap.4, p. 35-50, Fortaleza 2016.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote sensing of environment**, v. 25, n. 3, p. 295-309, 1988.

HUETE, A. R.; LIU, H. Q.; BATCHILY, K.; VAN LEEUWEN, W. A comparison of vegetation indices over a global set of TM images for MODIS-EOS. **Remote Sensing of Environment**, v. 59, p. 440-451, 1997.

IBRAHIM, Majed. Modeling soil salinity and mapping using spectral remote sensing data in the arid and semi-arid region. **International Journal of Remote Sensing Applications**, v. 6, p. 76-83, 2016.

Instituto Brasileiro de Geografia e Estatística - IBGE; **EMBRAPA. Mapa de Solos do Brasil.** Rio de Janeiro: IBGE, 2001.

Instituto Brasileiro de Geografia e Estatística - IBGE. Disponível em: <<https://cidades.ibge.gov.br/brasil/ba/juazeiro/pesquisa/23/25207?tipo=ranking>>. Acesso em: 15 de setembro de 2019.

INSTITUTO NACIONAL DE METEOROLOGIA - INMET. Disponível em: <<http://www.inmet.gov.br/portal/>>. Acesso em: 16 de setembro 2019.

Instituto Nacional de Pesquisas Espaciais - INPE. **Manual do SPRING: Tutorial de Geoprocessamento.** 2006. Disponível em: <<http://www.dpi.inpe.br/spring/portugues/tutorial/segmentacao.html>>. Acesso: 25 setembro de 2018.

IVUSHKIN, K.; BARTHOLOMEUS, H.; BREGT, A. K.; PULATOV, A. Satellite thermography for soil salinity assessment of cropped areas in Uzbekistan. **Land Degradation & Development**, v. 28, n. 3, p. 870-877, 2017.

JAYALAKSHMI, S.; VELAPPAN, E. Assessment of Water Quality Index in the St. Thomas Mount Block Using GIS and Remote Sensing. **Polish Journal of Environmental Studies**, v. 24, n. 4, 2015.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres.** São José dos Campos: Parêntese, p. 604, 2011.

JI-HUA, M.; BING-FANG, W. Study on the crop condition monitoring methods with remote sensing. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 37, n. B8, p. 945-950, 2008.

JOHNSON, R. A.; WICHERN, D. W. **Applied multivariate statistical analysis**. ed. 6, Upper Saddle River: Pearson, 2007.

JOLLIFFE, I. T. **Principal Component Analysis**. Springer series in statistics, UK, ed. 2, p. 1, 2002.

JUSTICE, C. O.; VERMOTE, E., TOWNSHEND, J. R.; DEFRIES, R.; ROY, D. P.; HALL, D. K.; LUCHT, W. The Moderate Resolution Imaging Spectroradiometer (MODIS): Land remote sensing for global change research. **IEEE transactions on geoscience and remote sensing**, v. 36, n. 4, p. 1228-1249, 1998.

KAISER, H. F. The varimax criterion for analytic rotation in factor analysis. **Psychometrika**, v. 23, n. 3, p. 187-200, 1958.

KASSAS, M. Desertification: a general review. **Journal of arid environments**, v. 30, n. 2, p. 115-128, 1995.

KHAN, N.M.; RASTOSKUEV, V. V.; SHALINA E.; SATO, Y. Mapping salt affected soil using remote sensing indicators. A Simple Approach With the Use of GIS IDRISI. 22nd **Asian Conference on Remote Sensing**, Singapore, 2001.

KHAN, S.; ABBAS, A. Using remote sensing techniques for appraisal of irrigated soil salinity. **Int. Congr. Model. Simul. (MODSIM), Model. Simul. Soc. Aust. New Zealand, Bright**, n. January, p. 2632-2638, 2007.

KHORRAM, S.; NELSON, S. A. C.; KOCH, F. H. **Remote Sensing**. Springer, 2012.

KOOHAFKAN, P. **Water and cereals in drylands**. Routledge, 2012.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, p. 159-174, 1977.

LEITE, E. M.; DINIZ, A. A.; CAVALCANTE, L. F.; GHEYI, H. R.; CAMPOS, V. B. Redução da sodicidade em solo sendo irrigado com a utilização de ácido sulfúrico e gesso agrícola. **Revista Caatinga**, v.23, p.110-116, 2010.

LOPES, J. F. B.; ANDRADE, E. DE; CHAVES, L. C. G. Impacto da irrigação sobre os solos de perímetros irrigados na bacia do Acaraú, Ceará, Brasil. **Engenharia Agrícola**, v.28, p. 34-43, 2008.

MAAS, E. V. Salt tolerance of plants. **Applied agricultural research**, v. 1, n. 1, p. 12-25, 1986.

MACCIOTTA, N. P. P.; CECCHINATO, A.; MELE, M.; BITTANTE, G. Use of multivariate factor analysis to define new indicator variables for milk composition and coagulation properties in Brown Swiss cows. **Journal of Dairy Science**, v. 95, n. 12, p. 7346-7354, 2012.

MACHADO, C. C.; DA SILVA, B. B.; DE ALBUQUERQUE, M B.; GALVÍNCIO, 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.

MARINOZZI, G.; CORREIA, R. C. Dinâmicas da agricultura irrigada do polo Juazeiro-BA/Petrolina-PE. In: Embrapa Semiárido-Artigo em anais de congresso (ALICE). In: **CONGRESSO BRASILEIRO DE ECONOMIA E SOCIOLOGIA RURAL**, 37., 1999, Foz do Iguaçu. Anais... Brasília, DF: SOBER, 1999., 1999.

MARKHAM, B. L.; BARKER, J. L. Thematic Mapper bandpass solar exoatmospheric irradiances. International. **Journal of remote sensing**, v. 8, n. 3, p. 517-523, 1987.

MEDEIROS, S. S.; CAVALCANTE, A. M. B.; MARIN, A. M. P.; TINÔCO, L. B. M.; SALCEDO, I. H.; PINTO, T. F. **Sinopse do censo demográfico para o semiárido brasileiro**. Campina Grande: INSA, 2012.

MENESES, P. R. Princípios de Sensoriamento Remoto. In: MENESES, P. R.; DE ALMEIDA, T. **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: UnB, p. 01-33, 2012.

MENESES, P. R.; SANO, E. E. Classificação pixel a pixel de imagens. In: MENESES, P. R.; DE ALMEIDA, T. **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: UnB, p. 191-220, 2012.

METTERNICHT, G. I.; ZINCK, J. A. Remote sensing of soil salinity: potentials and constraints. *Remote Sensing Environment*. v. 85, n. 1, p. 1-20, 2003.

METTERNICHT, G. I.; ZINCK, J. A. Remote Sensing of Soil Salinization: Impact on Land Management. Boca Raton: **CRC Press**, p. 31, 2008.

MINISTÉRIO DO MEIO AMBIENTE - MMA. Disponível em: <<http://www.mma.gov.br/biomas/caatinga>>. Acesso em: 20 de outubro de 2019.

MINISTERIO DO MEIO AMBIENTE - MMA. **Monitoramento dos Desmatamentos nos Biomas Brasileiros Biomas por Satélite**. Brasília: Centro de Sensoriamento Remoto – CSR/IBAMA. 2011. Disponível em: <<http://www.ibge.gov.br>>. Acesso em: 20 outubro de 2019.

MINITAB, LLC. Disponível em: <<https://support.minitab.com/pt-br/minitab/18/help-and-how-to/modeling-statistics/multivariate/how-to/principal-components>>. Acesso em: 10 de dezembro de 2019.

MINITAB Inc. **Statistical Software Data Analysis Software**. Version 18, 2019.

MOREIRA, L. C. J.; TEIXEIRA, A. D. S.; GALVÃO, L. S. Identificação de problemas de salinidade do solo utilizando técnicas de sensoriamento remoto. In: GHEYI, H. R.; DIAS, N. D.; DE LACERDA, C. F.; FILHO, E. G. **Manejo da Salinidade na Agricultura: Estudos Básicos Aplicados**. INCTSAL, ed. 2, cap. 6, p. 65-81, 2016.

MOREIRA, L. C. J.; TEIXEIRA, A. S.; GALVÃO, L. S.; LEÃO, L. A. O.; NETO, O. C. R. Potential of multispectral and hyperspectral data to detect saline-exposed soils in Brazil. **Giscience & Remote Sensing**, v. 52, n. 4, p. 416-436, 2015.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. Editora UFV, p. 320, 2005.

MORO, M. F.; NIC LUGHADHA, E.; FILER, D. L.; ARAÚJO, F. S. DE; MARTINS, F. R. A catalogue of the vascular plants of the Caatinga hytogeographical domain: a synthesis of floristic and phytosociological surveys. **Phytotaxa**, v. 160, n. 1, p. 1- 118, 2014.

MORSHED, M. M.; ISLAM, M. T.; JAMIL, R. Soil salinity detection from satellite image analysis: an

integrated approach of salinity indices and field data. **Environmental monitoring and assessment**, v. 188, n. 2, p. 119, 2016.

MOURA GARCIA, A. C. S.; DE ARAÚJO FILHO, J. C.; DA SILVA, H. P. ESTUDO ESPAÇO TEMPORAL DE ÁREAS SUSCEPTÍVEIS À DESERTIFICAÇÃO DO SEMIÁRIDO BRASILEIRO. **Revista Gestão & Sustentabilidade Ambiental**, v. 8, n. 3, p. 352-370, 2019.

MOURA, M. S. B.; SÁ, I. I. S.; DA SILVA, T. G. F.; GALVÍNIO, J. D.; RIBEIRO, J. G. Variação espacial da precipitação e temperatura do ar no Submédio São Francisco. In: Embrapa Semiárido-Artigo em anais de congresso (ALICE). In: **CONGRESSO BRASILEIRO DE METEOROLOGIA**, 14., 2006, **Florianópolis. Anais...** Florianópolis: SBMET, 2006.

MULLA, D. J. Twenty five years of remote sensing in precision agriculture: key advances and remaining knowledge gaps. **Biosystems Engineering**, v. 114, n. 4, p. 358–371, 2013.

MUSTAK, S. Correction of atmospheric haze in Resourcesat-1 Liss-4 Mx Data for urban analysis: an improved dark object subtraction approach. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. x1-1/w3, p. 283-287, 2013.

NASCIMENTO, E. F. DO N.; PEREIRA, F. A. C.; NETTO, A. DE O. A.; CAMPECHE, L. F. S. M; SANTOS, C. A. Comportamento físico-hídrico dos solos do perímetro irrigado Curaçá em Juazeiro/BA. **Irriga**, v. 17, p. 435 - 447, 2012.

NASCIMENTO, I. S.; CRUZ, C. B. M.; NEVES, S. M. A. S.; GALVANIN, E. A. S. Avaliação da Exatidão dos Classificadores MAXV ER e ISO Cluster do Software ArcGIS for Desktop, com uso de imagem Landsat-8 do Município de Cáceres/MT. **Revista Continentes**, n. 8, p. 48-62, 2016.

NOVO, EVLYN. M. L. DE MORAES. **SENSORIAMENTO REMOTO: PRINCÍPIOS E APLICAÇÕES**. São Paulo, Blucher, ed. 4, p. 28, 2012.

NOROOZI, A. A.; HOMAEE, M.; FARSHAD, A. Integrated application of remote sensing and spatial statistical models to the identification of soil salinity: A case study from Garmsar Plain, Iranian. **Environmental Science**, v. 9, p. 59-74, 2012.

PACHECO, A. P.; CERQUEIRA, M. A.; SILVA, B. B.; NICACIO, R. M. Análise espaço temporal da evapotranspiração na área de preservação ambiental da Ilha de Santa Rita, Alagoas, Brasil. **Revista**

Árvore. vol. 38, n. 3. p. 453-460, 2014.

PENNINGTON, R. T.; PRADO, D. A.; PENDRY, C. Neotropical seasonally dry forests and Pleistocene vegetation changes. **Journal Biogeography**., v. 27, p. 261-273, 2000.

PEREIRA, A. R.; SEDIYAMA, G. C.; NOVA, V.; AUGUSTO, N. **Evapotranspiração**, 2013.

PEREIRA FILHO, J. M. ET AL. Efeito da altura de corte no controle da jurema-preta (*Mimosa tenuiflora* (Wild) Poir.). **Revista Caatinga**, v. 23, n. 2, p. 51-58, 2010.

PINHEIRO, M. P. M.; A; CRUZ, R. L.; SIMÕES, W. L. Comportamento do Teor de Água num Solo Cultivado com Cana-de-Açúcar Irrigada com Diferentes Lâminas. **Revista Brasileira de Energias Renováveis**, v.4, p. 30-42, 2015.

POLÔNIO, V. D. **Índices de vegetação na mensuração do estoque de carbono em áreas com cana-de-açúcar**. Dissertação (mestrado) - Universidade Estadual Paulista Júlio de Mesquita Filho- UNESP, 2015.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento Remoto da Vegetação**. Oficina de textos, p. 8, 2012.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no estudo da vegetação**. Parêntese, 2012.

QUEIROZ, J. E.; GONÇALVES, A. C.; SOUTO, J. S.; FOLEGATTI, M. V.; SOUZA, E. R. D.; BARROS, M. D. F. Avaliação e monitoramento da salinidade do solo usando ferramentas de geoestatística. In: GHEYI, H. R.; DIAS, DA S. N.; DE LACERDA, C. F. **Manejo da salinidade na agricultura: Estudos básicos e aplicados**. INCTSal, ed. 2, cap. 5, p. 51-63, Fortaleza 2016.

RIBEIRO, E. P.; NÓBREGA, R. S.; MOTA FILHO, F. O.; MOREIRA, E. B. Estimativa dos índices de vegetação na detecção de mudanças ambientais na bacia hidrográfica do rio Pajeú. **Geosul**, Florianópolis, v. 31, n. 62, p. 59-92, 2016b.

RIBEIRO, M. R.; BARROS, M. F. C.; FREIRE, M. B. G. S. Química dos solos salinos e sódicos. In: MELO, V. F.; ALLEONI, L. R. F. Química e mineralogia do solo. Parte II – Aplicações. Viçosa: **Sociedade Brasileira de Ciência do Solo**, p. 449-484, 2009.

RIBEIRO, M. R.; FILHO, M. R. R.; JACOMINE, P. K. T. Origem e classificação dos solos afetados por sais. In: GHEYI, H. R.; DIAS, DA S. N.; DE LACERDA, C. F. **Manejo da salinidade na agricultura: Estudos básicos e aplicados**. INCTSal, ed. 2, cap. 2, p. 9-15, Fortaleza 2016a.

RIBEIRO, S. R. A.; CENTENO, J. S. Classificação do uso do solo utilizando redes neurais e o algoritmo MAXVER. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 10, Foz do Iguaçu, Anais... São José dos Campos: INPE, p. 1341-1348, 2001.

RICHARDS, L. A. **Diagnosis and improvement of saline and alkali soils**. Washington: United States Salinity Laboratory, Agriculture Handbook, USDA p. 160, 1954.

ROCHA NETO, O.; TEIXEIRA, A.; LEÃO, R.; MOREIRA, L.; GALVÃO, L. Hyperspectral remote sensing for detecting soil salinization using ProSpecTIRVS aerial imagery and sensor simulation. **Remote Sensing**, v. 9, n. 1, p. 42, 2017.

RODAL, M. J. N.; COSTA, K. C. C.; SILVA, A. N. B. L. Estrutura da vegetação caducifólia espinhosa (Caatinga) de uma área do sertão central de Pernambuco. **Hoehnea**, v. 35, n. 2, p. 209-217, 2008.

RODRIGUES, M. T.; CARDOSO, L. G.; CAMPOS, S.; RODRIGUES, B. T.; BARROS, Z. X. Comportamento do Software Terraview na Classificação Supervisionada em Diferentes Bacias. **Revista Energia na Agricultura**, v. 31, n. 3, p. 282-290, 2016.

ROSA, R. **Introdução ao Sensoriamento Remoto**. ed. 6, p. 13, Uberlândia, EDUFU, 2007.

ROUSE JR, J.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. **Monitoring vegetation systems in the Great Plains with ERTS**, 1974.

SANTOS, F. A. C. **Alterações no Balanço Radiativo e Impactos Climáticos Decorrentes do Uso da Terra no Estado de São Paulo**. Dissertação (Mestrado em Meteorologia) Campina Grande, Paraíba, p. 78, 2010.

SANTOS, J. Y. G.; SILVA, R. M.; CARVALHO NETO, J. G.; MONTENEGRO, S. M. G. L.; SANTOS, C. A. G.; SILVA, A. M. Assessment of land use change on the streamflow using GIS, remote sensing and physically-based model. **Proceedings of the International Association of Hydrological Sciences**, v. 364, p. 38-43, 2014.

SATIR, O.; BERBEROGLU, S. Crop yield prediction under soil salinity using satellite derived vegetation indices. **Field Crops Research**, v. 192, p. 134-143, 2016.

SCHMID, T.; KOCH, M.; GUMUZZIO, J. Applications of hyperspectral imagery to soil salinity mapping. In: Remote Sensing of Soil Salinization. **CRC Press**, p. 126-153, 2008.

SCHOFIELD, R.; THOMAS, D. S. G.; KIRKBY, M. J. Causal processes of soil salinization in Tunisia, Spain and Hungary. **Land Degradation & Development**, v. 12, n. 2, p. 163-181, 2001.

SCUDIERO, E.; SKAGGS, T. H.; CORWIN, D. L. Regional scale soil salinity evaluation using Landsat 7, western San Joaquin Valley, California, USA. **Geoderma Regional**, v. 2, p. 82-90, 2015.

SILVA, C. V. S.; DA SILVA, J. L. B.; DE ALBUQUERQUE MOURA, G. B.; LOPES, P. M. O.; NASCIMENTO, C. R.; DA SILVA, L. C. Monitoramento da cobertura vegetal por sensoriamento remoto no semiárido brasileiro através de índices de vegetação. **Revista Nativa**, v. 7, n. 6, p. 708-717, 2019b.

SILVA, D. A. D. O.; LOPES, P. M. O.; MOURA, G. B. D. A.; SILVA, Ê. F. D. F.; SILVA, J. L. B. D.; BEZERRA, A. C. Evolução Espaço-Temporal do Risco de Degradação da Cobertura Vegetal de Petrolina-PE. **Revista Brasileira de Meteorologia**, v. 34, n. 1, p. 89-99, 2019a.

SILVEIRA, J. A. G.; SILVA, S. L. F.; SILVA, E. N.; VIÉGAS, R. A. Mecanismos biomoleculares envolvidos com a resistência ao estresse salino em plantas. In: GHEYI, H. R.; DIAS, N. DA S.; LACERDA, C. F. DE; GOMES FILHO, E. **Manejo da salinidade na agricultura: Estudos básicos e aplicados**. INCTSal, ed. 2, cap. 13, p. 181-197, Fortaleza 2016.

SOIL SALINIZATION. Disponível em: URL <http://www.recare-hub.eu/soil-threats/salinization>. Acesso: 10 de junho de 2019.

SOUZA, L. C.; QUEIROZ, J. E.; GHEYI, H. R. Variabilidade espacial da salinidade de um solo aluvial no semiárido paraibano. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 4, n. 1, p. 35-40, 2000.

TAGHADOSI, M. M.; HASANLOU, M. Trend analysis of soil salinity in different land cover types using Landsat time series data (case study Bakhtegan Salt Lake). **International Archives of the**

Photogrammetry, Remote Sensing & Spatial Information Sciences, v. 42, 2017.

UNITED STATES GEOLOGICAL SURVEY – USGS. Disponível em: <<https://landsat.usgs.gov/landsat-8>>. Acesso em: 01 de outubro de 2019.

US Salinity Laboratory. **Diagnosis and improvement of saline and alkali soils**. Washington: United States Department of Agriculture, Agriculture Handbook n. 60, p. 160, 1954.

WANG, D.; WILSON, C.; SHANNON, M. C. Interpretation of salinity and irrigation effects on soybean canopy reflectance in visible and near-infrared spectrum domain. **International Journal of Remote Sensing**, v. 23, n. 5, p. 811-824, 2002.

WANG, F.; CHEN, X.; LUO, G.; DING, J.; CHEN, X. Detecting soil salinity with arid fraction integrated index and salinity index in feature space using Landsat TM imagery. **Journal Arid Land**, v.5, p.340 – 353, 2013.

WEISS, E.; MARSH, S. E.; PFIRMAN, E. S. “Application of NOAA-AVHRR NDVI Time-Series Data to Assess Changes in Saudi Arabia’s Rangelands,” **International Journal of Remote Sensing**, v. 22, n. 6, p. 1005-1027, 2001.

WENG, Q. **Remote Sensing and GIS Integration: Theories, Methods, and Applications**. McGraw-Hill, 2010.

WHITE, R. E. **Princípios e práticas da ciência do solo: o solo como um recurso natural**. Organização Andrei Editora, 2013.

WILLADINO, L.; CAMARA, T. R. Tolerância das plantas à salinidade: aspectos fisiológicos e bioquímicos. **Enciclopédia biosfera**, v. 6, n. 11, p. 1-23, 2010.

WU, W.; MHAIMEED, A. S.; AL-SHAFIE, W. M.; ZIADAT, F.; DHEHIBI, B.; NANGIA, V.; DE PAUW, E. Mapping soil salinity changes using remote sensing in Central Iraq. **Geoderma Regional**, v. 2, p. 21-31, 2014.

WU, J. W.; VICENT, B.; YANG, J. Z.; BOUARFA, S.; VIDAL, A. Remote sensing monitoring of changes in soil salinity: a case study in inner Mongolia, China. **Sensors**, v. 8, n. 11, p. 7035-7049, 2008.

ZHANG, T. T.; QI, J. G.; GAO, Y.; OUYANG, Z. T.; ZENG, S. L.; ZHAO, B. ZHANG, Ting-Ting et al. Detecting soil salinity with MODIS time series VI data. **Ecological Indicators**, v. 52, p. 480-489, 2015.